

Identificación Neuronal de un Modelo Cinético para la Gasificación de Biomasa que Considera Señales de Entradas

R. Carrasco¹, E.N. Sánchez¹, S. Carlos-Hernandez²

¹ CINESTAV-IPN, Unidad Guadalajara, ² CINESTAV-IPN, Unidad Saltillo

¹ Av. Del Bosque 1145, Col. El Bajío, 45015, Zapopan, Jalisco, México.

² Carretera Saltillo-Monterrey Km. 13, 25900 Ramos Arizpe, Coahuila, México.

¹{carrasco, sanchez} @gdl.cinvestav.mx, ²salvador.carlos@cinvestav.edu.mx

Resumen—En este trabajo se presenta la aplicación de una red neuronal para la identificación de un modelo cinético correspondiente a la zona de reducción en un proceso de gasificación de combustibles sólidos, incluyendo señales de entrada. El modelo considerado consta de seis ecuaciones diferenciales que presentan la producción de los siguientes componentes: carbono, hidrógeno, monóxido de carbono, agua, bióxido de carbono y metano. Estas son obtenidas a partir de las ecuaciones de velocidad de reacción de las cuatro principales reacciones en la zona de reducción de un gasificador de lecho fluidizado. Por otro lado, la identificación realizada en el presente trabajo está basada en una red neuronal recurrente discreta de alto orden (RHONN), la cual es entrenada con el algoritmo de filtro de Kalman extendido (FKE). El desempeño del identificador neuronal se ilustra vía simulación.

Palabras clave: Gasificación de biomasa, redes neuronales, filtro de Kalman extendido.

I. INTRODUCCIÓN

El desarrollo de la sociedad requiere de la energía. Esto plantea un grave problema, ya que los consumos energéticos se ven incrementados continuamente debido al aumento de las necesidades de la población, la industria y el transporte. Con esta situación es imprescindible encontrar nuevas fuentes que garanticen el suministro de energía a la población. Una alternativa a esta problemática es la generación de energía mediante sistemas basados en fuentes renovables.

La biomasa es uno de los componentes fundamentales para alcanzar niveles aceptables de producción de energía procedente de fuentes renovables. El aprovechamiento y la mejora del uso eficiente de la biomasa conducen a la generación de empleo, beneficios medioambientales y favorece el desarrollo en zonas rurales. Se puede considerar que el uso eficaz de esta fuente de energía permite el avance y progreso de los países subdesarrollados garantizando la conservación del medio ambiente y la seguridad del abastecimiento energético. La gasificación de biomasa consiste en transformar un combustible sólido en gases con un alto potencial energético, además de recuperar elementos nocivos antes de que se liberen a la atmósfera, los cuales pueden ser empleados como materia prima para la síntesis

de productos con valor agregado. La transformación de sólido a gas se desarrolla en varias etapas: secado, pirolisis, combustión y reducción; cada una tiene lugar en diferentes zonas de reacción [1]. Debido a que la reacción de combustión en la zona de pirolisis es mucho más rápida que la reacción de gasificación en la zona de reducción ([1], [2] [3]), todas las velocidades en la gasificación de biomasa son controladas por las cinéticas en la zona de reducción.

Las redes neuronales se han establecido como una excelente metodología en el diseño de sistemas de identificación y control. Usando redes neuronales, es posible desarrollar algoritmos de control que sean robustos a incertidumbres y a errores de modelado. Las estructuras neuronales más usadas son: las estáticas y las recurrentes [4]. El segundo tipo permite un modelado eficiente de sistemas dinámicos complejos, son de fácil implementación y tienen la capacidad de ajustar sus parámetros en línea.

Existen diferentes algoritmos de entrenamiento para redes neuronales, los cuales presentan problemas técnicos tales como mínimos locales, lento aprendizaje y alta sensibilidad a las condiciones iniciales, entre otros. Como una alternativa viable se han propuesto diversos algoritmos, en particular los basados en el filtro de Kalman.

El objetivo principal de este trabajo es desarrollar un identificador neuronal, basada en una RHONN [5] con el fin de identificar las concentraciones de de carbono (C), hidrógeno (H₂), monóxido de carbono (CO), agua (H₂O), bióxido de carbono (CO₂) y metano (CH₄). El aprendizaje de la red neuronal está basado en el algoritmo del filtro de Kalman extendido [6]. Con este identificador se implementa una plataforma de simulación que permita evaluar estrategias de control.

