

PREDICCIÓN DE PARÁMETROS DE UNA PLANTA DE CRAQUEO CATALÍTICO DE FLUIDOS – FCC MEDIANTE MODELOS NEURONALES

OSCAR M. REYES T

*Ingeniero Electrónico
Universidad Industrial de Santander
reyes.uis@ieeee.org*

DIANA K. HURTADO F

*Ingeniero Electrónico
Tipiel S.A.
rkatherine@latinmail.com*

OSCAR GUALDRÓN G

*Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones
Universidad Industrial de Santander
gualdron@uis.edu.co*

RESUMEN

A partir del conocimiento de una unidad de craqueo catalítico de fluidos – FCC de una refinería europea se presenta el diseño de modelos neuronales capaces de predecir ciertos parámetros de la planta, restringidos a la zona de operación de la cual se posee la información necesaria para el entrenamiento de las redes neuronales. Más que en el modelo diseñado, se pretende hacer énfasis en las pautas y directrices que permiten abordar el problema de la identificación de sistemas y predicción de parámetros de procesos con un nivel de complejidad tal que las técnicas de modelamiento lineal puedan resultar insuficientes.

PALABRAS CLAVE: Unidad FCC, craqueo catalítico, red neuronal, modelo de referencia, predicción de parámetros, entrenamiento, retropropagación.

ABSTRACT

This document presents the design of neural models that can predict some parameters of a fluid catalytic cracking unit, located in an European refinery, using historical data. In this kind of work, it is necessary to take information about the behavior of the system, in this case the behavior of the FCC unit, which is used for neural network training. This work proposes a methodology for system identification and parameter prediction in processes with a high level of complexity, such that linear modeling techniques are not enough.

KEY WORDS: FCC unit, catalytic cracking, neural network, reference model, parameter prediction, backpropagation.

INTRODUCCIÓN

En procesos de refinación de crudo es necesario controlar de manera óptima las variables críticas con el fin de reducir costos y aumentar su eficiencia, mejorando la calidad del producto obtenido. Para llevar a cabo el control de este tipo de procesos es ventajoso contar con un modelo que lo caracterice y permita simular la dinámica del sistema facilitando así la predicción de su comportamiento ante diferentes condiciones de trabajo, de una manera virtual y sin exponer el sistema real a alteraciones que en muchos casos podrían llevarlo a un funcionamiento erróneo, inestable e inseguro. Tal es el caso de la Unidad de Craqueo Catalítico de Fluidos de la refinería Neste Oy (Porvoo-Finlandia) [3], la que en adelante se llamará unidad FCC, cuyo diagrama de flujo simplificado se muestra en la Figura 1.

Se tienen identificadas seis variables (variables manipuladas) que permiten controlar siete variables de proceso (variables controladas) cuyos valores nominales y objetivos de control se listan en la Tabla 1. El comportamiento de la unidad FCC dentro de estos rangos de operación se simuló empleando la matriz de funciones de transferencia de proceso [3] mostrada en la Tabla 2, a partir de la cual se pueden generar patrones entrada-salida necesarios para el entrenamiento supervisado de una red neuronal, con los cuales se trató de suplir la carencia de información del sistema de control distribuido (DCS) de la unidad. Aunque esta aproximación implica linealizar el problema, también permite medir el alcance del modelo neuronal como predictor de parámetros, de una manera directa, y se deja el camino abierto para validar el diseño empleando datos reales de planta.

