

Modelos para la operación de gasificación de la leña en instalaciones *downdraft*

Modeling for the operation of the firewood gasification in *downdraft* installations

Eduardo Roberto Gutiérrez-Gualotuña^I, José Arzola-Ruiz^{II}, Juan Carlos Almeida-Mera^I

I. Universidad de las Fuerzas Armadas del Ecuador. Quito, Ecuador

II. Universidad Tecnológica de La Habana José Antonio Echeverría, Centro de Estudios de Matemática para las Ciencias Técnicas. La Habana, Cuba

Correo electrónico: jarzola@cemat-cujae.edu.cu

Este documento posee una [licencia Creative Commons Reconocimiento-No Comercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)



Recibido: 19 de junio de 2018

Aceptado: 08 de agosto de 2018

Resumen

La operación óptima de las instalaciones energéticas debe influir considerablemente en su eficiencia, por lo que el presente trabajo consistió en la definición de la estructura de modelos requeridos para la operación de gasificadores *downdraft* sobre la base de su análisis sistémico, su identificación y determinación del tipo de modelo de mejor ajuste. Para la identificación de los modelos fue construida una instalación experimental, utilizando, entre otras biomásas, la leña. A partir de un plan experimental 3^N, con tres réplicas, se identificaron los modelos necesarios con ayuda de

técnicas de redes neuronales artificiales y de regresión no lineal. Los mejores resultados se obtuvieron utilizando modelos de redes neuronales, siendo por tanto el más recomendable en la etapa preliminar del proceso de construcción adaptativa del modelo de operación del proceso estudiado.

Palabras claves: operación de procesos tecnológicos, análisis de sistemas, fuentes de energía renovable, redes neuronales artificiales, regresión no lineal.

Abstract

Optimal operation of energetic installations must considerably influence on its efficiency. By this, the objective of the present paper consists in the definition of the required models structure for the operation of *downdraft* gasifiers and its identification based on systemic analysis, its identification and the determination of the better adjustment type of model. For the models identification an experimental installation was constructed using, between other biomasses, firewood. Starting from an 3^N experimental plan, with three replicas, needed models were identified helped by artificial

neural networks and regression techniques. The best results were obtained using neural network, being therefore the most advisable in the preliminary stage of the process of the adaptive construction of operation models of the studied process.

Key words: operation of technological processes, systems analysis, renewable energy sources, artificial neural networks, non-linear regression.

Introducción

En la presente investigación el problema de la operación de instalaciones de termo-gasificación en instalaciones tipo *downdraft* se enfrenta sobre una base sistémica, Este tema, hasta el presente se ha enfrentado tan solo desde el punto de vista de la búsqueda de relaciones entre variables de supuesta influencia, careciéndose de un enfoque integral [1]. La operación de los procesos requiere de la definición de la estructura de modelos y de su identificación experimental inicial y su posterior rectificación adaptativa en el curso de la explotación de estas instalaciones. En el presente trabajo se enfrenta este problema, tomando como ejemplo una instalación construida con este fin, tomando en consideración los últimos resultados disponibles en el área de modelado del proceso de gasificación en estas instalaciones, dado el efecto económico y ambiental que se derivaría de su operación óptima.

En el estudio bibliográfico se encontraron numerosos trabajos sobre diferentes tipos de modelos del proceso que de alguna forma se relaciona con la construcción de modelos que pudieran resultar de utilidad para la el modelado de la operación de estas instalaciones. Algunos de ellos utilizan modelos de equilibrio termodinámico para predecir la composición del gas de síntesis al suponer una mezcla de reactivos en un tiempo infinito [2, 3]. 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 [4, 5]. En cambio, al emplear un modelo no estequiométrico se puede minimizar la energía libre de Gibbs [2, 4] sin tomar en cuenta la presencia de las diferentes reacciones, por lo que este método introduce también errores por lo incompleto de la descripción [6, 7].