Las secciones II y III están dedicadas a dar una explicación de los conceptos básicos de las redes neuronales recurrentes de alto orden y de su algoritmo de entrenamiento. En la sección IV se presenta el modelo cinético basado en el mecanismo de reacciones de superficie, el cual es utilizado para llevar a cabo la identificación neuronal presentada en la sección V. La identificación es validada vía simulación y los resultados obtenidos se discuten en la sección VI. Finalmente se muestran conclusiones y perspectivas.

II. RED NEURONAL RECURRENTE DE ALTO ORDEN DISCRETA

Considérese un sistema MIMO no lineal

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

donde $x \in \mathfrak{R}^n, u \in \mathfrak{R}^m$ y $F \in \mathfrak{R}^n \times \mathfrak{R}^m \rightarrow \mathfrak{R}^n$ es una función no lineal.

Sea una red neuronal discreta de alto orden

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

donde $x_i (i = 1, 2, \dots, n)$ es el estado de la i -ésima neurona, n es el número de estados, $w_i (1, 2, \dots, n)$ es el respectivo vector de adaptación de pesos en línea y $z_i(x(k), u(k))$ dado por

$$z_i(x(k), u(k)) = \begin{bmatrix} z_{i1} \\ z_{i2} \\ \vdots \\ z_{iL_i} \end{bmatrix} = \begin{bmatrix} \prod_{j \in I_1} y_i^{d_{ij}(1)} \\ \prod_{j \in I_2} y_i^{d_{ij}(2)} \\ \vdots \\ \prod_{j \in I_{L_i}} y_i^{d_{ij}(L_i)} \end{bmatrix} \quad (3)$$

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 de $\{1, 2, \dots, n\}$, $d_{ij}(k)$ son enteros no negativos y y_i es definido como

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

En (4), $u = [u_1, u_2, \dots, u_m]^T$ es el vector de entrada a la red neuronal y $S(\bullet)$ es definida por

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

donde β es la pendiente de la función.

Se considera ahora el problema de aproximar el sistema no lineal (1), por la siguiente red neuronal recurrente de alto orden discreta [7]:

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

donde x_i es el i -ésimo estado de la planta, ε_{zi} es el error de aproximación, el cual puede ser reducido, incrementando el número de pesos. Se supone que existe un vector de pesos ideal w_i^T tal que $\|\varepsilon_{zi}\|$ puede ser minimizado en un conjunto compacto $\Omega_{zi} \subset \mathfrak{R}^{L_i}$ [8]. En general, se supone que existe un vector y y es constante pero desconocido, ver [9] para

mayor información. Si definimos la estimación de w^* como w_i , el error de estimación es:

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

III. EL FILTRO DE KALMAN EXTENDIDO 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 [10]. Para el entrenamiento basado en el filtro de Kalman, los pesos de la red son los estados a estimar. En este caso, el error entre la salida de la red neuronal y la salida medible de la planta puede ser considerado como ruido blanco. Puesto que la red neuronal constituye una transformación no lineal, entonces se requiere un filtro de Kalman.

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 tal 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. Esta es la razón más importante por la cual el FKE es utilizado como algoritmo de entrenamiento de redes neuronales.

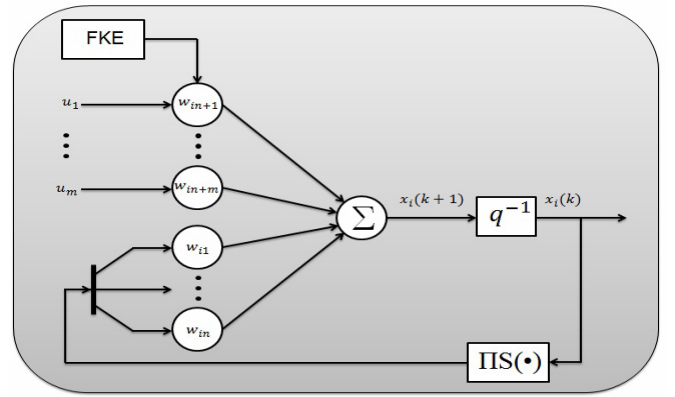


Fig. 1 RHONN entrenada con el filtro de Kalman extendido.