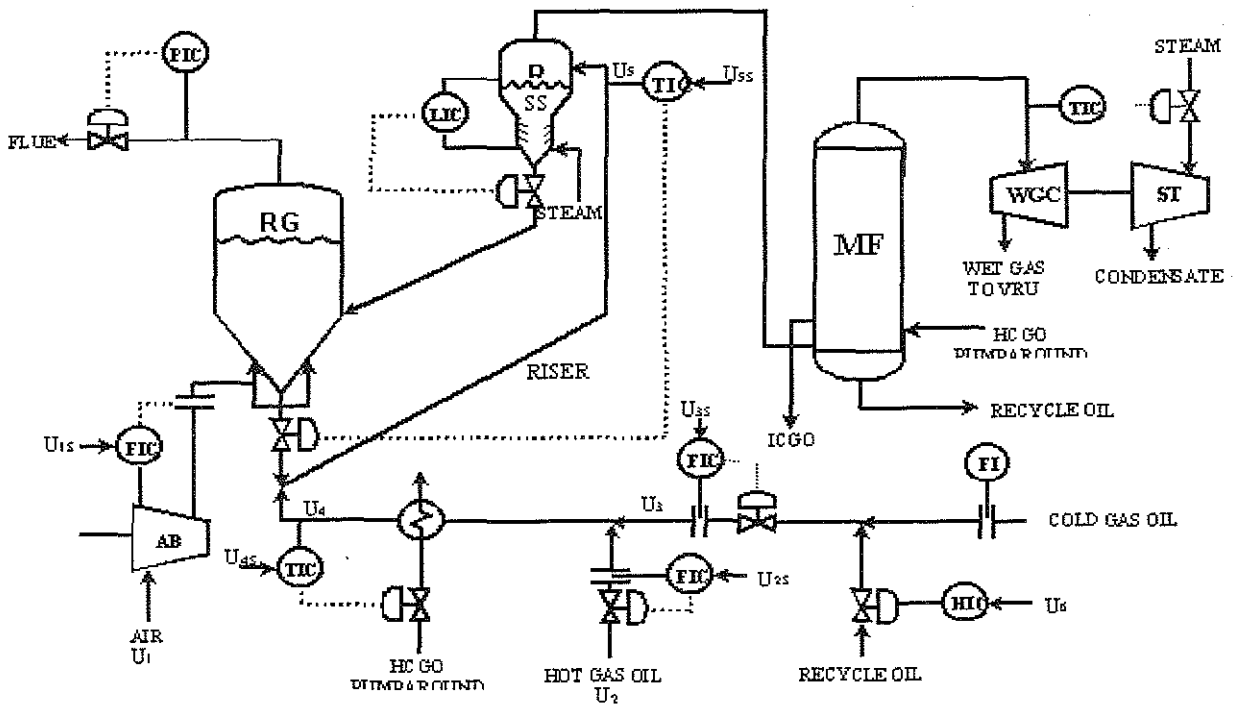


Figura 1. Diagrama de flujo de la unidad FCC.

Tabla 1. Variables de la unidad FCC.

Descripción de variables	Ta g	Valores límite	Objetivo de control
Variables manipuladas			
Flujo del aire de combustión	U ₁	140-155 T/H	-
Flujo de gasóleo caliente	U ₂	90-110 M ³ /H	IRV*
Combinación de gasóleo frío y de reciclo	U ₃	90-110 M ³ /H	IRV*
Temperatura de la carga precalentada	U ₄	230-250 °C	IRV*
Temperatura a la salida del elevador	U ₅	515-535 °C	IRV*
Salida del controlador del flujo de gasóleo de reciclo	U ₆	20-80 %	IRV*
Variables controladas			
Concentración de O ₂ en el gas de combustión	Y ₁	1.0 %	SETPOINT
Temperatura del lecho del regenerador	Y ₂	705-735 °C	Zona límite
Flujo de combustible	Y ₃	15 T/H	Zona límite máx.
Salida controlador presión de succión del WGC	Y ₄	70 %	Zona límite máx.
Salida del controlador de temperatura del elevador	Y ₅	80 %	Zona límite máx.
Presión diferencial válvula del catalizador regenerado	Y ₆	22 kPa	Zona límite mín.
Presión diferencial válvula del catalizador gastado	Y ₇	24 kPa	Zona límite máx.

