

# Identificación Neuronal para un Modelo de Combustión de Lodos en Lecho Fluidizado

R. Carrasco, E.N. Sanchez, C. Cadet y S. Carlos-Hernandez

CINVESTAV-IPN, Unidad Guadalajara, Av. del Bosque 1145, Col. El Bajío, 45015  
Zapopan, Jalisco, México (e-mail:[carrasco,sanchez]@gdl.cinvestav.mx)

GIPSA-lab, Departamento de Control Automático, UMR 5216 CNRS-INPG-UJF, BP46  
Saint Martin d'Herès Cedex (e-mail: Catherine.Cadet@gipsa-lab.inpg.fr)

CINVESTAV-IPN, Unidad Saltillo, Carretera Saltillo-Monterrey Km 13, 25900, Ramos Arizpe  
Coahuila, México (e-mail: salvador.carlos@cinvestav.edu.mx)

**Resumen**— Este artículo presenta una aplicación neuronal para identificar el modelo de combustión en un incinerador de lodos en lecho fluidizado. El modelo considerado consta de ocho ecuaciones diferenciales las cuales representan las concentraciones de especies gaseosas en el lecho fluidizado burbujeante y en el lecho de postcombustión así como las temperaturas de ambos lechos. Por otro lado, la identificación presentada en este trabajo está basada en una red neuronal recurrente de alto orden discreta (*RHONN por sus siglas en inglés*) la cual es entrenada con el algoritmo del filtro de Kalman extendido (*FKE*). El objetivo de este trabajo es reproducir la producción de componentes gaseosos y temperaturas bajo diferentes condiciones de operación. El desempeño del identificador neuronal es ilustrado vía simulación.

**Palabras clave:** Redes neuronales, filtro de Kalman extendido, combustión de lodos.

## I. INTRODUCCIÓN

La producción de desechos es una consecuencia directa del desarrollo social alrededor del mundo. La mayoría de los procesos industriales y las actividades humanas están basados en la transformación de materias primas produciendo una gran cantidad de desechos.

En Europa se obtiene una producción de desechos de 1.2 a 2.5 kg/persona/día mientras tanto en Latinoamérica se reporta una producción de 0.6 a 1.5 kg/persona/día por organismos especializados. La disposición final de tales residuos requiere de un proceso de tratamiento adecuado con el fin de reducir al mínimo los posibles riesgos ambientales y de salud.

Los vertederos y las plantas de tratamiento son los principales métodos para tratar desechos orgánicos; algunos gases de efecto invernadero como el metano ( $CH_4$ ), óxidos de nitrógeno ( $NO_x$ ), óxidos de azufre ( $SO_x$ ), entre otros, son producidos en la transformación de desechos. Las normas ambientales internacionales exigen la reducción de emisiones de este tipo de gases. Además, los procesos de transformación producen subproductos los cuales pueden ser usados como una fuente de energía renovable. Por estas razones, el tratamiento y eliminación de desechos es un

tópico científico y tecnológico importante alrededor del mundo.

Los procesos termoquímicos permiten la reducción de grandes cantidades de desechos orgánicos por medio de reacciones químicas con altas temperaturas y oxígeno controlado. La incineración (combustión completa) es una tecnología ampliamente usada debido a su alto rendimiento y a la completa destrucción de residuos orgánicos. Sin embargo, estos procesos producen cantidades considerables de monóxido de carbono ( $CO$ ) y  $NO_x$ . Las emisiones del monóxido de carbono son eficientemente controladas por la regulación del oxígeno en el horno. La formación de los óxidos de nitrógeno es muy compleja y no muy conocida. La gasificación (combustión incompleta) permite la transformación de desechos en una mezcla de gases, aplicando altas temperaturas en una atmósfera controlada de oxígeno; los componentes nocivos tales como  $NO_x$ ,  $H_2S$ , etc., pueden ser capturados y usados para sintetizar sustancias químicas con alto valor agregado antes de ser liberados a la atmósfera.