Otro grupo importante de modelos es el cinético. Al igual que el modelo anterior se enfocan 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 [7]. 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 [7, 8], es decir: su hidrodinámica, balances de masa y la energía requerida enfocada hacia el conocimiento del rendimiento del gas. 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 [7].

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 [7, 9].

Dados los considerables errores que aportan los modelos de origen químico-físico del proceso de gasificación, algunos autores realizan el modelado sobre una base experimental, como principal recurso para el modelado adecuado con fines de operación. Los modelos que aparecen reflejados en la bibliografía se enfocan a la utilización de técnicas de regresión lineal y redes neuronales artificiales (RNA). Entre ellos se encuentra Vladimir Kirsanovs *et al.* [10], en el que se 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 calórico 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 la estructura adecuada de modelos con el fin de operar racionalmente el proceso. En el trabajo de Tigabwa Y. *et al* [11], se da prioridad a la generación de hidrogeno como producto del proceso de gasificación y se hace una revisión de los modelos utilizados, entre ellos las RNA. Las mismas que se usan para mejorar la precisión de predicción de la composición del gas producto de gasificación [12]. Sin embargo, el modelado por RNA 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 [13], publica un trabajo sobre modelado con RNA del proceso de gasificación de biomasa en gasificadores tipo *downdraft*. Los modelos basados en RNA se formularon para predecir la composición del gas del producto en términos de concentración de cuatro componentes principales del gas de síntesis: CH₄, CO, CO₂ y H₂ y no se sustenta en estudio sistémico alguno en las relaciones a identificar.

Los grupos anteriormente descritos de modelos, incluyendo los construidos sobre una base experimental, se enfocan en el 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 no se enfocan directamente al desempeño del proceso, carecen de un enfoque sistémico que los sustente, orientado bien al diseño o bien a la operación y se limitan principalmente a estimar la composición química del gas resultante del proceso de gasificación.

Los modelos matemáticos que en adelante se elaboran, parten de un análisis sistémico para la definición de las variables que intervienen y su relación mutua. Se realiza un plan experimental y se elaboran las relaciones requeridas para la operación del proceso, en correspondencia con el enfoque propuesto en [14] para el desarrollo de sistemas de ingeniería en general, y de operación de procesos, en particular.

Métodos y Materiales

La instalación experimental está constituida por un gasificador tipo *downdraft* con una capacidad de 10 kW el que 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 [14], se obtiene 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 y 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 .

Indicadores de eficiencia: Eficiencia de la instalación Ef , temperatura de la zona pilórica Tzp , poder calórico del gas PCG y caudal másico de gas generado MG .

Como salidas del análisis externo se obtienen el modelo matemático conceptual de operación, del que se derivan las siguientes relaciones que deben ser identificadas, las que están dadas por las ecuaciones (1) a (4):

$$Ef = Ef (Hu, Cbio, Cau) \quad (1)$$

$$Tzp = Tzp (Hu, Cbio, Cau) \quad (2)$$

$$MG = MG (Hu, Cbio, Cau) \quad (3)$$

$$PCG = PCG (Hu, Cbio, Cau) \quad (4)$$

Con el fin de identificar estas relaciones, se concibió un plan experimental con una estructura 3^N (alto, medio y bajo, por variables independientes) con tres réplicas, que permitan reflejar los errores casuales, incluyendo los de medición, para biomasa con bajo, medio y alto poder calórico. Para alto poder calórico fue seleccionada la leña, objeto de identificación en el presente artículo. Se seleccionaron los niveles, para las variables independientes, 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 . Para la recopilación automatizada de la información experimental, se utilizó en la instalación una tarjeta de adquisición de datos myRIO y la interface maquina hombre con un programa desarrollado en LabView. 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 ± 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 censar el nivel de biomasa, 8 termopares tipo k, con intervalo de medición de 0 a 1250 °C de temperatura con un límite de error ± 2.2 % °C de chromel - alumel y un cable de compensación KX, ubicadas de la siguiente forma: cuatro para las zonas de reducción, pirolisis, combustión y secado, una en la descarga de cenizas, y tres para censar 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 H_2O , con error de medición de ± 1 mm de H_2O . 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.