* Valor ideal de reposo (Ideal Resting Value)

Tabla 2. Modelos de proceso de la unidad FCC.

	U ₁	U ₂	U ₃	U ₄	U ₅	U ₆
Y ₁	$\frac{0.097(1.7s+1)e^{-2s}}{19s^2+6.5s+1}$	$\frac{-0.87e^{-2s}}{13s^2+4.7s+1}$	$\frac{-0.092(0.25s+1)e^{-3s}}{3.7s^2+4.7s+1}$	$\frac{0.026e^{-7s}}{12s+1}$	$\frac{-0.074(4.8s+1)}{9.3s^2+3.4s+1}$	$\frac{-0.48s e^{-12s}}{(6.0s+1)(8.0s+1)}$
Y ₂	0	$\frac{0.55e^{-4s}}{27s^2+8.7s+1}$	$\frac{0.55e^{-4s}}{10s^2+4.9s+1}$	0	$\frac{0.74(1.7s+1)e^{-2s}}{11s^2+7.3s+1}$	$\frac{0.36e^{-11s}}{33s^2+6.5s+1}$
Y ₃	0	$\frac{0.14e^{-11s}}{46s^2+8.5s+1}$	$\frac{0.14e^{-6s}}{46s^2+8.5s+1}$	0	$\frac{0.27(16s+1)}{53s^2+23s+1}$	$\frac{0.015(12s+1)e^{-9s}}{66s^2+27s+1}$
Y ₄	0	$\frac{0.25e^{-11s}}{17s^2+7.0s+1}$	$\frac{0.25e^{-7s}}{3.0s+1}$	0	$\frac{0.70}{3.0s+1}$	$\frac{0.079(6.3s+1)e^{-10s}}{24s^2+12s+1}$
Y ₅	0	$\frac{0.66e^{-s}}{2.5s+1}$	$\frac{0.66e^{-s}}{2.5s+1}$	$\frac{-0.9e^{-10s}}{6.0s+1}$	$\frac{1.0}{2.0s+1}$	$\frac{-0.54e^{-11s}}{9.0s+1}$
Y ₆	0	$\frac{-0.84e^{-s}}{6.1s+1}$	$\frac{-0.90}{1.5s+1}$	$\frac{0.35e^{-10s}}{5.0s+1}$	$\frac{-(0.64s+1)}{13s^2+7.0s+1}$	$\frac{0.23(0.5s+1)e^{-14s}}{3.6s^2+11s+1}$
Y ₇	0	$\frac{0.8}{6.0s+1}$	$\frac{0.90}{s+1}$	$\frac{-0.35e^{-10s}}{5.0s+1}$	0.80	$\frac{-0.26e^{-18s}}{7.1s+1}$

ESQUEMA DE PREDICCIÓN DE PARÁMETROS MEDIANTE UN MODELO NEURONAL

Cuando se pretende implementar una estrategia de control mediante la estimación o predicción de parámetros con frecuencia se busca un modelo capaz de producir valores numéricos que coincidan con los valores medidos de algún sistema físico. Esta aplicación de la estimación de parámetros se conoce como identificación de sistemas [2], y se llevó a cabo siguiendo el procedimiento que se describe a continuación.

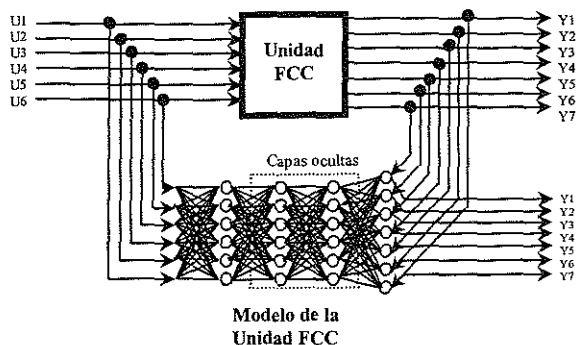


Figura 2. Sistema de identificación directo.