El FKE como algoritmo de entrenamiento está dado por:

$$w_i(k+1) = w_i(k) + \eta_i K_i(k) e(k) \quad (8)$$

$$K_i(k) = P_i(k) H_i^T(k) M_i(k) \quad i = 1, \dots, n$$

$$P_i(k+1) = P_i(k) - K_i(k) H_i^T(k) P_i(k) + Q_i(k)$$

donde

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

$$e(k) = y(k) - \hat{y}(k)$$

con $e(k) \in \mathfrak{R}^p$ el error de estimación y $P_i(k) \in \mathfrak{R}^{L_i \times L_i}$ la matriz de covarianza en el paso k , $w_i \in \mathfrak{R}^{L_i}$ 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 neuronal, n es el número de estados, $K_i \in \mathfrak{R}^{L_i \times p}$ es la matriz de ganancia de Kalman, $Q_i \in \mathfrak{R}^{L_i \times L_i}$ es la matriz de covarianza de 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:

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

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 FKE son acotadas [11].

IV. MODELO CINÉTICO

Esta sección está basada principalmente en [1],[3],[12] y [13]. En la Fig. 2, se muestra un esquema simplificado de un gasificador de lecho fluidizado, donde se muestran las diferentes zonas de reacción. La biomasa entra a alta temperatura a la zona de pirolisis, donde es convertida en carbón y en volátiles. La combustión tiene lugar cuando los volátiles reaccionan con el oxidante. El proceso pirolisis-combustión está dominado por reacciones exotérmicas donde la biomasa es convertida en carbón, CO_2 y H_2O . Se supone que parte de los volátiles son transformados en metano dentro de la zona de pirolisis. Los productos obtenidos en la zona de pirolisis pasan a la zona de reducción del carbón, donde predominan reacciones endotérmicas y la energía térmica generada por el proceso pirolisis-combustión es transformada en energía química en gases combustibles como H_2 y CO . Las concentraciones de los productos existentes en la zona de pirolisis se convierten en las concentraciones de los reactantes en la zona de reducción de carbón. Así, en dicha zona, las cantidades iniciales de H_2 y CO son cero y la cantidad de nitrógeno permanece constante.

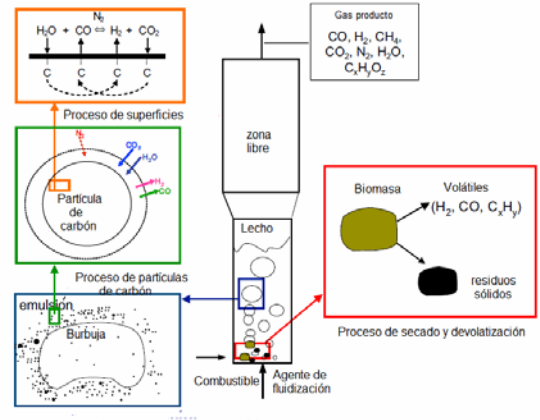




Fig. 2 Gasificador de lecho fluidizado.

La ecuación general de la gasificación de biomasa es:



donde $\text{CH}_\alpha\text{O}_\beta$ es la representación química de la biomasa, y y , z , w , y x_i son los coeficientes molares de varios componentes. Los subíndices α y β son determinados por análisis elemental último.

Las reacciones que tienen lugar en la zona de reducción se muestran a continuación:



La razón de producción de los diferentes componentes está dada por las siguientes ecuaciones diferenciales:

$$\begin{aligned} \frac{dx_1}{dt} &= v_1(X) + v_2(X) + v_3(X) \\ \frac{dx_2}{dt} &= -v_2(X) + 2v_3(X) - 3v_4(X) \\ \frac{dx_3}{dt} &= -2v_1(X) - v_2(X) - v_4(X) \\ \frac{dx_4}{dt} &= v_2(X) + v_4(X) \\ \frac{dx_5}{dt} &= v_1(X) \\ \frac{dx_6}{dt} &= -v_3(X) + v_4(X) \end{aligned} \quad (13)$$

donde $v_i(X)$ representan las ecuaciones de velocidad de reacción de las reacciones (12) las cuales se obtienen considerando el mecanismo de Langmuir-Hinshelwood [14], y están dadas por:

$$-v_1(X) = k_{a1} \frac{x_5 - x_3^2 / (P_X K_{p1})}{\sum (K_i + 1/p)x_i} \left(\frac{x_1,0}{x_1} \right)^{1/3} \frac{x_1}{\rho d_p} \quad (14)$$