Por otro lado, las redes neuronales han sido establecidas como una excelente metodología en el diseño, identificación y control de sistemas. Usando redes neuronales es posible desarrollar algoritmos de control robustos a incertidumbres y a errores de modelado. Las estructuras más usadas son: las estáticas y las recurrentes, (Alanis, 2007). El segundo tipo permite un modelado eficiente de sistemas dinámicos complejos, son de fácil implementación y tienen la habilidad de ajustar sus parámetros en línea. Existen diferentes algoritmos de entrenamiento para redes neuronales, los cuales presentan problemas técnicos como mínimos locales, bajo aprendizaje y alta sensibilidad a condiciones iniciales entre otros. Como una alternativa viable varios algoritmos han sido propuestos, en particular los basados en filtros de Kalman.

Así, el objetivo principal de este trabajo es desarrollar un identificador neuronal, basado en una RHONN, (Rovithakis y Chistodoulou, 2000) para la concentración de especies gaseosas en el lecho fluidizado burbujeante y en el lecho de postcombustión, así como las temperaturas de ambos lechos

en un proceso de combustión de lodos. El aprendizaje de la red neuronal es basado en el algoritmo del filtro de Kalman extendido, (E. N. Sanchez y Chen, 2006). Las secciones II y III son dedicadas a dar la teoría básica acerca de las redes neuronales recurrentes de alto orden discretas y el algoritmo del filtro de Kalman extendido. La sección IV presenta el modelo de combustión de lodos en lecho fluidizado el cual es identificado por una RHONN en la sección V. La identificación es validada vía simulación y los resultados obtenidos son discutidos en la sección VI. Finalmente conclusiones y perspectivas son escritas.

## II. REDES NEURONALES RECURRENTE DE ALTO ORDEN DISCRETA

Se considera un sistema MIMO no lineal:

$$x_i(k+1) = F(x(k), u(k)) + d(w(k)), \quad (1)$$

donde  $x(k) \in \mathfrak{R}^n$  es el vector de estados,  $u(k) \in \mathfrak{R}^m$  es el vector de entradas,  $F \in \mathfrak{R}^n \times \mathfrak{R}^m \rightarrow \mathfrak{R}^n$  es una función no lineal,  $d(w(k)) \in \mathfrak{R}^n$  son las perturbaciones del sistema y  $k$  es el periodo de muestreo. Ahora una red neuronal recurrente de alto orden discreta (RHONN) puede ser presentada como:

$$\hat{x}_i(k+1) = w_i^T z_i(x(k), u(k)), \quad (i = 1, \dots, n) \quad (2)$$

donde  $\hat{x}_i (i = 1, \dots, n)$  es el estado de la  $i$ -ésima neurona,  $n$  es el número de neuronas,  $w_i (i = 1, 2, \dots, n)$  es el respectivo vector de pesos adaptado en línea,  $u = [u_1, \dots, u_m]^T$  es el vector de entradas a la red neuronal (NN por sus siglas en inglés) y  $z_i(x(k), u(k))$  está dado por:

$$z_i(x(k), u(k)) = \begin{bmatrix} z_{i_1} \\ z_{i_2} \\ \vdots \\ z_{i_{L_i}} \end{bmatrix} = \begin{bmatrix} \prod_{j \in I_1} y_i^{d_{i_j}(1)} \\ \prod_{j \in I_2} y_i^{d_{i_j}(2)} \\ \vdots \\ \prod_{j \in I_{L_i}} y_i^{d_{i_j}(L_i)} \end{bmatrix} \quad (3)$$

donde  $L_i$  es el respectivo número de conexiones de alto orden,  $I_1, I_2, \dots, I_{L_i}$  es la colección de subconjuntos no ordenados  $\{1, 2, \dots, n\}$ ,  $d_j(k)$  son enteros no negativos y  $y_i$  es definido como:

$$y_i = \begin{bmatrix} y_{i_1} \\ \vdots \\ y_{i_n} \\ y_{i_{n+1}} \\ \vdots \\ y_{i_{n+m}} \end{bmatrix} = \begin{bmatrix} S(x_1) \\ \vdots \\ S(x_n) \\ u_1 \\ \vdots \\ u_n \end{bmatrix} \quad (4)$$