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 al laboratorio para la medición de composición y masa de los gases y cálculo de su poder calórico. La medición de la temperatura se realizó de forma permanente en los puntos indicados en la figura 1 y se promedió la temperatura en la zona pilórica para todo el lote.

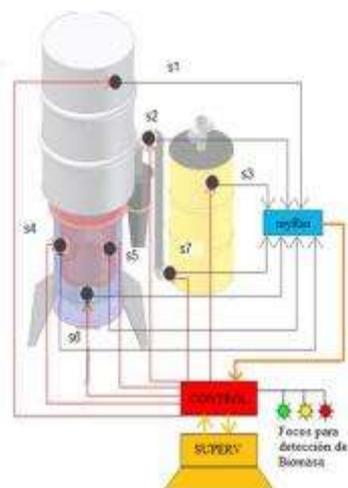


Fig. 1. Puntos de control del gasificador tipo *downdraft*

La identificación de los modelos 1 a 4 se realiza, en adelante, con ayuda de RNAy de ecuaciones de regresión no lineal. Los modelos obtenidos por RNA se comparan con los obtenidos por modelos no lineales de regresión mediante la linealización de monomiales, generación de términos con posible influencia sobre las variables de salida y eliminación entre ellos de los no significativos, según se estudia en [14]. Se debe, no obstante, notar 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 habría de acumular, suficiente para la obtención de modelos mucho más precisos.

Para crear las RNA se utiliza una herramienta programada en MATLAB [15], la que permite crear y manipular objetos en base a RNA, con número variable de capas ocultas y de nodos por capa, función de activación para los nodos de las capas ocultas, y optimización de los valores de los pesos entre nodos y de los valores de las bias por capas. El software realiza, además, toda la gestión de información de entrada – salida de forma de poder variar operativamente la configuración de la red visualizado el comportamiento de los indicadores R y error estándar óptimos de la configuración para los datos seleccionados para entrenar la red y para validarla.

Se elaboraron variantes de RNA con la inclusión de todas las salidas en un mismo modelo, pero dada la muy baja correlación entre los indicadores de eficiencia y la poca cantidad de datos experimentales para el

entrenamiento de la red, se evidenció la necesidad del procesamiento individual de los indicadores de desempeño de la operación del proceso.

Resultados y Discusión

Para el entrenamiento de las redes 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 la estructura de dos capas ocultas, con funciones de transferencia no lineales, adicionalmente a las capas de entrada y salidas de datos, resultó ser la más efectiva. Para las dos capas ocultas la cantidad de nodos requeridos y de las funciones de transferencia se establecieron mediante prueba y error, en correspondencia con el plan experimental señalado, para modelar las variables de salida $y = (Ef, Tzp, MG \text{ y } PCG)$, utilizando como objetivo el máximo valor del coeficiente de regresión R. En la figura 2 se muestra gráficamente la estructura de la red finalmente obtenida.

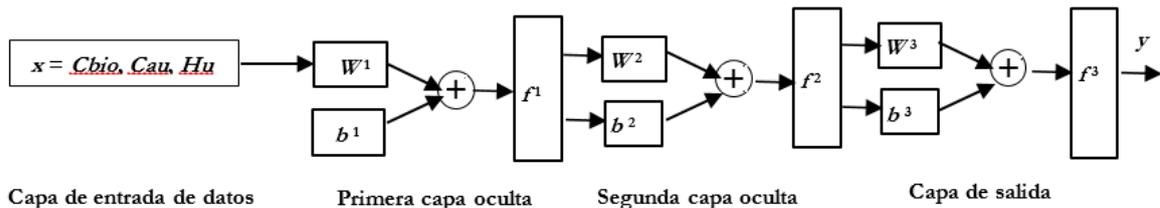


Fig. 2. Estructura de la red neuronal encontrada para todas y cada una de las salidas

En los resultados se identifican, de tal forma, modelos con la estructura general dada, por la ecuación 5:

$$y = f_3 (W^3 f_2 (W_2 f_1 (W_1 x + b_1) + b_2) + b_3) \tag{5}$$

donde y representa la variable de salida modelada, x el vector de entrada, W_i , f_i , b_i , n_i la matriz de coeficientes, función de transición, vector de bias y salidas de la capa i , respectivamente.

