



Modelado de indicadores de operación de un gasificador downdraft por redes neuronales para biomasa *Eichhornia Crassipes*

*Operational performance indicators of a downdraft gasifier through modeling by neural networks for biomass *Eichhornia Crassipes**

Eduardo Roberto Gutiérrez Gualotuña¹, Juan Carlos Almeida Mera¹, José Arzola Ruiz²

¹Universidad de las Fuerzas Armadas – ESPE. Ecuador

²Universidad Tecnológica de La Habana José Antonio Echeverría, Cujae. Cuba

E-mail: ergutierrez@espe.edu.ec

Recibido: julio de 2018

Aprobado: febrero 2019

Licencia de uso y distribución Creative Commons Reconocimiento-No Comercial 4.0 Internacional.



RESUMEN/ABSTRACT

En el trabajo se presentan resultados investigativos obtenidos por los autores en el modelado de indicadores de desempeño de la operación de instalaciones de gasificación de la biomasa con ayuda de redes neuronales artificiales, a partir de la clasificación de la información derivada del análisis sistémico de la operación de estas instalaciones. Se realiza el estudio bibliográfico de los trabajos de investigaciones previos, vinculados al modelado matemático de estas instalaciones por las diferentes técnicas reflejada en la literatura especializada. Se realiza un plan experimental 3^N con tres réplicas, a partir del cual se elaboran, utilizando las técnicas de las redes neuronales, cuatro modelos correspondientes a respectivos indicadores de desempeño, con satisfactorios resultados de su evaluación a partir de los coeficientes de regresión y errores estándar utilizando como biomasa el *Eichhornia Crassipes*. Se describe la instalación experimental y el sistema de adquisición de datos desarrollados.

Palabras clave: gasificación de biomasa; fuentes de energía renovable; redes neuronales artificiales; operación de procesos.

*The research results are presented by the authors in the modeling of performance indicators of the operation of biomass gasification facilities through the use of artificial neural networks, starting from the classification of the information derived from the systemic analysis of the operation of these facilities. A bibliographical study of previous research, related to mathematical modeling of these facilities through the different techniques specified on the literature was developed. A 3^N experimental plan with 3 replicas is made to generate four models according to their own performance indicators using neural networks, with satisfactory results of their evaluation and based on regression coefficients and standard errors using *Eichhornia Crassipes* as biomass. The experimental installation and the developed data acquisition systems are described.*

Keywords: Biomass gasification; renewable energy sources; artificial neural networks; processes operation.

INTRODUCCIÓN

Como consecuencia del creciente consumo de combustibles, se observa el incremento en los últimos años de los fenómenos asociados a la crisis energética y al calentamiento global. Se hace indispensable, por tanto, el desarrollo creciente de las fuentes alternativas de energía. Una de las fuentes mayoritarias está constituida por la biomasa, de la que se dispone en abundancia y tiene mucho menor impacto al medio ambiente que los combustibles fósiles [1]. La operación racional de las instalaciones de gasificación de biomasa contribuye también a la reducción de las emisiones contaminantes, costos de generación, etc. [2,3].

En general, el proceso de gasificación depende de varios factores, entre los que se destacan la temperatura de pirólisis, parámetro que determina el rompimiento de la molécula de la biomasa experimental gracias a la reacción de reducción que se produce por la cantidad de calor existente en el reactor, además de la presión en el mismo.

En el caso de estudio de los gasificadores tipo downdraft, la calidad del gas que produce la instalación depende no solo de las características del flujo de gas, del agente gasificante utilizado, del tipo de biomasa y del diseño del reactor, sino también de los parámetros de operación [1-4]. El análisis real del proceso de gasificación, por su complejidad y diversidad en procesos que ocurren en tiempos pequeños, tiene muchas dificultades. Es por esto que los modelos matemáticos tienen vital importancia en la predicción del comportamiento operacional del equipo, ya que provee sistemas de relaciones matemáticas que permiten predecir el comportamiento de la instalación energética [5,6].

En el estudio bibliográfico realizado se encontraron numerosos trabajos sobre diferentes tipos de modelos del proceso, algunos de ellos se refieren a los modelos de equilibrio termodinámico que se utilizan para predecir la composición del gas de síntesis al suponer una mezcla de reactivos en un tiempo infinito [7,8]. El problema del empleo de este método es la introducción de errores, ya que no se toman en cuenta todas las reacciones existentes en el proceso [9,10]. En cambio, al emplear un modelo no estequiométrico se puede minimizar la energía libre de Gibbs [2, 9,11], sin tomar en cuenta la presencia de las diferentes reacciones, por lo que este método es más complejo, aunque introduce también errores por lo incompleta de la descripción. Estos tipos de modelos se enfocan en particular al proceso de gasificación y dan preferencia a los parámetros termodinámicos sin referencia directa a los parámetros de operación de la instalación en sí, para un análisis de los componentes existentes en el producto final de la gasificación, es decir, el gas de síntesis, por lo que los errores de apreciación del desempeño siguen siendo considerables. Otro tipo de modelo importante es el cinético. Al igual que el modelo anterior se enfoca en realizar un análisis del gas de síntesis producto del proceso y predecir su rendimiento en función de su composición en un volumen de control en un tiempo dado [11, 12]. Con este modelo se predicen los perfiles tanto de composición del gas de síntesis como los de temperatura dentro del reactor en condiciones de operación dadas. Aquí se considera la cinética de las diferentes reacciones y también las condiciones de movimiento del proceso dentro del reactor, es decir: su hidrodinámica, balances de masa y la energía requerida enfocada hacia el conocimiento del rendimiento del gas. En este punto se cumple un aspecto importante en referencia al tiempo de residencia de la biomasa en el reactor.