La función  $S(\bullet)$  es definida por:

$$S(x) = \frac{\mu}{1 + \exp^{-\beta x}} + \varepsilon, \quad (5)$$

donde  $\beta$  y  $\mu$  son constantes positivas y  $\varepsilon$  es un número real positivo pequeño.

Se considera el problema de aproximar el sistema no lineal (1) por la siguiente red neuronal recurrente de

alto orden discreta, introduciendo el error de modelado (Ricalde, 2005):

$$\chi_i(k+1) = w_i^{*T} z_i(x(k), u(k)) + \varepsilon_{z_i}, \quad i = 1, \dots, n \quad (6)$$

donde  $\chi_i$  es el  $i$ -ésimo estado de la planta,  $\varepsilon_z$  es el error de aproximación acotado, el cual puede ser reducido incrementando el número de pesos ajustables, (Rovithakis y Chistodoulou, 2000). Se asume que existe un vector de pesos ideal  $w_i^*$  tal que  $\|\varepsilon_z\|$  puede ser minimizado en un conjunto compacto  $\Omega_{z_i} \subset \mathfrak{R}^{L_i}$ . El vector de pesos ideal  $w_i^*$ , (Rovithakis y Chistodoulou, 2000), (Alanis, 2004). En general, se asume que este vector existe y es constante pero desconocido. Definimos su estimación como  $w_i$  y su error de estimación es:

$$\tilde{w}_i(k) = w_i(k) - w_i^* \quad (7)$$

## III. FILTRO EXTENDIDO DE KALMAN COMO ALGORITMO DE ENTRENAMIENTO

El filtro de Kalman es un conjunto de ecuaciones matemáticas que provee una solución recursiva para estimar los estados de un sistema lineal perturbado con ruido aditivo en la salida, (Song y Grizzle, 1995). Para el entrenamiento basado en el filtro de Kalman los pesos de la red se convierten en los estados a estimar y la salida de la red son las mediciones utilizadas por éste. En este caso, el error entre la salida de la red neuronal y la salida de la planta pueden ser consideradas como ruido blanco aditivo. Debido al hecho de que el mapeo de la red neuronal es no lineal, es requerido un filtro de Kalman extendido, (E. N. Sanchez y Chen, 2006).

El objetivo de entrenamiento es encontrar los pesos óptimos que minimicen el error de predicción. La estimación de los pesos se hace de manera recursiva, de forma que cada actualización del peso estimado es hecha a partir del peso anterior y los datos actuales; esto implica que no se requiere la actualización de todos los pesos estimados. Ésta es la razón más importante por la cual el FKE es utilizado como algoritmo de entrenamiento de redes neuronales.

El FKE como algoritmo de entrenamiento está dado por:

$$\begin{aligned} w_i(k+1) &= w_i(k) + \eta_i k_i(k) e(k), \quad e(k) = y(k) - \hat{y}(k) \\ k_i(k) &= P_i(k) H_i(k) M_i(k), \quad i = 1, \dots, n \\ P_i(k+1) &= P_i(k) - k_i(k) H_i^T(k) H_i(k) P_i(k) + Q_i(k) \end{aligned} \quad (8)$$