DEFINICIÓN DEL PROBLEMA

El *problema* se definió en términos de los parámetros a predecir que se seleccionaron, teniendo en cuenta las características de la unidad FCC y las necesidades en términos del control. Estos parámetros fueron:

- Valor de estado estable.
- Tiempo de establecimiento (t_s).
- Velocidad de respuesta.
- Rangos de operación.
- Relación de tendencia entrada-salida.
- Relación de dependencia entrada-salida.

Los parámetros sobre los cuales se fijó la tolerancia del modelo fueron: el error de estado estable y el error en el tiempo de establecimiento. Además, se buscó generar un modelo neuronal capaz de adaptarse rápidamente a nuevas condiciones de operación, para que pueda ser empleado en línea con el proceso real.

OBTENCIÓN DE DATOS

La *obtención de datos* experimentales necesarios para el entrenamiento del modelo neuronal y su puesta a punto se realizó observando el comportamiento de las entradas y salidas de la unidad FCC (Figura 2), donde la red recibe las mismas entradas que la planta y las salidas de ésta son las esperadas a la salida de la red [2]. Esta información se obtuvo a partir del modelo lineal descrito por la matriz de funciones de transferencia (Tabla 2), el cual hace las veces de la planta real.

SELECCIÓN DEL MODELO

Se realizó teniendo en cuenta el tipo de sistema que se intenta modelar y su complejidad, y teniendo en cuenta los aspectos relacionados con la definición del problema.

Debido a la dinámica de la unidad FCC y dadas las características de los parámetros que se pretenden predecir mediante el modelo neuronal, el problema se dividió en dos partes:

a) Parámetros asociados a la respuesta transitoria del sistema:

- * Tiempo de establecimiento.
- * Velocidad de respuesta
- * Relación de tendencia entrada-salida

b) Parámetros asociados a la respuesta de estado estable del sistema:

- * Valor de estado estable de las salidas.
- * Rangos de operación
- * Relación de dependencia entrada-salida

Se diseñaron sendos modelos para dar solución a cada parte del problema de forma independiente. Aunque esto implica un mayor costo al tiempo de hacer el diseño experimental, se incrementa la especialización que puede alcanzar cada modelo empleando una arquitectura relativamente simple.

Este esquema se ilustra en la Figura 3, donde el *modelo A* está diseñado y entrenado para predecir comportamiento de estado estable, en tanto que el *modelo B* lo está para predecir comportamiento

transitorio. Para acoplar las salidas de los modelos se realiza un promedio ponderado de las mismas, en función del nivel de oscilación que presente la red del modelo A en dos instantes consecutivos.




Figura 3. Esquema del modelo neuronal seleccionado.

Los modelos A y B son a su vez un arreglo de siete redes trabajando en paralelo, pues, teniendo en cuenta que las salidas son independientes entre sí, es posible modelar cada una con una red diferente, lo cual contribuye a la especialización y simplicidad del modelo conjunto.

La arquitectura de las redes que conforman los modelos A y B se resume en las Tablas 3 y 4, respectivamente.

Tabla 3. Parámetros de las redes del modelo A.

	Denominación	Valor
Tipo de red	Perceptrón multicapa	1 capa oculta 1 capa de salida
Número de neuronas	Capa oculta	2
	Capa de salida	1
Funciones de activación	Capa oculta	Sigmoidal
	Capa de salida	Lineal
Algoritmo de entrenamiento	Levenberg-Marquardt	
Parámetros de entrenamiento	Rata de aprendizaje	0.01
	Factor de momentum	0.9
Función de inicialización	Nguyen-Widrow	
Criterio de convergencia	Error cuadrático medio	

Tabla 4. Parámetros de las redes del modelo B.