Al igual que el método de equilibrio termodinámico, este método se enfoca de manera muy especial a la caracterización del gas y sus componentes, dando especial cuidado a la mezcla y su rendimiento. Este es muy sensible a la reacción dada en dos fases (sólido-gas) dentro del reactor, por lo que, a pesar de ser estos modelos más precisos y detallar el proceso de gasificación, tienen la desventaja de ser computacionalmente muy intensivos [13,14]. Los modelos basados en la dinámica de fluidos computacional (CFD) permiten realizar una simulación rápida y eficaz del flujo de fluidos y los procesos de transferencia de calor y masa dentro del reactor, con lo que se pueden calcular las fuerzas que actúan en el fluido y ayuda a comprender el impacto del gas en el rendimiento de la instalación de gasificación. Se basan en la solución de ecuaciones simultáneas obtenidas de los balances de energía, masa y momento en cualquier zona del reactor downdraft, para predecir y formular perfiles de temperatura. Estos modelos se han utilizado para caracterizar el comportamiento de varios tipos de gasificadores de biomasa al tomar en cuenta que la composición de la biomasa es compleja y depende de la materia prima, tiempo a la intemperie, ubicación geográfica y época del año [15, 16]. Dados los considerables errores que aportan los modelos de origen químico-físico del proceso de gasificación, se requiere de la realización de experimentos que permitan elaborar modelos que predigan con errores admisibles la operación de los procesos. Sin embargo, el estudio del estado del arte muestra pocas publicaciones dedicadas al modelado por medio de técnicas de regresión a partir de un diseño experimental adecuado a la tarea que se quiere resolver, entre ellos se encuentra Vladimir Kirsanov et al (2017) [17]. En este trabajo el autor realiza una investigación experimental del proceso de gasificación en una planta real de 400 kW con el fin de caracterizar indicadores de eficiencia de la operación. Se hallan cuatro modelos para definir el poder calorífico del gas de síntesis, la capacidad del gasificador y la eficiencia en frío y en caliente del gas. No obstante, carece de un análisis sistémico previo que permita definir el conjunto de relaciones que se requiere modelar con el fin de operar racionalmente el proceso y se limita a modelos lineales. En [12], aparece uno de los primeros trabajos dedicado al modelado de los parámetros de funcionamiento enfocado al diseño.

En el trabajo de Tigabwa Y. et al (2012) [18], se da prioridad a la generación de hidrógeno como producto del proceso de gasificación y se hace una revisión de los modelos utilizados, entre ellos las redes neuronales. Las mismas que se usan para mejorar la precisión de predicción de la composición del gas producto de gasificación [13]. Sin embargo, el modelado por redes neuronales requiere datos experimentales a partir de un plan experimental. Estos datos son obtenidos de los procesos de gasificación de biomasa y no se reflejan en la publicación.

Arnavat MP (2013) [19], publica un trabajo sobre modelado con redes neuronales del proceso de gasificación de biomasa en gasificadores tipo downdraft. Los modelos basados en ANN se formularon para predecir la composición del gas del producto en términos de concentración de cuatro componentes principales del gas de síntesis: CH_4 , CO , CO_2 y H_2 y no se sustenta en estudio sistémico alguno en las relaciones a identificar. Se puede observar que los trabajos expuestos carecen de un enfoque sistémico orientado bien al diseño o bien a la operación y se limitan principalmente a estimar la composición química del gas resultante en el proceso de gasificación. En el estudio del comportamiento de los procesos termoquímicos que ocurren en el reactor durante el proceso de gasificación, con el propósito de evaluar cómo influyen los diferentes parámetros operativos en las variables de salida, en algunas investigaciones se hace uso de las redes neuronales artificiales (ANN). [12, 18, 19]. Los modelos matemáticos se elaboran, como regla, como herramientas para la toma de decisiones, por lo que su estructura depende de un análisis sistémico previo de las tareas asociados [20].

El modelado se realiza, en este trabajo, con ayuda de redes neuronales (ANN) [21], a partir de un análisis sistémico aplicado a este tipo de instalaciones, que permita definir el conjunto de relaciones requeridas para modelar su operación en tiempo real, para la gasificación de diferentes biomásas, siendo descritos los modelos obtenidos correspondientes a la biomasa *Eichhornia crassipes* (más conocida como lechuguín) en una instalación experimental construida con el objetivo de generar los datos experimentales requeridos para identificar las relaciones requeridas por el análisis. Los modelos obtenidos por redes neuronales se comparan con los obtenidos por modelos no lineales de regresión. Se debe notar, no obstante, que una vez en funcionamiento el sistema, se hará posible obtener información estadística del experimento pasivo resultante de su operación normal, lo que ha de permitir perfeccionar las relaciones que intervienen con mucha mayor precisión, dado el volumen de datos que se habrían de acumular, suficiente para la obtención de modelos mucho más precisos.

MATERIALES Y MÉTODOS

La instalación experimental está constituida por un gasificador tipo downdraft con una capacidad de 10 kW el cual se conecta a un motor de combustión interna de 0.8 kW de potencia nominal como carga. Como resultado del análisis sistémico realizado en correspondencia con la metodología de análisis y síntesis de sistema de ingeniería expuesta en [20], se obtuvo la siguiente composición de variables para la tarea de operación de la instalación de gasificación downdraft.

Variables de coordinación:

Potencia demandada (o deseada) u^d

Humedad de la biomasa Hu

Poder calórico inferior requerido del gas generado PCG^{inf}

Variables de decisión:

Cantidad de biomasa del tipo j $Cbio_j$ y caudal de aire de combustión Cau .

Variables dependientes:

Eficiencia de la instalación Ef , Temperatura de la zona pilórica Tzp , poder calórico del gas PCG , caudal másico de gas generado MG .