Los mejores resultados se obtuvieron, para los cuatro modelos buscados, ocho nodos en la primera capa oculta y cuatro en la segunda oculta. En la tabla 1 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 1. 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	0,6721	0,6271
2	8	6	0,6800	0,6048
3	6	6	0,7925	0,7746
4	10	4	0,8025	0,8026
5	8	4	0,8236	0,8333
6	6	4	0,7632	0,7133
7	10	2	0,7228	0,6448
8	8	2	0,7044	0,7035
9	6	2	0,6723	0,6730

La función de transferencia más adecuada en las capas ocultas 1 y 2, para los cuatro modelos, resultó ser la función tangente sigmoideal. Esta función entrega una salida que se encuentra en el rango de (-1,0 a 1,0) y es utilizado con frecuencia en redes del tipo estudiado.

En adelante, se muestran las matrices y bias óptimos obtenidos según modelo 5 de Ef dado por las matrices (6) a (8):

$$W^1 = \begin{pmatrix} -0,342 & -2,028 & 2,102 \\ 1,301 & 1,952 & -2,102 \\ -0,254 & 2,522 & -0,264 \\ -0,274 & 2,665 & 1,161 \\ -1,464 & -0,027 & 3,613 \\ -2,494 & -0,859 & -1,300 \\ -1,295 & -1,470 & 1,543 \\ 2,029 & 1,213 & 2,213 \end{pmatrix}; \quad b^1 = \begin{pmatrix} 2,670 \\ -1,467 \\ 0,935 \\ -0,204 \\ -0,325 \\ -1,233 \\ -2,481 \\ 2,561 \end{pmatrix} \tag{6}$$

$$W^2 = \begin{pmatrix} -0,719 & 0,389 & 0,489 & 0,144 & 2,175 & -0,007 & -0,001 & -0,687 \\ 0,543 & 0,547 & 0,027 & 0,198 & -0,170 & 0,718 & -1,599 & -0,504 \\ 0,133 & -0,755 & 0,060 & -1,271 & -0,433 & -0,697 & 0,479 & 0,107 \\ -0,590 & 0,741 & -0,520 & -0,521 & -0,179 & -0,426 & 1,173 & 1,159 \end{pmatrix}; \quad b^2 = \begin{pmatrix} 1,669 \\ -0,291 \\ -0,263 \\ -1,387 \end{pmatrix} \quad (7)$$

$$W^3 = (0,784 \quad 0,710 \quad 0,091 \quad 0,782); \quad b^3 = (0,599) \quad (8)$$

Se obtuvieron el coeficiente de regresión y el error estándar (desviación típica) calculados para los datos de validación de la red, respectivamente, $R = 83,33$, $S = 1,83 \%$

Estos resultados se comparan con la estimación de Ef , dado por (9) con ayuda de un modelo de regresión no lineal de ajuste, obtenida a partir de los mismos datos experimentales:

$$Ef = 215,41 + 75,13Cau^{0,202}Hu^{-0,220} - 202,16Cbio^{0,083} - 441,21Hu^{-0,220} + 412,01Hu^{-0,220}Cbio^{0,083} \quad (9)$$