	Denominación	Valor
Tipo de red	Perceptrón multicapa con HSA	2 Capas ocultas 1 Capa de salida
Definición de los TDL	Número de retardos (n_s)	12
	Retardo (T_s)	4
Función de activación y número de neuronas	Primera capa oculta	10 (sigmoidal)
	Segunda capa oculta	15 (sigmoidal)
	Capa de salida	1 (lineal)
Algoritmo de entrenamiento	Levenberg-Marquardt	
Parámetros	Rata de aprendizaje	0.01
	Factor de momentum	0.9
Función de inicialización	Nguyen-Widrow	
Criterio de convergencia	Error cuadrático medio	

La arquitectura HSA [5] empleada (Figura 4) permite un procesamiento en el tiempo [4] de secuencias de muestras con actualización de los TDL's cada cierto número de instantes (donde un instante corresponde al tiempo de muestreo de las señales de entrada).

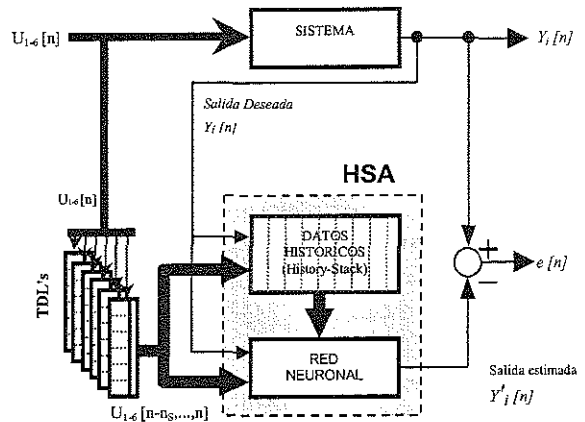


Figura 4. Integración del HSA en una estructura de identificación.

SIMULACIÓN DEL PROCESO

Para realizar la *simulación del proceso* se implementó en Simulink el modelo diseñado así como el modelo lineal disponible, con el fin de comprobar los resultados obtenidos en la predicción de parámetros de la unidad FCC. Este modelo incluye: señales de entrada, modelo lineal de la FCC y HSA, modelos neuronales A y B acoplados y señales de salida.

VALIDACIÓN DEL MODELO

La validación se realizó con patrones diferentes a los empleados durante el entrenamiento de las redes de cada modelo. El parámetro de número de épocas de validación (Tablas 3 y 4) garantiza que el entrenamiento cese cuando el error de validación aumente durante ese número de épocas consecutivas [6], y así evitar que la red empiece a memorizar los patrones de entrenamiento.

En la validación post-entrenamiento se hizo una comparación entre los datos experimentales y los resultados arrojados por el modelo neuronal, enfocada en evaluar los parámetros a predecir dentro de rangos de tolerancia previamente definidos.

- *Valor de estado estable:*
Promediando los resultados de 64 experimentos (empleando patrones generados aleatoriamente dentro del rango de operación normal de las entradas) se obtuvieron los porcentajes de error mostrados en la Tabla 5.

Tabla 5. Porcentaje de error del valor de estado estable.

% Error promedio						
Y ₁	Y ₂	Y ₃	Y ₄	Y ₅	Y ₆	Y ₇
3.87	0.02	0.99	0.74	0.61	0.92	0.91

- *Tiempo de establecimiento:*
En la Figura 5 se observa la medición del tiempo de establecimiento para una de las salidas del sistema y en la Tabla 6 se muestra el error promedio luego de 22 experimentos.









Figura 5. Medición del tiempo de establecimiento

Tabla 6. Porcentaje de error del tiempo de establecimiento.

% de error						
Y ₁	Y ₂	Y ₃	Y ₄	Y ₅	Y ₆	Y ₇
5.87	4.59	1.87	3.37	7.48	3.34	1.26

- *Velocidad de respuesta:*
Para estimar la velocidad de respuesta del modelo respecto al sistema de referencia se midió la respuesta del sistema ante senoidales puras de diferentes frecuencias (Figura 6). Aumentando la tasa de muestreo de las entradas el error de discretización disminuye, pero se pierde la relación funcional con la frecuencia (Tabla 7).