Modelo matemático conceptual para la operación del proceso: Vea la ecuación (1).

$$\text{Minimizar: } \max \left[\frac{|Ef - Ef^d|}{Ef^d}, \frac{|u - u^d|}{u^d} \right] \quad (1)$$

asegurando: Vea las ecuaciones (2,3,4,5)

$$u = MB(Cau, Hu, Cbio) \cdot PCG(Cbio_j, Cau, Hu) \quad (2)$$

$$Cbio_j \leq Cbio_j^{sup}; j = 1, \dots, jt \quad (3)$$

$$Tzp(C_j, Apv, Hu, PC) \geq Tzp^{inf} \quad (4)$$

$$PCG \geq PCG^{inf} \quad (5)$$

Relaciones que requieren ser identificadas, según análisis externo: Vea las ecuaciones (6, 7, 8,9):

$$Ef = Ef(Hu, Cbio, Cau) \quad (6)$$

$$Tzp = Tzp(Hu, Cbio, Cau) \quad (7)$$

$$MG = MG(Hu, Cbio, Cau) \quad (8)$$

$$PCG = PCG(Hu, Cbio, Cau) \quad (9)$$

Una vez identificadas las relaciones, el modelo (1) – (5), pasa a ser un modelo de programación estocástica, dado el origen experimental de las relaciones componentes, relativamente sencillo.

Con el fin de identificar las relaciones derivadas del análisis externo, se concibió un plan experimental con una estructura 3^N (alto, medio y bajo, por variables) con tres réplicas, que permitan reflejar los errores casuales, incluyendo los errores de medición, para biomazas con bajo, medio y alto poder calórico. Para bajo poder calórico fue seleccionado el *EichhorniaCrassipes*, objeto de identificación en el presente artículo. Fueron también identificadas las relaciones correspondientes a otras biomazas, pero su exposición se escapa del alcance del presente artículo. Se seleccionaron los niveles, para las variables de coordinación y de decisión, de: 12 %, 16 %, 20 % (para *Hu*); 1 kg, 3 kg, 5 kg (para *Cbio*); 0.0001666 kg/s, 0.0002098 kg/s, 0.0002531 kg/s (para *Cau*). Los datos obtenidos se muestran en la tabla 1. Para la recopilación automatizada de la información experimental, se utilizó una tarjeta de adquisición de datos myRIO y la interface máquina hombre con un programa desarrollado en LabView. En la tabla 2, se muestran los resultados experimentales obtenidos.

La instrumentación utilizada consta de una alarma digital de detección de *CO* marca Kidde con un intervalo de medición de 30-999 PPM con error $\pm 30\%$ de la magnitud medida en condiciones normales, un medidor de humedad MD914 con un intervalo de medición de 2 a 60%, una resolución de 0.5%, un sensor de nivel de combustible controlado mediante una paleta para sensar el nivel de biomasa, 8 termocuplas tipo k, con intervalo de medición de 0 a 1250°C de temperatura con un límite de error $\pm 2.2\%$ °C de chromel - alumel y un cable de compensación KX, ubicadas de la siguiente forma: cuatro para las zonas de reducción, pirólisis, combustión y secado, una en la descarga de cenizas, y tres para sensar las temperaturas del gas a la entrada del ciclón, a la entrada del intercambiador de calor y a la salida del intercambiador de calor, así como de dos manómetros de agua tipo U con intervalo de medición de 200 mm de *H₂O*, con error de medición de ± 1 mm de *H₂O*. Uno de ellos toma la diferencia de presión existente en el reactor y el otro en la placa orificio para medición del caudal másico de aire que ingresa en las diferentes aperturas de válvula. La disposición de toda la instrumentación se ilustra en la figura 1.

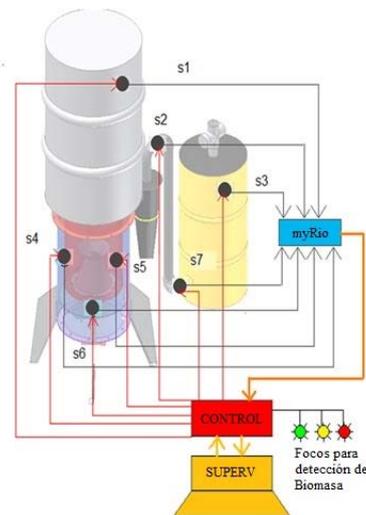


Fig.1. Puntos de control del gasificador tipo downdraft.

Los experimentos se realizaron por lotes en el siguiente orden: activación de la instalación, carga de la biomasa, apertura de la válvula de aire, captura del gas resultante y envío a laboratorio contratado a una empresa particular para la medición de composición y masa de los gases y cálculo de su poder calórico por los autores. La medición de temperatura se realizaba de forma permanente en los puntos indicados en la figura 1, y se promediaba la temperatura en la zona pilórica para todo el lote.

RESULTADOS

Los datos experimentales de partida para el modelado matemático, según plan experimental se muestran en la tabla 1. Se elaboraron variantes de redes neuronales con la inclusión de todas las salidas en un mismo modelo, obteniéndose muy baja calidad en las redes obtenidas, dada la muy baja correlación entre los indicadores y la poca cantidad de datos experimentales para el entrenamiento de la red. Se evidenció, de tal forma, la necesidad del procesamiento individual de los indicadores de desempeño de la operación del proceso.

Para el entrenamiento, los datos se seleccionaron aleatoriamente en cada corrida. Se adoptó el 30% para la validación y el 70% para el entrenamiento de la red neuronal. Como resultado, se estructuraron redes con 1 y 2 capas ocultas. En todos los casos resultó más efectiva la estructura de dos capas ocultas, con funciones de transferencia tangente sigmoideal.