with

$$M_i(k) = [R_i(k) + H_i^T(k) P_i(k) H_i(k)]^{-1} \quad (9)$$

donde  $e(k) \in \mathfrak{R}^p$  es el error de estimación,  $P_i(k) \in \mathfrak{R}^{L_i \times L_i}$  es la matriz de covarianza en el paso  $k$ ,  $w_i \in \mathfrak{R}^{L_i}$  es el vector de pesos,  $L_i$  es el respectivo número de pesos en la red neuronal,  $y \in \mathfrak{R}^p$  es la salida de la planta,  $\hat{y} \in \mathfrak{R}^p$  es la salida de la red neuronal,  $n$  es el número de estados de la red neuronal,  $K_i \in \mathfrak{R}^{L_i \times p}$  es la matriz de ganancia de Kalman,  $Q_i \in \mathfrak{R}^{L_i \times L_i}$  es la matriz de covarianza del ruido del proceso,  $R_i \in \mathfrak{R}^{p \times p}$  es la matriz de covarianza del ruido de medición y  $H_i \in \mathfrak{R}^{L_i \times p}$  es la matriz de medición donde

cada entrada ( $H_{ij}$ ) es la derivada de la  $i$ -ésima salida de la red neuronal con respecto al  $j$ -ésimo peso de la red neuronal ( $w_{ij}$ ), la cual está dada de la siguiente forma:

$$H_{ij}(k) = \left[ \frac{\partial \hat{y}(k)}{\partial w_{ij}(k)} \right] \quad (10)$$

donde  $i = 1, \dots, n$  y  $j = 1, \dots, L_i$ . Usualmente  $P_i$  y  $Q_i$  son inicializadas como matrices diagonales, con entradas  $P_i(0)$  y  $Q_i(0)$  respectivamente. Es importante remarcar que  $H_i(k)$ ,  $K_i(k)$  y  $P_i(k)$  para el filtro de Kalman extendido son acotadas, (Alanis, 2004).

#### IV. MODELO DEL INCINERADOR DE LODOS EN LECHO FLUIDIZADO

Esta sección está basada principalmente en (Li *et al.*, 2010). Figura 1, muestra esquemáticamente el incinerador en lecho fluidizado, el cual puede ser dividido en dos lechos: lecho fluidizado burbujeante y lecho de postcombustión. El lodo es introducido en el fondo del lecho fluidizado burbujeante. El aire es precalentado por un intercambiador de calor y después es inyectado con suficiente velocidad para asegurar la fluidización de la materia inerte. En el lecho de postcombustión, localizado por encima del lecho fluidizado burbujeante, la combustión se produce principalmente en gases volátiles. La concentración de oxígeno es regulada por encima del 4.5 % por el flujo de aire. Esta regulación garantiza un exceso de oxígeno asegurando una combustión completa y evita la formación del monóxido de carbono.

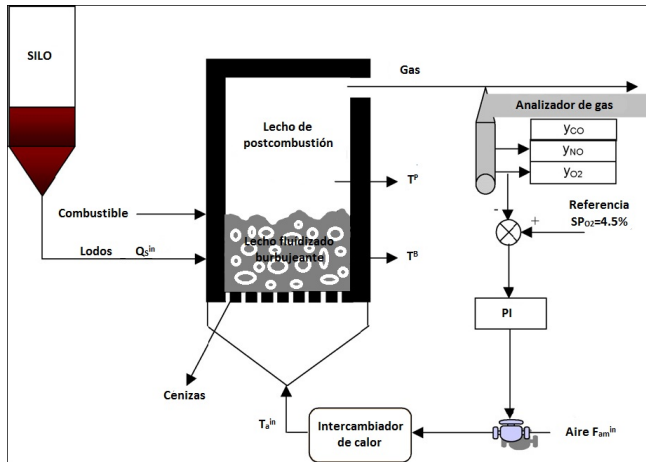


Figura 1. Incinerador de Lodos en Lecho Fluidizado

##### IV-A. Modelo de combustión de lodos

Figura 2, muestra la estructura del modelo de combustión. Las entradas medibles son: el flujo de lodos en base seca ( $Q_s^{in}$ ), el flujo del aire ( $F_{am}^{in}$ ), la temperatura del aire de entrada ( $T_a^{in}$ ), la concentración de oxígeno ( $C_{O_2}^P$ ), la temperatura del lecho fluidizado burbujeante ( $T^B$ ) y la temperatura del lecho de postcombustión ( $T^P$ ).