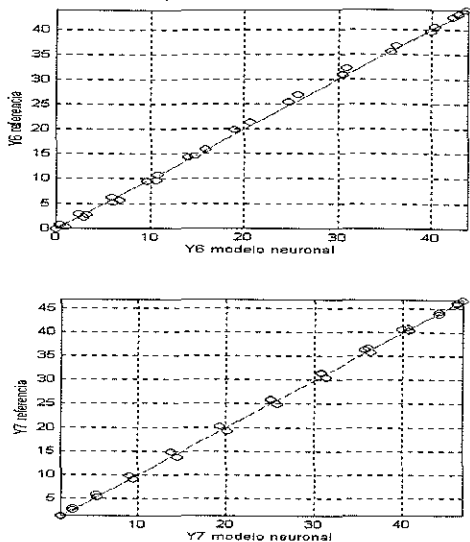


Figura 6. Comparación de la respuesta del modelo neuronal con el modelo de referencia ante entradas senoidales.

Tabla 7. Error de respuesta en frecuencia.

f (Hz)	Error de amplitud A (%) y diferencia de fase θ (grados)													
	Y ₁		Y ₂		Y ₃		Y ₄		Y ₅		Y ₆		Y ₇	
	A	θ	A	θ	A	θ	A	θ	A	θ	A	θ	A	θ
1e-2	0.3	1.8	1.1	1.3	1.0	1.5	0.5	1.4	2.4	1.0	1.3	1.4	0.4	1.2
2e-2	0.8	8.6	3.2	8.8	1.6	7.2	6.1	4.7	21.8	2.7	6.2	4.4	4.5	3.2
4e-2	16.3	27	17.9	24	175	31	6.8	3.1	19.4	4.1	4.9	8.6	1.3	7.2
0.1	86.1	42	165	72	342	36	13.5	5.4	40.5	5.4	31.4	72	24.6	46

Rangos de operación:

Dado que el modelo neuronal posee funciones de activación sigmoideas en sus capas ocultas, éste no puede producir excursiones de salida en cualquier rango. Es decir, ésta es una consecuencia de la arquitectura de la red, por lo cual es importante saber en qué rangos se desea que opere el modelo con el fin de realizar una normalización adecuada de los patrones de entrada tal que en dichos rangos no se produzca una saturación prematura de las salidas (Tabla 8).

Tabla 8. Rango de operación de las salidas del modelo neuronal

	Y ₁	Y ₂	Y ₃	Y ₄	Y ₅	Y ₆	Y ₇
Mínimo	-102.6	418.6	-47.4	-51.3	-359.3	-344.3	-343.9
Máximo	78.4	1021.3	77.4	191.3	515.2	388.3	391.8
Rango	181	602.7	124.8	242.6	874.5	732.6	735.7

Relación de tendencia entrada-salida:

Se analizó la tendencia de cada salida ante cambios individuales de las entradas en respuesta a cada entrada por separado. En la Tabla 9, una tendencia de salida directa

(D) indica que un cambio positivo en la respectiva entrada se refleja en un cambio positivo en dicha salida y viceversa. Una tendencia inversa (I), representa una tendencia opuesta entrada/salida.

Tabla 9. Tendencia de las salidas respecto a variaciones en las entradas.

	Y ₁	Y ₂	Y ₃	Y ₄	Y ₅	Y ₆	Y ₇
U ₁	D						
U ₂	I	D	D	D	D	I	D
U ₃	I	D	D	D	D	I	D
U ₄	D				I	D	I
U ₅	I	D	D	D	D	I	D
U ₆	I	D	D	D	I	D	I

Relación de dependencia entrada-salida:

La relación de dependencia entrada-salida se clasificó en tres grupos (Tabla 10), asumiendo un rango uniforme entre 0 y 100% tal que la máxima excursión debida a una sola entrada es el 100%.