Con los indicadores $R = 59,25$, $S = 2,03 \%$

Matrices y bias óptimos obtenidos para Tzp según modelo (5) dado por (10) a (12):

$$W^1 = \begin{pmatrix} -1,409 & 1,882 & 1,701 \\ 0,870 & -1,290 & 2,179 \\ -1,394 & 0,195 & -2,381 \\ 0,725 & 2,160 & -1,696 \\ -0,766 & 0,837 & 2,493 \\ -0,815 & 1,608 & 2,254 \\ -1,909 & 2,307 & -0,105 \\ -1,763 & 1,832 & 1,209 \end{pmatrix}; \quad b^1 = \begin{pmatrix} 2,670 \\ -2,254 \\ 1,244 \\ -0,295 \\ -0,796 \\ -0,983 \\ -1,717 \\ -2,829 \end{pmatrix} \quad (10)$$

$$W^2 = \begin{pmatrix} -0,221 & -0,771 & -0,278 & 0,549 & 0,542 & 0,950 & 0,948 & 0,123 \\ -0,218 & -0,131 & 0,874 & 0,948 & -0,014 & 0,129 & -0,840 & -0,861 \\ -0,681 & -0,444 & 0,152 & -0,246 & 0,679 & -0,481 & -1,018 & 0,275 \\ -0,255 & 0,857 & 0,255 & 0,925 & 0,595 & -0,098 & 0,113 & 0,932 \end{pmatrix}; \quad b^2 = \begin{pmatrix} 1,654 \\ 0,585 \\ -0,454 \\ -1,686 \end{pmatrix} \quad (11)$$

$$W^3 = (0,148 \quad 0,522 \quad -0,708 \quad 0,852); \quad b^3 = (0,141) \quad (12)$$

obtuvieron el coeficiente de regresión y el error estándar calculados para los datos de validación de la red, respectivamente, $R = 81,87$, $S = 3,94 \text{ }^\circ\text{C}$

Estos resultados se comparan con la estimación de Tzp con ayuda de un modelo de regresión no lineal de ajuste, obtenida a partir de los mismos datos experimentales:

$$Tzp = 2,88 - 6652,6Cau^{-0,063}Cbio^{0,051} + 11218,5Cau^{-0,063}Hu^{-0,190}Cbio^{0,051} + 7334,31Cbio^{0,051} - 12109,6Hu^{-0,190}Cbio^{0,051} \quad (13)$$

Con los indicadores $R = 78,77$, $S = 4,34 \text{ }^\circ\text{C}$

Matrices y bias óptimos obtenidos para MG según modelo (5) dado por (14) a (16):

$$W^1 = \begin{pmatrix} 0,507 & -0,133 & 2,590 \\ -3,017 & -0,071 & -1,917 \\ 2,052 & 1,457 & -1,657 \\ 1,798 & -2,121 & 1,295 \\ -0,681 & -1,531 & -1,511 \\ 1,499 & -0,163 & 2,071 \\ -0,577 & -0,718 & 2,234 \\ 0,563 & 2,349 & 0,979 \end{pmatrix}; \quad b^1 = \begin{pmatrix} -2,715 \\ 1,418 \\ -0,804 \\ -0,092 \\ 0,270 \\ 1,320 \\ -2,436 \\ 3,005 \end{pmatrix} \quad (14)$$

$$W^2 = \begin{pmatrix} 0,363 & -0,250 & 0,208 & 0,281 & 0,922 & 0,214 & 0,324 & -0,286 \\ 0,414 & 1,141 & 0,842 & 0,113 & 0,071 & 0,329 & -0,024 & -1,019 \\ -0,177 & 0,888 & -0,902 & 0,141 & -0,451 & 0,579 & -1,082 & 0,574 \\ 1,286 & -0,066 & -0,320 & -0,155 & -0,217 & 0,517 & 0,836 & -0,241 \end{pmatrix}; \quad b^2 = \begin{pmatrix} -2,040 \\ 0,320 \\ 1,010 \\ 1,558 \end{pmatrix} \quad (15)$$

$$W^3 = (0,420 \quad 0,420 \quad 0,623 \quad 2,348); \quad b^3 = (-0,284) \quad (16)$$