Tabla 1. Resultados experimentales

MG Kg/hora	Ef %	Tzp °C	PCG KJ/Kg	Hu %	Cau Kg/s	Cbio Kg
2.16	29.7	163.4	19.76	20	0.00024453	5
2.16	28.9	155.23	19.24	20	0.00024012	3
2.16	30.8	147.47	18.7	20	0.00023563	1
2.16	30.7	170.51	20.43	16	0.00024886	5
2.16	28.7	170.76	19.11	16	0.0002573	3
2.16	25.5	162.22	18.63	16	0.00025311	1
2.16	35.1	183.34	23.36	12	0.00025311	5
2.16	33.7	174.17	22.38	12	0.00024012	3
2.16	32.3	165.46	21.47	12	0.00024886	1
1.14	29.9	161.34	19.35	20	0.00020666	5
1.14	27.1	163.11	17.58	20	0.00020143	3
1.14	28.4	156.63	18.38	20	0.00021177	1
1.14	30.8	171.02	19.97	16	0.00021675	5
1.14	29	162.47	18.79	16	0.00019606	3
1.14	28.8	154.34	18.64	16	0.00020666	1
1.14	32.5	186.41	21.03	12	0.00021177	5
1.14	32.1	177.09	20.79	12	0.00022162	3
1.14	28.3	168.24	18.34	12	0.00022639	1
0.58	29.2	158.45	18.65	20	0.00017291	5
0.58	29	150.53	18.56	20	0.00017898	3
0.58	25.4	143	16.21	20	0.00017291	1
0.58	31.3	175.88	19.99	16	0.00018485	5
0.58	29.2	167.08	18.67	16	0.00019054	3
0.58	29.5	158.73	16.479	16	0.00019054	1
0.58	34.8	189.95	22.27	12	0.00017291	5
0.58	31.7	180.45	20.29	12	0.00017898	3
0.58	27	171.43	17.23	12	0.00017898	1
2.16	31.8	166.87	21.18	20	0.00024886	5
2.16	31.4	161.60	20.9	20	0.00024012	3
2.16	30.4	163.69	20.2	20	0.00023563	1
2.16	33.6	170.52	22.36	16	0.00024886	5
2.16	31.1	164.749	20.69	16	0.00025311	3
2.16	27.8	158.00	18.51	16	0.00025311	1
2.16	38.8	175.56	23.52	12	0.00025311	5
2.16	37.3	169.00	22.39	12	0.00024012	3
2.16	31	161.76	20.61	12	0.00024886	1
1.14	26.9	169.52	19.20	20	0.00021177	5
1.14	26	170.13	18.56	20	0.00020666	3
1.14	26.3	161.62	17.02	20	0.00021675	1
1.14	30.8	177.12	19.93	16	0.00021177	5
1.14	31.4	169.79	20.33	16	0.00019054	3
1.14	27.9	171.32	18.06	16	0.00020143	1

Continuación: Tabla 1. Resultados Experimentales						
1.14	35	187.60	22.67	12	0.00021177	5
1.14	31.5	178.90	20.4	12	0.00022162	3
1.14	30.9	170.54	20.02	12	0.00022639	1
0.58	28	166.26	17.92	20	0.00017291	5
0.58	28.5	157.84	18.23	20	0.00018485	3
0.58	25.6	158.73	16.38	20	0.00017898	1
0.58	27.3	178.14	19.03	16	0.00019054	5
0.58	25.4	168.26	18.18	16	0.00019054	3
0.58	25.4	159.84	16.23	16	0.00018485	1
0.58	36.1	194.58	21.36	12	0.00016662	5
0.58	34.2	182.51	20.23	12	0.00017291	3
0.58	25.9	172.17	16.52	12	0.00017291	1
2.16	31.3	166.87	20.82	20	0.00024886	5
2.16	27.8	161.60	20.00	20	0.00023563	3
2.16	26.1	155.18	17.33	20	0.00023106	1
2.16	31.6	168.60	21.03	16	0.00024453	5
2.16	30.6	160.17	20.34	16	0.0002573	3
2.16	29.8	152.16	19.8	16	0.0002573	1
2.16	32.1	171.97	23.52	12	0.0002573	5
2.16	29.4	163.37	22.39	12	0.00024453	3
2.16	30.1	155.2	20.05	12	0.00025311	1
1.14	32.4	169.52	19.20	20	0.00020666	5
1.14	24.8	163.11	18.56	20	0.00020143	3
1.14	27.1	156.63	17.55	20	0.00021177	1
1.14	33.3	177.12	19.75	16	0.00021177	5
1.14	27	169.79	17.47	16	0.00018485	3
1.14	24.7	162.56	15.97	16	0.00020143	1
1.14	35.9	187.61	23.28	12	0.00021177	5
1.14	33.1	178.90	21.4	12	0.00021675	3
1.14	25.9	170.54	18.68	12	0.00022162	1
0.58	29.1	166.27	18.58	20	0.00016662	5
0.58	32.2	157.84	17.84	20	0.00019054	3
0.58	24.5	150.72	15.63	20	0.00018485	1
0.58	30.8	178.14	19.66	16	0.00019606	5
0.58	29	168.26	18.56	16	0.00019606	3
0.58	25.7	159.84	16.42	16	0.00018485	1
0.58	31.9	194.58	20.41	12	0.00017291	5

Para las dos capas ocultas la cantidad de nodos se estableció por prueba y error, según el plan experimental señalado, para modelar las variables de salida $y = (Ef, Tzp, MG \text{ y } PCG)$, con el objetivo del máximo valor del coeficiente de regresión R . En la figura 2, se muestra gráficamente la estructura de la red finalmente obtenida.

En los resultados se identifican, de tal forma, modelos con la estructura general dada por la ecuación (10):

$$y = f^3 \left(W^3 f^2 \left(W^2 f^1 \left(W^1 x + b^1 \right) + b^2 \right) + b^3 \right) \quad (10)$$

donde:

y representa la variable de salida modelada,

x el vector de entrada,

W^i, f^i, b^i la matriz de coeficientes, función de transición y vector de bias de la capa i .

En la tabla 2, se muestran los resultados intermedios obtenidos durante la búsqueda del número de nodos óptimo por capas durante la optimización de la red para el modelado de Ef .