Las variables de estado son las concentraciones gaseosas en el lecho fluidizado burbujeante, ( $C_{H_2O}^B, C_{CO}^B, C_{O_2}^B$ ). Las

concentraciones gaseosas en el lecho de postcombustión ( $C_{H_2O}^P, C_{CO}^P, C_{O_2}^P$ ) así como las temperaturas de ambos lechos ( $T^B$  y  $T^P$ ).




Figura 2. Modelo de combustión de lodos

El modelo de combustión está escrito basado en los balances de conservación de masa y energía ("B" lecho burbujeante, "P" lecho de postcombustión):

$$\begin{aligned} \frac{dC_{H_2O}^B}{dt} &= \frac{F_{H_2O}^{in}}{V^B} - C_{H_2O}^B \frac{F_g^B}{V^B} + \varphi_{H_2O}^B \\ \frac{dC_{CO}^B}{dt} &= \frac{F_{CO}^{in}}{V^B} - C_{CO}^B \frac{F_g^B}{V^B} + \varphi_{CO}^B \\ \frac{dC_{O_2}^B}{dt} &= \frac{F_{O_2}^{in}}{V^B} - C_{O_2}^B \frac{F_g^B}{V^B} + \varphi_{O_2}^B \end{aligned} \quad (11)$$

con

$$\begin{aligned} \varphi_{H_2O}^B &= \frac{F_{H_2}^{in} + F_{CH_4}^{in}}{V^B} \\ \varphi_{CO}^B &= -1r_{22}^B + \frac{F_{CH_4}^{in}}{V^B} \\ \varphi_{O_2}^B &= -0,5r_{22}^B + \frac{-0,5F_{H_2}^{in} - 1,5F_{CH_4}^{in}}{V^B} \end{aligned} \quad (12)$$

donde  $F_i^{in}$  ( $molh^{-1}$ ) ( $i= H_2O, CO, O_2, H_2, CH_4$ ) es el flujo molar del componente  $i$  después del secado y devolatilización de lodos, reconstruido de la distribución de lodos después de la devolatilización.  $F_g^B$  ( $m^3h^{-1}$ ) es el flujo del gas,  $V^B$  es el volumen del lecho fluidizado burbujeante ( $m^3$ ),  $\varphi_i^B$  es el flujo de producción o consumo de los componentes.

$$\begin{aligned} \frac{dT^B}{dt} &= [(c_{p,a}\rho_a(T_{am})F_{am}^{in}T_a^{in} + c_{p,s}\frac{Q_s^{in}}{1-f_{H_2O}}T_b^{in}) \\ &\quad - (c_{p,g}\rho_g(T^B)F_g^BT^B + c_{p,ash}Q_s^{in}(1-f_{vol}) \\ &\quad T^B) - (F_{H_2O}^{in}L_{H_2O}) - r_{22}^B\Delta H_{R22}V^B \\ &\quad - F_{CH_4}^{in}\Delta H_{R23} - F_{H_2}^{in}\Delta H_{R24}]/c_p^Bm^B \end{aligned} \quad (13)$$

donde  $c_p^B$ ,  $c_{p,a}$ ,  $c_{p,s}$ ,  $c_{p,g}$  y  $c_{p,ash}$  son capacidades caloríficas específicas del lecho fluidizado burbujeante, aire, lodos, gas y cenizas,  $Jkg^{-1}K^{-1}$ .  $m^B$  es la masa del lecho fluidizado burbujeante,  $m_s^B = 14,000kg$  es la masa de la materia inerte,  $c_p^B = c_{p,s} = 1050Jkg^{-1}K^{-1}$ .  $c_{p,a} = 1103Jkg^{-1}K^{-1}$  y  $c_{p,g} = 1510Jkg^{-1}K^{-1}$ .  $\rho$  es la densidad, la cual depende de la temperatura del gas ( $kgm^{-3}$ ).  $L_{H_2O}$  es el calor latente del agua de vaporización,  $2,258 \times 10^6 Jmol^{-1}$ .