Se obtuvieron el coeficiente de regresión y el error estándar calculados para los datos de validación de la red, respectivamente, $R = 82,5$; $S = 0,16$ Kg/hora

Estos resultados se comparan con la estimación de MG con ayuda de un modelo de regresión no lineal de ajuste, obtenida a partir de los mismos datos experimentales (17):

$$MG = 1,83 - 12,73Cau + 706,94Cau^{3,791} \quad (17)$$

Con los indicadores $R = 80,14$; $S = 0,18$ Kg/hora

Matrices y bias óptimos obtenidos para PCG según modelo (5) dado por (18) a (20):

$$W^1 = \begin{pmatrix} 4,740 & 2,412 & -2,726 \\ -0,776 & -8,148 & 6,772 \\ -5,615 & 1,075 & 2,463 \\ 9,522 & -8,119 & -0,441 \\ -5,397 & -3,277 & -4,553 \\ -4,753 & 3,661 & 5,477 \\ 5,225 & -2,483 & -0,529 \\ -1,965 & -2,999 & 4,8017 \end{pmatrix}; \quad b^1 = \begin{pmatrix} 2,923 \\ 2,094 \\ -1,528 \\ -0,722 \\ 0,522 \\ -0,875 \\ 1,489 \\ -2,950 \end{pmatrix} \quad (18)$$

$$W^2 = \begin{pmatrix} 4,566 & 6,322 & 4,233 & 2,487 & 3,043 & -8,319 & 8,149 & 5,363 \\ -3,059 & 5,090 & -2,825 & 4,817 & 1,819 & 2,701 & 8,507 & -2,544 \\ -0,881 & -0,219 & -1,500 & -5,935 & 3,400 & 3,218 & -4,853 & 3,102 \\ -1,972 & -1,839 & 8,692 & -7,346 & 2,263 & 0,879 & 4,065 & -0,212 \end{pmatrix}; \quad b^2 = \begin{pmatrix} 8,764 \\ 0,001 \\ -1,374 \\ 3,504 \end{pmatrix} \quad (19)$$

$$W^3 = (-4,128 \quad 3,882 \quad -0,297 \quad 0,380); \quad b^1 = (0,577) \quad (20)$$

Se obtuvieron el coeficiente de regresión y el error estándar calculados para los datos de validación de la red, respectivamente, $R = 87,0$ $S = 0,65$ KJ/Kg

Estos resultados se comparan con la estimación de PCG con ayuda de un modelo de regresión no lineal de ajuste, obtenida a partir de los mismos datos experimentales:

Para la estimación del poder calórico del gas (PCG), se puede observar en la ecuación 14:

$$PCG = -103,42 + 71,41Cau^{0,332}Hu^{-0,224}Cbio^{0,084} + 45,18Cbio^{0,084} + 0,84Hu + 212,10Hu^{-0,224} - 139,06Hu^{-0,224}Cbio^{0,084} \quad (21)$$

Con los indicadores $R = 80,1$; $S = 0,76$ KJ/Kg

Los resultados obtenidos muestran que, para todas las salidas requeridas según el análisis sistémico de la tarea de operación de las instalaciones de gasificación *downdraft*, se obtiene mejor ajuste con ayuda de las RNA que con las ecuaciones de regresión no lineal, Las RNA obtenidas, para la identificación de todas y cada una de las relaciones requeridas para la operación del proceso de gasificación 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, No se logra en una misma red identificar todos los indicadores requeridos dada la ausencia de suficiente correlación entre ellos y la pequeña cantidad de datos de partida (81), A pesar de esto se logran indicadores estadísticos con suficiente precisión para la implementación de estas redes como relaciones participantes del modelo inicial de operación, el que, en condiciones de instalaciones en explotación, debe ser rectificado periódicamente a partir del experimento pasivo derivado de ella, pues mientras mayor sea la cantidad de datos mayor será la calidad de los modelos obtenidos.