Tabla 2. Búsqueda del número óptimo de nodos para redes ocultas en el modelado de Ef.

No. de Modelo	Capa 2	Capa 3	R Entrenamiento	R Validación
1	10	6	0.6425	0.6496
2	8	6	0.7124	0.6548
3	6	6	0.7325	0.6746
4	10	4	0.7625	0.7326
5	8	4	0,7555	0,7417
6	6	4	0.7432	0.7400
7	10	2	0.7401	0.7342
8	8	2	0.7345	0.7236
9	6	2	0.7326	0.7115

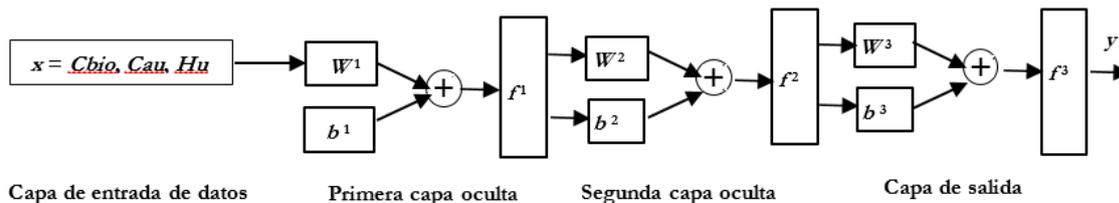


Fig. 2. Estructura de la red neuronal encontrada para todas y cada una de las salidas.

El error medio, con una probabilidad no inferior al 95%, en adelante se calcula por la ecuación (11):

$$\varepsilon = 1,64 \times S \times 100 / \bar{y} \quad (11)$$

donde: 1,64 percentil de la distribución normal, correspondiente a una probabilidad del 95 %,

\bar{y} valor medio de la variable de salida y ,

S error estándar de la ecuación.

En adelante, se muestran las matrices y vías óptimos obtenidos para el modelado de Ef , se expresan por las ecuaciones (12, 13,14 y 15), según la ecuación general (10):

$$W^1 = \begin{bmatrix} 1,375 & 2,364 & -0,281 \\ 1,344 & 1,639 & 1,886 \\ -2,349 & -1,140 & 1,361 \\ 0,786 & 2,471 & 1,394 \\ 0,402 & 2,086 & 0,772 \\ -1,561 & -0,415 & -2,121 \\ -1,878 & 1,494 & 1,808 \\ 0,611 & -1,909 & 2,625 \end{bmatrix}, \quad b^1 = \begin{bmatrix} -2,844 \\ -2,211 \\ 0,747 \\ -0,908 \\ 1,004 \\ -1,762 \\ -1,289 \\ 2,282 \end{bmatrix} \quad (12)$$

$$W^2 = \begin{bmatrix} 0,233 & 1,049 & -0,617 & 1,399 & 0,137 & -0,8677 & 0,488 & 0,364 \\ 0,965 & -0,242 & -0,926 & -0,077 & -0,4631 & -0,199 & 0,708 & -0,732 \\ 0,578 & 0,469 & -0,984 & 1,074 & 0,4584 & -0,079 & -0,448 & -0,705 \\ -0,107 & -0,966 & 0,518 & -0,245 & 0,354 & -0,491 & 0,411 & -1,132 \end{bmatrix} \quad (13)$$

$$b^2 = \begin{bmatrix} -1,453 \\ -0,905 \\ 0,368 \\ -1,121 \end{bmatrix} \quad (14)$$

$$W^3 = [0,567 - 0,108 \quad 0,550 \quad 1,319]; \quad b^3 = [-0,005] \quad (15)$$

Para los datos de la validación, la estimación del coeficiente de regresión es de $R=74,1$ y del error estándar. $S = 1,90$ %. El error medio de Ef , calculado según la ecuación (11) es $\varepsilon = 1,64 \times 1,90 \times 100/30 = 10,39$ %

La mejor ecuación de regresión no lineal obtenida, a partir de la linealización de monomiales se expresa según la ecuación (16):

$$Ef = -61.742 + 72.60Cau^{(0.204)}Hu^{(-0.212)} - 107.17Cbio^{(0.084)} + 2.18Hu + 236.99Hu^{(-0.212)}Cbio^{(0.084)} \quad (16)$$

Con los indicadores: $R=71,28$; $S=1,98$ %, para un error medio de $\varepsilon = 1,98 \times 1,64 \times 100/30 = 10,82$ %

Matrices y bias óptimos obtenidos para el modelado de Temperatura de la zona pilórica (Tzp), se expresan por las ecuaciones (17,18, 19), según la ecuación general (10):

$$W^1 = \begin{bmatrix} 1,378 & 1,993 & -0,636 \\ 0,776 & 1,448 & -2,222 \\ -1,171 & 2,260 & -0,805 \\ -2,174 & 0,050 & -1,515 \\ -1,883 & -1,367 & -1,721 \\ 0,011 & -2,742 & -0,309 \\ 2,534 & 1,641 & 0,588 \\ -0,875 & 2,505 & -0,780 \end{bmatrix}; \quad b^1 = \begin{bmatrix} -3,1624 \\ -1,8229 \\ 0,8923 \\ 0,6837 \\ -0,552 \\ 1,4216 \\ 1,6474 \\ -2,7609 \end{bmatrix} \quad (17)$$

$$W^2 = \begin{bmatrix} 0,654 & 0,837 & 0,267 & -0,539 & 0,718 & -0,170 & -0,260 & 0,676 \\ -0,186 & -0,636 & 0,161 & 0,676 & 0,747 & 1,329 & -0,324 & -0,113 \\ 0,405 & 0,343 & -0,613 & 0,704 & -0,966 & -0,370 & -0,014 & -0,668 \\ 0,672 & -0,426 & -0,676 & -0,632 & 0,029 & -0,158 & -0,194 & -1,106 \end{bmatrix}; \quad b^2 = \begin{bmatrix} -1,759 \\ -0,437 \\ 0,530 \\ 1,794 \end{bmatrix} \quad (18)$$

$$W^3 = [0,306 - 0,812 - 0,408]; \quad b^3 = [0,394] \quad (19)$$

En la validación de los datos de la red, el coeficiente de regresión obtenido es de $R=87,73$ y el error estándar calculado de los datos validados es de $S=3,87$ °C, para un error medio de $\varepsilon = 3,87 \times 1,64 \times 100/178 = 3,57$ %