Los balances del lecho de postcombustión son escritos de manera similar:

$$\begin{aligned}\frac{dC_{H_2O}^P}{dt} &= \frac{C_{H_2O}^B F_g^B}{V^P} - \frac{C_{H_2O}^P F_g^P}{V^P} + \varphi_{H_2O}^P \\ \frac{dC_{CO}^P}{dt} &= \frac{C_{CO}^B F_g^B}{V^P} - \frac{C_{CO}^P F_g^P}{V^P} + \varphi_{CO}^P \\ \frac{dC_{O_2}^P}{dt} &= \frac{C_{O_2}^B F_g^B}{V^P} - \frac{C_{H_2O}^P F_g^P}{V^P} + \varphi_{O_2}^P\end{aligned}\quad (14)$$

$$\begin{aligned}\varphi_{H_2O}^P &= 0 \\ \varphi_{CO}^P &= -1r^P 22 \\ \varphi_{O_2}^P &= -0,5r^P 22\end{aligned}\quad (15)$$

$$\frac{dT^P}{dt} = [(c_{p,g}\varphi_{g(T^B)}F_g^B T^B - c_{p,g}\varphi_{g(T^P)}F_g^P T^P) - (r_{22}^B \Delta H_{R22} V^P)] / c_P^P m^P \quad (16)$$

## V. IDENTIFICACIÓN NEURONAL

En esta sección se muestra el esquema de identificación usado en este trabajo, el cual es aplicado al submodelo de combustión de lodos en un proceso termoquímico de residuos sólidos, el cual está representado por (11), (13), (14) y (16).

Para llevar a cabo la identificación se utiliza una red neuronal recurrente de alto orden discreta con  $n=8$ , considerando como medibles todas las variables de estado. La identificación de parámetros y la identificación de estados están relacionadas en el sentido de como las mediciones de los sensores pueden ser usadas para obtener una aproximación del modelo de la planta a ser controlada. Para muchas aplicaciones de control es aconsejable identificar los estados del sistema o al menos una parte de ella. El objetivo de este trabajo, es reproducir el comportamiento del modelo de combustión en lecho fluidizado bajo diferentes condiciones de operación. El identificador neuronal para el modelo de combustión de lodos es propuesto como sigue:

$$\begin{aligned}\hat{x}_1(k+1) &= w_{11}S(x_1) + w_{12}S(x_1)S(x_4) + w_{13}S(x_4) \\ &\quad + w_{14}u_1 \\ \hat{x}_2(k+1) &= w_{21}S(x_2) + w_{22}S(x_2)S(x_4) \\ &\quad + w_{23}S(x_2)S(x_3)S(x_1) + w_{24}u_1 \\ \hat{x}_3(k+1) &= w_{31}S(x_3) + w_{33}S(x_3)S(x_4) \\ &\quad + w_{33}S(x_2)S(x_3)S(x_5) + w_{34}u_1 \\ \hat{x}_4(k+1) &= w_{41}S(x_4) + w_{42}S(x_2)S(x_3)S(x_5) \\ &\quad + w_{43}u_1 \\ \hat{x}_5(k+1) &= w_{51}S(x_5) + w_{52}S(x_1)S(x_4) \\ &\quad + w_{53}S(x_5)S(x_8) + w_{54}u_1 \\ \hat{x}_6(k+1) &= w_{61}S(x_6) + w_{62}S(x_2)S(x_4) \\ &\quad + w_{63}S(x_6)S(x_8) \\ &\quad + w_{64}S(x_6)S(x_7)S(x_5) + w_{65}u_1\end{aligned}\quad (17)$$