Fue definida la estructura de modelos requeridos para la operación de gasificadores *downdraft* sobre la base de su análisis sistémico, estableciéndose como adecuada la estructura que incluye la eficiencia de la instalación (Ef), temperatura de la zona pilórica (Tzp), poder calórico del gas (PCG), caudal másico del gas (MG) como función de la humedad (Hu), cantidad de biomasa ($Cbio$) y caudal de aire de combustión (Cau). Los experimentos realizados aportaron los datos necesarios para la identificación de los modelos. Se identificaron las salidas con ayuda de modelos de redes neuronales y de regresión no lineal, obteniéndose el mejor ajuste con ayuda de modelos de redes neuronales artificiales.

Conclusiones

Con la aplicación de estas redes al caso concreto de la operación del gasificador tipo *downdraft* desarrollado en la investigación experimental, para la leña, se obtienen redes individuales por cada indicador de desempeño de la operación con 2 capas ocultas, 8 nodos en la primera y cuatro en la segunda y funciones de transferencias tipo tangencial sigmoideal y valores de pesos y bias por capas propios de cada indicador concreto, Se puede considerar que el estudio realizado pueda servir como punto de partida para la

identificación de redes neuronales artificiales para otras instalaciones de gasificación tipo *downdraft*, en la construcción de modelos de operación del proceso de gasificación.

Las redes neuronales elaboradas para una instalación con vistas a su operación pueden ser utilizadas tan solo como modelos iniciales. Los definitivos deben ser rectificadas periódicamente a partir del experimento pasivo resultante de su operación

Referencias

1. Sharma AK. Experimental investigations on a 20 kW, solid biomass gasification system. *Biomass Bioenergy*. 2011;35:421-8
2. Hannula I, Kurkela E. A parametric modeling study for pressurized steam blown fluidised-bed gasification of wood. *Biomass Bioenergy*. 2012;38:58-67.
3. Shabbar S, Janajreh I. Thermodynamic equilibrium analysis of coal gasification using Gibbs energy minimization method. *Energy Conversion Management*. 2013;65:755-763
4. Han, J. Modeling downdraft biomass gasification process by restricting chemical reaction equilibrium with Aspen Plus. *Energy Conversion and Management*. 2017;153:641-8.
5. Barman NS, Ghosh S, De S. Gasification of biomass in a fixed bed downdraft gasifier: a realistic model including tar. *BioresourTechnology*. 2013;107:505-11.
6. 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;46:248-54.
7. Puig Arnavat M, Bruno A. Review and analysis of biomass gasification models. *Renewable and Sustainable Energy Reviews*. 2010; 14: 2841-51.
8. DiBlassi A. Dynamic behaviour of stratified downdraft gasifiers. *Chem Eng Sci*. 2000;55:2931-44.
9. Bhattacharya A, Bhattacharya A, Datta A. Modeling of hydrogen production process from biomass using oxygen blown gasification. *Int Hydrogen Energy*. 2013;37:18782-90
10. Kirsanovs V. Experimental investigation of downdraft gasifier at various conditions. *Energy Procedia*. 2017;128:332-338
11. Tigabwa Y. Mathematical and computational approaches for design of biomass gasification for hydrogen production: A review, *Renewable and Sustainable Energy Reviews*. 2012;16:2304-15.
12. Patra T, Sheth N. Biomass gasification models for downdraft gasifier: A state-of-the-art review. *Renewable and Sustainable Energy Reviews*. 2015;50:583-93.
13. Arnavat MP, Hernández JA, Bruno JC, et al. Artificial neural network models for biomass gasification in fluidized bed gasifiers. *Biomass Bioenergy*. 2013;49:279-89.
14. Arzola Ruiz, J. *Sistemas de Ingeniería*. La Habana, Cuba: Editorial Félix Varela; 2012. [Consultado el: 18 de marzo de 2018]. Disponible en: <https://www.researchgate.net/publication/271505692>
15. Jain, LC, et al. *Recent advances in artificial neural networks. Design and applications*. USA: CRC Press; 2000.