Para la estimación de la temperatura de la zona de pirólisis (Tzp), se obtuvo la ecuación de regresión (20):

$$Tzp = 5445.95 - 4739.92Cau^{(-0.085)} + 8107.4Cau^{(-0.085)}Hu^{(-0.193)} + 3.83Cbio - 9055.84Hu^{(-0.193)} \quad (20)$$

Con los indicadores $R=83,40$; $S=4,34$ °C, para un error medio de $\varepsilon = 4,34 \times 1,64 \times 100/178 = 4$ %

Matrices y bias óptimos obtenidos para el modelo del poder calórico del gas (PCG) se expresan por las ecuaciones (21,22, 23), según la ecuación general (10).

$$W^1 = \begin{bmatrix} -2,565 & 0,099 & 0,934 \\ 0,490 & -2,494 & -1,276 \\ 1,696 & -2,261 & -0,541 \\ -1,336 & 1,020 & 2,144 \\ -1,927 & -2,020 & 0,287 \\ -0,885 & 2,430 & -0,056 \\ -1,024 & 1,602 & -2,382 \\ -2,634 & 0,423 & -0,669 \end{bmatrix}; \quad b^1 = \begin{bmatrix} 2,873 \\ -1,811 \\ -1,042 \\ 0,510 \\ -0,306 \\ -1,301 \\ -1,809 \\ -2,920 \end{bmatrix} \quad (21)$$

$$W^2 = \begin{bmatrix} 0,172 & 0,682 & 0,776 & 0,546 & 0,031 & 0,906 & -0,893 & -0,080 \\ 0,066 & -0,837 & -0,766 & -0,238 & 0,292 & 0,424 & -0,698 & 0,999 \\ -0,332 & 0,978 & -0,556 & 0,448 & 0,605 & -0,342 & 0,814 & 0,295 \\ -0,213 & 1,114 & -0,260 & -1,025 & 0,619 & 0,482 & -0,068 & 0,081 \end{bmatrix}; \quad b^2 = \begin{bmatrix} -1,570 \\ -0,800 \\ -0,622 \\ -1,687 \end{bmatrix} \quad (22)$$

$$W^3 = [0,912 \quad 0,407 \quad 0,102 \quad -0,813]; \quad b^3 = [0,005] \quad (23)$$

En la validación de los datos, el coeficiente de regresión obtenido es de $R=84,54$ y el error estándar calculado de los datos validados es de $S= 0,75\text{KJ/Kg}$, para un error medio de $\varepsilon = 0,75 \times 1,64 \times 100 / 19,1 = 6,44 \%$
Para la estimación del poder calórico de los gases de salida (PCG), se obtuvo la ecuación de regresión (24):

$$PCG = -38.73 + 60.34Cau^{(0.349)}Hu^{(-0.209)} - 65.36Cbio^{(0.087)} + 1.33Hu + 144.64Hu^{(-0.209)}Cbio^{(0.087)} \quad (24)$$

Con los indicadores $R = 0,86$ y $S = 0.68\text{KJ/Kg}$, para un error medio de $\varepsilon = 0,68 \times 1,64 \times 100 / 19,1 = 5,84 \%$

Matrices y bias óptimos obtenidos para el flujo másico del gas (MG), se expresan por las ecuaciones (25, 26, 27), según la ecuación general (10):

$$W^1 = \begin{bmatrix} -1,520 & 1,563 & 1,900 \\ 1,646 & -2,437 & 0,566 \\ 0,604 & 1,299 & -2,152 \\ 0,215 & 0,123 & -2,843 \\ 3,067 & 0,792 & 0,546 \\ 2,545 & -0,424 & -0,623 \\ -1,197 & -1,040 & -2,547 \\ -1,685 & 0,444 & 2,355 \end{bmatrix}; \quad b^1 = \begin{bmatrix} 2,765 \\ -1,553 \\ -1,980 \\ 1,286 \\ -0,015 \\ 1,764 \\ -2,507 \\ -3,164 \end{bmatrix} \quad (25)$$

$$W^2 = \begin{bmatrix} -0,702 & 0,773 & -0,032 & -0,319 & 1,099 & 0,703 & 0,642 & 0,438 \\ 0,700 & 0,070 & -0,676 & -0,745 & -0,672 & -0,075 & 0,201 & 0,305 \\ 0,527 & 0,079 & -0,178 & -0,024 & 0,800 & 0,115 & -0,692 & 1,364 \\ -0,363 & 0,988 & -0,0767 & -0,7205 & 0,6888 & -0,6611 & 0,127 & -1,144 \end{bmatrix}; \quad b^2 = \begin{bmatrix} 1,378 \\ 1,031 \\ 0,565 \\ -1,734 \end{bmatrix} \quad (26)$$

$$W^3 = [0,190 \quad 1,575 \quad 1,673 \quad 1,058]; \quad b^3 = [-0.329] \quad (27)$$

En la validación de los datos de la red, el coeficiente de regresión obtenido es de $R=96,83$ y el error estándar calculado de los datos validados es de $S = 0,11\text{Kg/hora}$, para un error medio de $\varepsilon = 0,11 \times 1,64 \times 100 / 1,67 = 10,82 \%$.