$$\begin{aligned}\hat{x}_7(k+1) &= w_{71}S(x_7) + w_{72}S(x_3)S(x_4) \\ &\quad + w_{73}S(x_7)S(x_8) \\ &\quad + w_{74}S(x_6)S(x_7)S(x_5) + w_{75}u_1 \\ \hat{x}_8(k+1) &= w_{81}S(x_8) + w_{82}S(x_4)S(x_8) \\ &\quad + w_{83}S(x_6)S(x_7)S(x_5) + w_{84}u_1\end{aligned}$$

donde  $x_1, x_2$  y  $x_3$  corresponden a las concentraciones de especies gaseosas en el lecho fluidizado burbujeante del agua ( $H_2O$ ), monóxido de carbono ( $CO$ ) y oxígeno ( $O_2$ ).  $x_4$  es la temperatura en el lecho burbujeante.  $x_5, x_6$  y  $x_7$  son las concentraciones gaseosas en el lecho de postcombustión del agua, monóxido de carbono y oxígeno.  $x_8$  es la temperatura del lecho de postcombustión.  $u_1$  es la entrada de control que corresponde al flujo del aire.

El entrenamiento es realizado en línea, usando una configuración serie-paralelo como se muestra en la Figura 3.

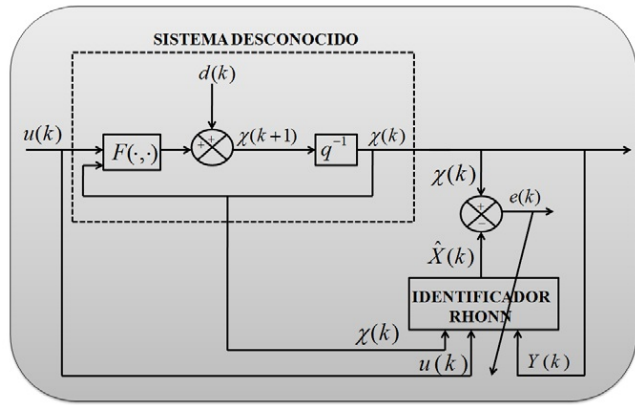


Figura 3. Esquema de Identificación

Todos los estados de la red neuronal son inicializados aleatoriamente así como los vectores de pesos iniciales. Las matrices de covarianza del FKE son inicializadas diagonalmente con elementos diferentes a cero. Estos valores son determinados por prueba y error como aparecen en la Tabla I.

$P_i(0)$	$Q_i(0)$	$R_i(0)$
$P_1(0)_{4 \times 4} = \text{diag } 9e6$	$Q_1(0)_{4 \times 4} = \text{diag } 1e2$	$R_1(0) = 1e3$
$P_2(0)_{4 \times 4} = \text{diag } 9e6$	$Q_2(0)_{4 \times 4} = \text{diag } 1e2$	$R_2(0) = 1e3$
$P_3(0)_{4 \times 4} = \text{diag } 9e6$	$Q_3(0)_{4 \times 4} = \text{diag } 1e2$	$R_3(0) = 1e3$
$P_4(0)_{3 \times 3} = \text{diag } 9e6$	$Q_4(0)_{3 \times 3} = \text{diag } 1e2$	$R_4(0) = 1e3$
$P_5(0)_{4 \times 4} = \text{diag } 9e6$	$Q_5(0)_{4 \times 4} = \text{diag } 1e2$	$R_5(0) = 1e3$
$P_6(0)_{5 \times 5} = \text{diag } 9e6$	$Q_6(0)_{5 \times 5} = \text{diag } 1e2$	$R_6(0) = 1e3$
$P_7(0)_{5 \times 5} = \text{diag } 9e6$	$Q_7(0)_{5 \times 5} = \text{diag } 1e2$	$R_7(0) = 1e3$
$P_8(0)_{4 \times 4} = \text{diag } 9e6$	$Q_8(0)_{4 \times 4} = \text{diag } 1e2$	$R_8(0) = 1e3$

TABLA I

MATRICES DE COVARIANZA PARA EL MODELO DE COMBUSTIÓN DE LODOS

## VI. RESULTADOS EN SIMULACIÓN

En esta sección se presenta los resultados obtenidos en simulación, la cual es implementada usando Matlab/Simulink®.