Tabla 10. Relación cualitativa de dependencia entrada-salida*.

	Y ₁	Y ₂	Y ₃	Y ₄	Y ₅	Y ₆	Y ₇
U ₁	B						
U ₂	M	M	M	M	M	A	A
U ₃	B	M	M	M	M	A	A
U ₄	B				M	M	M
U ₅	B	A	A	A	M	A	A
U ₆	A	A	B	B	A	A	A

* A: Alta. M: media. B: baja. Las casillas sombreadas indican que no existe ninguna relación de dependencia.

Una vez validados los resultados, comprobando que éstos se encuentran dentro de los niveles de tolerancia admitidos, este diseño puede ser puesto a prueba con datos reales de planta y acondicionado para adaptarse en línea a nuevas condiciones de operación. Los tiempos de adaptación de las redes que conforman este modelo están por debajo de dos minutos que, teniendo en cuenta las constantes de tiempo que se manejan en este tipo de procesos químicos, resulta ser un tiempo bastante aceptable.

CONCLUSIONES

El diseño de redes especializadas permite obtener un modelo versátil con una organización bien definida, evitando así el empleo de topologías demasiado complejas. Es así, como la predicción del comportamiento del estado estable de la unidad se logró con redes de pequeñas dimensiones, reduciendo notablemente los tiempos de entrenamiento. En este sentido, en trabajos como el de Arias y García [1], se ha llegado a conclusiones similares.

Es importante adaptar la complejidad de la red a los requerimientos de velocidad de adaptación que requiera el sistema para su trabajo en línea con el proceso real. En casos en los que las señales de entrada presenten diferencias de velocidad significativas, se aconseja muestrear cada una a la frecuencia apropiada, lo que implica un diseño de experimentos más elaborado y redes neuronales que posean estructuras de almacenamiento temporal (TDL's) diseñadas independientemente para cada entrada.

Se requiere un amplio conocimiento del comportamiento del sistema y del problema a solucionar y contar con una base de datos para caracterizarlo. Con el análisis de esta información se puede realizar un diseño de experimentos apropiado, tal que los datos empleados en el entrenamiento sean suficientes para el aprendizaje de la red, sin llevarla a una extrema generalización o memorización. Para el diseño de un modelo neuronal "óptimo" no existe un procedimiento estándar. Sin embargo, pueden seguirse pautas que permitan realizar un diseño apropiado de la red sin llegar a sobredimensionarla, alcanzando tiempos de entrenamiento y resultados de validación razonables de acuerdo a la complejidad del problema.

AGRADECIMIENTOS

Los autores expresan sus agradecimientos al ingeniero Alirio Acuña por su valiosa colaboración en el desarrollo del trabajo.

BIBLIOGRAFÍA

- [1] ARIAS R., Elsa L. y GARCÍA F., Lenny G. Redes Neuronales Artificiales en fenómenos de conducción de calor multidimensional transitorio. Universidad Industrial de Santander. p. 89. 1998
- [2] BARTO, Andrew G. Connectionist Learning for Control. Editado por Miller W., Sutton R., y Werbos P. en Neural Networks for Control. 55 p. 1995.
- [3] GROSDIDIER, P., MASON, A., AITOLAHTI, A., HEINONEN, P. y VANHAMÄKI, V. FCC Unit Reactor-Regenerator Control. Computer chem. Engng, Vol. 17, No.2, 8 p. 1993.
- [4] HAYKIN, Simon. Neural Networks, A comprehensive foundation. Macmillan Publishing Company. 696 p. 1994.
- [5] MILLS, Peter M., ZOMAYA, Albert Y., TADÉ, Moses O. Neuro-Adaptive Process Control. A practical Approach. John Willey & Sons. 212 p. 1996.
- [6] USERSGUIDENEURALNETWORKSTOOLBOX. Matwhorks, 1999.