Para la estimación del flujo másico (MG), se obtuvo la ecuación de regresión (28):

$$MG = 5.06733 - 1454.41Cau^{(3.5929)}Cbio^{(0.0075)} + 1366.2Cau^{(3.5929)}Hu^{(0.0962)}Cbio^{(0.0075)} - 3.87865Hu^{(0.0962)}Cbio^{(0.0075)} \quad (28)$$

Con los indicadores $R = 0,92$ y $S = 0.18\text{Kg/hora}$, para un error medio de $\varepsilon = 0,18 \times 1,64 \times 100 / 1,67 = 17,68 \%$

Los resultados obtenidos muestran la posibilidad de utilización de las RNA en la identificación de los indicadores de operación de las instalaciones de gasificación tipo downdraft. Las RNA obtenidas, para la identificación de todas y cada una de las relaciones requeridas para la operación del proceso de gasificación de la biomasa *EichhorniaCrassipes* en la instalación experimental, tienen la misma estructura, tanto por la cantidad de nodos por capas como por las funciones de transferencia de los nodos por capas ocultas. No se logra en una única red identificar todos los indicadores requeridos dada la ausencia de suficiente correlación entre ellos y la pequeña cantidad de datos de partida (81 ensayos).

El modelado por redes neuronales arroja errores desde el 3,57 al 10,84 % con respecto a las magnitudes medias de cada salida, mientras que la regresión no lineal lo hace desde el 4 hasta el 17 %, con una probabilidad no inferior al 95 %.

Experimentos más intensivos aportarían sin dudas mejores indicadores, por lo que los indicadores estadísticos obtenidos tienen suficiente precisión para la implementación de estas redes tan solo como un modelo inicial de operación, el que, en condiciones de instalaciones en explotación, debe ser rectificado periódicamente a partir del experimento pasivo derivado de ella.

CONCLUSIONES

El trabajo realizado permite extraer las siguientes conclusiones principales:

La composición de modelos a ser identificados depende del adecuado análisis del sistema estudiado. En el caso concreto de la operación de las instalaciones de gasificación tipo downdraft se requieren identificar, al menos, la eficiencia de la instalación (E_f), la temperatura de la zona pilórica (T_{zp}), el poder calórico del gas de síntesis (PCG), el caudal másico del gas (MG) como función de la humedad (Hu), cantidad de biomasa (C_{bio}) y caudal de aire de combustión (Cau).

En ausencia de modelos que satisfagan las necesidades del análisis sistémico se requiere realizar planes experimentales con suficiente número de ensayos para lograr su identificación mediante los métodos de procesamiento de datos de efectividad comprobada, entre los que se encuentran las redes neuronales artificiales.

Los modelos obtenidos para la biomasa *Eichhornia Crassipes* brindan resultados ligeramente mejores que los logrados por los autores utilizando modelos de regresión a partir de monomiales linealizados, con excepción de PCG , lo que no significa que no puedan ser mejorados con ayuda de otros modelos no lineales.

Las redes neuronales elaboradas para una instalación con vistas a su operación pueden ser utilizadas tan solo como modelos iniciales para la operación del proceso de gasificación. Los definitivos deben ser obtenidos a partir del experimento pasivo resultante de su operación normal, con el fin de adaptar periódicamente los modelos para cada relación que forma parte del modelo general de operación.

La aplicación de estas redes al caso concreto de la operación del gasificador tipo downdraft desarrollado en la investigación experimental, para la biomasa *EichhorniaCrassipes*, se obtienen redes individuales por cada indicador de desempeño de la operación con 2 capas ocultas, 8 nodos en la primera y 4 en la segunda y funciones de transferencias tipo tangente sigmoidal y valores de pesos y bias por capas propios de cada indicador concreto. Es de esperar que estas redes sean de utilidad también en la identificación de otras instalaciones de gasificación, como punto de partida de la construcción de modelos de operación del proceso de gasificación.

REFERENCIAS

- [1] SHARMA AK., "Experimental investigations on a 20 kW, solid biomass gasification system". *Biomass Bioenergy* 2011; v. 35, n.1, p.421–428. [Consultado el 10 diciembre 2017]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S096195341000317X>, <https://doi.org/10.1016/j.biombioe.2010.08.050>
- [2] SHABBAR S. Janajreh I. , "Thermodynamic equilibrium analysis of coal gasification using Gibbs energy minimization method". *Energy Conversion and Management*, 2013; v. 65, p.755–763. [Consultado el 12 diciembre 2017]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0196890412001501>, <https://doi.org/10.1016/j.enconman.2012.02.032>
- [3] BARMAN NS, *et al.*, "Gasification of biomass in a fixed bed downdraft gasifier: a realistic model including tar". *Bioresour Technol* 2013; v. 107; p.505–511. [Consultado el 18 diciembre 2017]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0960852411019055>, <https://doi.org/10.1016/j.biortech.2011.12.124>
- [4] AZZONE E, Morini M, Pinelli M., "Development of an equilibrium model for the simulation of thermochemical gasification and application to agricultural residues". *Renewable Energy* 2013; v. 46, p.248–254. [Consultado el 18 diciembre 2017]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0960148112002042>, <https://doi.org/10.1016/j.renene.2012.03.017>
- [5] HANNULA I, Kurkela E., "A parametric modeling study for pressurised steam/O₂-blown fluidised-bed gasification of wood with catalytic reforming". *Biomass Bioenergy*. March 2012; v. 38, p.58–67. [Consultado el 20 de diciembre 2017]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0961953411001206>, <https://doi.org/10.1016/j.biombioe.2011.02.045>