Figura 4, muestra la entrada de control que corresponde al flujo del aire.

Figuras 5, 6, 7, 8, 9, 10, 11 y 12 muestran las variables de estado y su respectiva identificación. La línea azul representa el modelo real mientras que la línea verde representa la identificación neuronal.

De la Figura 5 a la Figura 8 las variables de estado corresponden a las concentraciones gaseosas de agua, monóxido de carbono y oxígeno así como la temperatura en el lecho fluidizado burbujeante.

De la Figura 9 a la Figura 12 las variables corresponden a las concentraciones gaseosas de agua, monóxido y oxígeno, así como la temperatura en el lecho de postcombustión.

## VII. CONCLUSIONES

En este trabajo se lleva a cabo la identificación neural para las concentraciones de agua ( $H_2O^B, H_2O^P$ ), monóxido de carbono ( $CO^B, CO^P$ ) y oxígeno ( $O_2^B, O_2^P$ ), así como, las temperaturas ( $T^B, T^P$ ) en el modelo de combustión de lodos. La identificación es realizada usando una red neuronal recurrente de alto orden discreta considerando todos los estados como medibles. El identificador neuronal es entrenado con el algoritmo del filtro de Kalman extendido el cual es implementado en línea. Los resultados en simulación muestran la efectividad del esquema de identificación propuesto. Para dar continuidad a esta temática se analizan alternativas para el desarrollo de estrategias de control.

## VIII. AGRADECIMIENTOS

Los autores agradecen el apoyo de CONACYT, México, en el proyecto 131678.

## REFERENCIAS

- Alanis, A. Y. (2004). Entrenamiento de redes neuronales con el filtro de kalman. Tesis de maestría. CINVESTAV, Guadalajara, Mexico.
- Alanis, A. Y. (2007). Discrete-time Neural Control: Application to Induction Motors. Tesis de doctorado. CINVESTAV-IPN, Unidad Guadalajara.
- E. N. Sánchez, A. Y. Alanis y G. Chen (2006). Recurrent neural networks trained with kalman filtering for discrete chaos reconstruction. *Dynamics of Continuous, Discrete and Impulsive Systems Series B* **13**, 1–18.
- Li, S., C. Cadet, P. X. Thivel y F. Delpech (2010). Towards the modelling and control of nox emission in a fluidized bed sludge combustor. *Computers and Chemical Engineering* **35**, 1281–1294.
- Ricalde, L. J. (2005). Inverse Optimal Adaptive Recurrent Neural Control with Constrained Inputs. Tesis de doctorado. CINVESTAV, Guadalajara, Mexico.
- Rovithakis, G. A. y M. A. Chistodoulou (2000). *Adaptive Control with Recurrent High-Order Neural Networks*. Springer-Verlag.
- Song, Y. y J. W. Grizzle (1995). The extended kalman filter as a local asymptotic observer for discrete-time nonlinear systems. *Journal of Mathematical Systems, Estimation and Control*.




Figura 4. Entrada de control




Figura 5. Concentración de agua y su respectiva identificación




Figura 6. Concentración de CO y su respectiva identificación




Figura 7. Concentración de oxígeno y su respectiva identificación




Figura 10. Concentración del CO y su respectiva identificación




Figura 8. TB y su respectiva identificación




Figura 11. Concentración del oxígeno y su respectiva identificación




Figura 9. Concentración del agua y su respectiva identificación




Figura 12. TP y su respectiva identificación