$$-v_2(X) = k_{a2} \frac{x_4 - x_3 x_2 / (P_X K_{p2})}{\sum (K_i + 1/p)x_i} \left(\frac{x_1,0}{x_1} \right)^{1/3} \frac{x_1}{\rho d_p} \quad (15)$$

$$-v_3(X) = k_{a3} \frac{x_2^2 - x_6 / (P_X K_{p3})}{\sum (K_i + 1/p)x_i} \left(\frac{x_1,0}{x_1} \right)^{1/3} \frac{x_1}{\rho d_p} \quad (16)$$

$$-v_4(X) = k_{a4} \frac{x_4 x_6 - x_3 x_2^3 / (P^2 X K_{p4})}{\sum (K_i + 1/p)x_i} \left(\frac{x_1,0}{x_1} \right)^{1/3} \frac{x_1}{\rho d_p} \quad (17)$$

donde K_i es la constante de adsorción para las especies i , p es la presión en el gasificador, ρ es la densidad del carbón, d_p es el diámetro inicial del carbón en forma de esfera, K_{p_i} es la constante de equilibrio, P_X es la presión total del gasificador, $x_1,0$ es la cantidad inicial del carbón y k_{ai} es la constante de velocidad para la reacción i . La constante de velocidad es el producto de un factor pre-exponencial A_i y un factor exponencial, conforme a la ecuación de Arrhenius,

$$k_{ai} = A_i \exp(-E_{ai} / RT) \quad (18)$$

donde R es la constante universal del gas, E_{ai} es la energía de activación para la reacción i y T es la temperatura en la zona de reducción. El signo negativo de las ecuaciones de la velocidad de reacción indica el componente global de la reacción que se está consumiendo, mientras que el signo positivo indica el componente que se está produciendo

De (14), (15), (16) y (17), se deduce que el gas producto depende de la presión y la temperatura del gasificador.

En este trabajo se usan los parámetros que se muestran en la Tabla 1. Las constantes de equilibrio fueron determinadas de las Tablas termoquímicas de JANAF.

Tabla 1. Parámetros

Parámetro	Valor	Parámetro	valor
p	1 atm	A_1	3.616×10^1 1/s
T	800°C	A_2	1.517×10^4 1/s
dp	1 mm	A_3	4.189×10^{-3} 1/s
R	8.314 J/molK	A_4	7.301×10^{-2} 1/s
E_{a1}	77.39 kJ/mol	K_{p1}	1.3123 kg/ms ²
E_{a2}	121.62 kJ/mol	K_{p2}	1.0440 kg/ms ²
E_{a3}	9.21 kJ/mol	K_{p3}	1 kg/ms ²
E_{a4}	36.15 kJ/mol	K_{p4}	1.0440 kg/ms ²

V. IDENTIFICADOR DEL MODELO CINÉTICO DE GASIFICACIÓN DE BIOMASA.

En esta sección se muestra el esquema de identificación que se aplica al modelo cinético para la gasificación de biomasa el cual queda representado por el sistema de ecuaciones (12). Para ello se utiliza una red neuronal recurrente de alto orden con $n=6$ considerando medibles los estados. La red neuronal utilizada está dada por

$$\begin{aligned} \hat{x}_1(k+1) &= w_{11}S(x_1) + w_{12}S(x_1)S(x_5)S(x_3) + w_{13}S(x_4) + w_{14}S(x_3)S(x_4) \\ &\quad + w_{15}S(x_2)S(x_6) + w_{16}u_T + w_{17}u_p \\ \hat{x}_2(k+1) &= w_{21}S(x_2) + w_{22}S(x_4) + w_{23}S(x_3)S(x_4) + w_{24}S(x_6)S(x_1) \\ &\quad + w_{25}u_T + w_{26}u_p \\ \hat{x}_3(k+1) &= w_{31}S(x_3) + w_{32}S(x_5) + w_{33}S(x_3)S(x_1) + w_{34}S(x_3)S(x_2)S(x_1) \\ &\quad + w_{35}S(x_4)S(x_6) + w_{36}u_T + w_{37}u_p \\ \hat{x}_4(k+1) &= w_{41}S(x_4) + w_{42}S(x_3)S(x_2) + w_{43}S(x_6) + w_{44}S(x_3)S(x_2)S(x_1) \\ &\quad + w_{45}u_T + w_{46}u_p \\ \hat{x}_5(k+1) &= w_{51}S(x_5) + w_{52}S(x_3)S(x_1) + w_{53}u_T + w_{54}u_p \\ \hat{x}_6(k+1) &= w_{61}S(x_6) + w_{62}S(x_2) + w_{63}S(x_6)S(x_1) + w_{64}S(x_4)S(x_6) \\ &\quad + w_{65}S(x_3)S(x_2)S(x_1) + w_{66}u_T + w_{67}u_p \end{aligned} \quad (19)$$