- [6] XIE J, *et al.*, “Simulation on gasification of forestry residues in fluidized beds by EulerianLagrangian approach”. *BioresourTechnol* 2012; v. 121; p.36–46. [Consultado el 24 diciembre 2017]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0960852412009947>, <https://doi.org/10.1016/j.biortech.2012.06.080>
- [7] NGUYEN TDB, *et al.*, “Three stage steady state model for biomass gasification in a dual circulating fluidized bed”. *Energy Conversion and Management*. 2013, v.54 (1), p.100–112. [Consultado el 30 de diciembre 2017]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0196890411002755>, <https://doi.org/10.1016/j.enconman.2011.09.019>
- [8] SHABBAR S, Janajreh I., “Thermodynamic equilibrium analysis of coal gasification using Gibbs energy minimization method”. *EnergyConversManage*, 2013; v. 65, p.755–763. [Consultado el 18 de marzo 2018]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0196890412001501>, <https://doi.org/10.1016/j.enconman.2012.02.032>
- [9] BHATTACHARYA A, *et al.*, “Modeling of hydrogen production process from biomass using oxygen blown gasification”. *IntHydrogen Energy* 2013; v. 37, p. 18782-18790. [Consultado el 6 de enero 2018]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0360319912021982>, <https://doi.org/10.1016/j.ijhydene.2012.09.131>
- [10] PIRC A, *et al.*, “Universal model of a biomass gasifier for different syngas compositions. *J Mech*, 2012; v. 58, n.5, p. 291–299. [Consultado el 12 de enero de 2018]. Disponible en: https://www.sv-jme.eu/?ns_articles_pdf=ns_articles/files/ojs/607/submission/copyedit/607-1692-1-CE.pdf&id=2991, DOI:10.5545/sv-jme.2011.101
- [11] JANAJREH I, AlShrah M., “Numerical and experimental investigation of downdraft gasification of woodchips.” *EnergyConversManage*, 2013; v. 65, p.783–792. [Consultado el 20 de enero 2018]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0196890412001471>, <https://doi.org/10.1016/j.enconman.2012.03.009>
- [12] SREEJITH C.C., *et al.*, “Performance prediction of fluidized bed gasification of biomass using experimental data-based simulation models”. *BiomassConversBiorefinery*, 2013 v. 3, n. 4, p.283–304. [Consultado el 4 marzo de 2018]. Disponible en: <https://link.springer.com/article/10.1007/s13399-013-0083-5>, <https://doi.org/10.1007/s13399-013-0083-5>
- [13] PUIG-ARNAVAT, M, Bruno J.C., “Review and analysis of biomass gasification models”, *Renewable and Sustainable Energy Reviews*. 2010,v. 14, n.9 , p. 2841–2851. [Consultado el 22 de marzo 2018]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1364032110002108>, <https://doi.org/10.1016/j.rser.2010.07.030>
- [14] DI Blassi. “Dynamic behaviour of stratified downdraft gasifiers”. *Chemical Engineering Science*,2000; v. 55, n.15,p. 2931–2944. [Consultado el 22 de marzo 2018].Disponible en:<https://www.sciencedirect.com/science/article/pii/S000925099900562X>, [https://doi.org/10.1016/S0009-2509\(99\)00562-X](https://doi.org/10.1016/S0009-2509(99)00562-X)
- [15] CHEN W., *et al.*, “Recent progress on energy research: A bibliometric analysis” *Renewable and Sustainable Energy Reviews*, 2017,v.73, p. 1051-1060 [Consultado el 22 de marzo 2018]. Disponible en: <https://www.elsevier.com/locate/rser> , <https://doi.org/10.1016/j.rser.2017.02.041>
- [16] BARUAH D, Baruah D C “Modeling of biomass gasification: A review”, *Renewable and Sustainable Energy Reviews*, 2014,v. 39, p.806–815. [Consultado el 24 de marzo 2018]Disponible en: <https://www.sciencedirect.com/science/article/pii/S1364032114005814?via%3Dihub>,doi.org/10.1016/j.rser.2014.07.129
- [17] KIRSANOVS, Vladimirs *et al.* “Experimental investigation of downdraft gasifier at various conditions”, *Energy Procedia*, 2017, v. 128, p. 332–338. [Consultado el 8 marzo 2018]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1876610217338419>, <https://doi.org/10.1016/j.egypro.2017.08.321>
- [18] TIGABWA Y. *et al.*, “Mathematical and computational approaches for design of biomass gasification for hydrogen production: A review”, *Renewable and Sustainable Energy Reviews* 16 (2012) p.2304– 2315 [Consultado el 18 de marzo 2018] Disponible en: https://s3.amazonaws.com/academia.edu.documents/35794561/Modeling_Tigabwa.pdf?response-content-disposition=inline%3B%20filename%3DMathematical_and_computational_approache.pdf&X-Amz-Algorithm=AWS4-HMAC-SHA256&X-Amz-Credential=AKIAIWOWYYGZ2Y53UL3A%2F20190610%2Fus-east-1%2Fs3%2Faws4_request&X-Amz-Date=20190610T173119Z&X-Amz-Expires=3600&X-Amz-SignedHeaders=host&X-Amz-Signature=f134af372672b05fa1151b0561c02207f655174694ed344c43f2624abe08cbc3
- [19] ARNAVAT MP, *et al.*, “Artificial neural network models for biomass gasification in fluidized bed gasifiers”. *Biomass Bioenergy*, 2013, v. 49, p. 279–289. [Fecha de consulta 27 de enero 2018]. Disponible en: <https://www.sciencedirect.com/science/article/pii/S0961953412005107>, <https://doi.org/10.1016/j.biombioe.2012.12.012>
- [20] ARZOLA-Ruiz, J. “Análisis y Síntesis de Sistemas de ingeniería”. 2009,p.104, [Consultado el 24 de marzo de 2018], Disponible en https://www.researchgate.net/publication/255620644_Analisis_y_Sintesis_de_Sistemas_de_Ingenieria / ISBN 978-959-261-299-0.
- [21] HAGAN-Demuth-Beale de Jesús *et al.*, “Neuronal Network Desing”. 2da editions e Book, 2010, p 2-9, [Consultado el 24 de marzo del 2018], Disponible en :<http://hagan.okstate.edu/NNDesign.pdf>