donde x_1, x_2, x_3, x_4, x_5 y x_6 corresponden a las concentraciones de carbono (C), hidrógeno (H₂), monóxido de carbono (CO), agua-gas (H₂O), bióxido de carbono (CO₂) y metano (CH₄) respectivamente, u_T y u_p son las entradas

de control que corresponden a incrementos en la temperatura y la presión respectivamente. Las condiciones iniciales están definidas por:

$$x_2 = 0, \quad x_3 = 0, \quad x_7 = z \quad (20)$$

$$x_1 + x_5 + x_6 = 1 \quad (21)$$

$$2x_4 + 4x_6 = \alpha + 2w \quad (22)$$

$$x_4 + 2x_5 = 2y + \beta + w \quad (23)$$

Las cuales son obtenidas de (11).

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

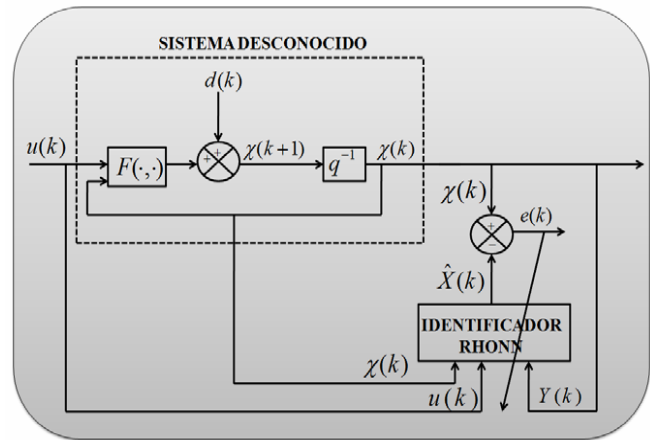


Fig. 3 Esquema de identificación.

Todos los estados de la red son inicializados aleatoriamente así como los vectores de pesos iniciales. Las matrices de covarianza para el FKE son inicializadas con valores determinados por prueba y error los cuales se presentan en la Tabla 2.

Tabla 2. Matrices de covarianza para la RHONN en el proceso de identificación.

$P_i(0)$	$Q_i(0)$	$R_i(0)$
$[P_1(0)]_{7 \times 7} = \text{diag} \{9e6\}$	$[Q_1(0)]_{7 \times 7} = \text{diag} \{0.1\}$	$[R_1(0)]_{1 \times 1} = 9e2$
$[P_2(0)]_{6 \times 6} = \text{diag} \{9e7\}$	$[Q_2(0)]_{6 \times 6} = \text{diag} \{0.01\}$	$[R_2(0)]_{1 \times 1} = 8e3$
$[P_3(0)]_{7 \times 7} = \text{diag} \{2e6\}$	$[Q_3(0)]_{7 \times 7} = \text{diag} \{0.1\}$	$[R_3(0)]_{1 \times 1} = 2e3$
$[P_4(0)]_{6 \times 6} = \text{diag} \{9e7\}$	$[Q_4(0)]_{6 \times 6} = \text{diag} \{0.001\}$	$[R_4(0)]_{1 \times 1} = 7e2$
$[P_5(0)]_{4 \times 4} = \text{diag} \{9e9\}$	$[Q_5(0)]_{4 \times 4} = \text{diag} \{0.01\}$	$[R_5(0)]_{1 \times 1} = 8e3$
$[P_6(0)]_{7 \times 7} = \text{diag} \{9e5\}$	$[Q_6(0)]_{7 \times 7} = \text{diag} \{0.01\}$	$[R_6(0)]_{1 \times 1} = 5e2$

VI. RESULTADOS EN SIMULACIÓN

En esta sección se presentan los resultados obtenidos en simulación. El software empleado es Matlab ®.

Las Fig. 4 y Fig. 5 muestran las entradas de control.

Las Fig. 6, Fig. 7, Fig. 8, Fig. 9, Fig. 10 y Fig. 11 muestra cada estado y su respectiva identificación. El identificador se inicializa aleatoriamente para evaluar la convergencia, la cual se ilustra al inicio de la simulación. Como puede observarse en las graficas respectivas el tiempo de convergencia es pequeño y el error de identificación tiende a cero.




Fig. 4 Entrada de control de la temperatura.




Fig. 5 Entrada de control de la presión.




Fig. 6 Concentración de carbono y su respectiva identificación.




Fig. 7 Concentración de hidrógeno y su respectiva identificación.




Fig. 8 Concentración de monóxido de carbono y su respectiva identificación.




Fig. 9 Concentración de agua y su respectiva identificación.




Fig. 10 Concentración de bióxido de carbono y su respectiva identificación.




Fig. 11 Concentración de metano y su respectiva identificación.

© Trademark of The Matlab Inc.

VII. CONCLUSIONES

En este artículo se desarrolla la identificación de las concentraciones de carbono (C), hidrógeno (H_2), monóxido de carbono (CO), agua (H_2O), bióxido de carbono (CO_2) y metano (CH_4) respectivamente, usando una red neuronal recurrente de alto orden discreta considerando que todos los estados son medibles; el identificador neuronal es entrenado con el algoritmo del filtro de Kalman extendido el cual es implementado en línea. Los resultados de simulación muestran la efectividad del esquema de identificación propuesto. De esta manera se ilustra la aplicabilidad de las redes neuronales en el estudio y análisis en los procesos termoquímicos para la generación de energía. Para dar continuidad a esta temática, actualmente se estudian las propiedades de los procesos de gasificación y 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

[1] Y. Wang and C. M. Kinoshita, *Kinetic Model of Biomass Gasification*, Journal Solar Energy, Vol. 51, No.1, pp. 19-25, USA, 1993.

- [2] T. B. Reed, B. Levie and M. S Graboski, *Fundamentals, development and scaleup of the air-oxygen stratified downdraft gasifier*, SERI, PNL-6600 (1988).
- [3] T. B. Reed, *Biomass Gasification principle and technology*, Noyes Data Corporation, New Jersey, 1981.
- [4] A. Y. Alanis, *Discrete-time Neural Control: Application to Induction Motors*, Tesis de Doctorado, CINVESTAV, Unidad Guadalajara, 2007.
- [5] E. N. Sanchez and A. Y. Alanis, *Redes Neuronales, conceptos fundamentales y aplicación a control automático*, Pearson Education, Madrid, España, 2006.
- [6] E.N. Sanchez, A.Y. Alanis and G. Chen, "Recurrent neural networks trained with Kalman filtering for discrete chaos reconstruction", *Workshop on Chaos Control and Synchronization '04*, Melbourne, Australia, July, 2004.
- [7] L. J. Ricalde and E. N. Sanchez, "Inverse optimal nonlinear high order recurrent neural observer", *International Joint Conference on Neural Networks, IJCNN 05*, Montreal, Canada, August, 2005.
- [8] G. A. Rovithakis and M. A. Christodoulou, *Adaptive Control with Recurrent High-Order Neural Network*, Springer-Verlag, New York, USA, 2000.
- [9] E. N. Sanchez, A. Y. Alanis, and A. G. Loukianov, *Discrete-Time Recurrent High Order Neural Observer for Induction Motors*, in "Foundations of Fuzzy Logic and Soft computing" Eds. P. Melin et al., Springer-Verlag, Berlin Heidelberg, Germany, 2007.
- [10] Y. Song and J. W. Grizzle, *The extended Kalman filter as a local asymptotic observer for discrete-time nonlinear systems*, Journal of Mathematical Systems, Estimation and Control, Vol. 5, No.1, pp. 59-78, Birkhauser-Boston, 1995.
- [11] A. Y. Alanis, "Neural Network Training with Kalman filter", M. Sc Thesis, CINVESTAV, Unidad Guadalajara, 2004.
- [12] T. B. Reed, B. Levie and M.S. Graboski, *Fundamentals, development and scaleup of the air-oxygen stratified downdraft gasifier*, SERI, PNL-6600, 1988.
- [13] K. J. Laidler, *Chemical kinetics*, Harper & Row Publishers, New York, 1987.
- [14] M. Laurendeau *Heterogeneous Kinetics of Coal Char Gasification and Combustion*, Journal Energy Combustion, Vol. 4, pp. 221-270, Great Britain, 1978.