



Determinación y Evaluación de la Temperatura de Piroloxación para el Proceso de Cogeneración en Gasificación tipo Downdraft con el Uso de Redes Neuronales Artificiales (RNA).

Determination and Evaluation of the Pyrolysis Temperature for the
Cogeneration Process in Downdraft Gasification with the Use of Artificial
Neural Networks (ANN).

EDISON SOLIS CORNEJO¹, GERMAN LLAMATUMBI PIÑAN¹ Y EDUARDO GUTIÉRREZ
GUALOTUÑA¹

RESUMEN

En el presente estudio se realizó el control de la temperatura de piroloxación en un proceso de gasificación de la madera de eucalipto, su predicción se realiza a partir de los parámetros de operación del reactor para asegurar la obtención de un gas de síntesis con la calidad requerida. Se muestran los resultados obtenidos del modelado matemático para la predicción de la temperatura de piroloxación con la utilización de técnicas de inteligencia artificial y el desarrollo de redes neuronales artificiales, con datos experimentales del proceso. Por ello se implementó un diseño estadístico experimental de tipo 3^a, con dos réplicas adicionales, mediante el cual se realizaron los entrenamientos de una red neuronal artificial capaz de predecir la temperatura de piroloxación en un gasificador de tipo downdraft con cogeneración. La predicción de la temperatura de piroloxación tiene error de 4,6 °C y un ajuste del 93,71 %, valores adecuados sobre este parámetro de trabajo.

Palabras Claves: gasificación; biomasa; predicción; temperatura de piroloxación; redes neuronales.

¹Departamento de Ciencias de la Energía y Mecánica, Universidad de las Fuerzas Armadas – ESPE, Sangolquí, Ecuador

©Los autores. Este artículo es publicado por la Revista Aporte Santiaguino de la Universidad Nacional Santiago Antúnez de Mayolo. Este es un artículo de acceso abierto, distribuido bajo los términos de la Licencia Creative Commons Attribution 4.0 International (CC BY 4.0) (<https://creativecommons.org/licenses/by/4.0/>), que permite: Compartir — copiar y redistribuir el material en cualquier medio o formato, Adaptar — remezclar, transformar y construir a partir del material para cualquier propósito, incluso comercialmente.

ABSTRACT

In the present study, the control of the pyrolysis temperature was carried out in a gasification process of eucalyptus wood, its prediction is made based on the operating parameters of the reactor to ensure the obtaining of a synthesis gas with the required quality. The results obtained from the mathematical modeling for the prediction of the pyrolysis temperature with the use of artificial intelligence techniques and the development of artificial neural networks are shown, with experimental data of the process. For this reason, an experimental statistical design of type 3ⁿ was implemented, with two additional replications, by means of which the training of an artificial neural network capable of predicting the pyrolysis temperature in a downdraft type gasifier with cogeneration was carried out. The prediction of the pyrolysis temperature has an error of 4.6 °C and an adjustment of 93.71%, adequate values for this working parameter.

Keywords: gasification; biomass; prediction; pyrolysis temperature; neural networks.

INTRODUCCIÓN

A pesar de la constante disminución de las reservas de combustibles fósiles y su posible agotamiento en un periodo de tiempo relativamente corto, en la actualidad se mantiene una demanda creciente de energía en todas las esferas de la sociedad, lo cual ha fomentado la necesidad de utilizar y desarrollar fuentes energéticas alternativas que permitan mantener el suministro energético requerido. Como parte de las alternativas presentes en nuestros días, la utilización de tecnologías que empleen las fuentes energías renovables (FER) constituyen una alternativa aprovechada por muchos países como forma viable para disminuir el consumo de hidrocarburos y reducir el impacto que se deriva de su explotación ([Sharma, 2018](#)).

Una opción muy efectiva para países con una disponibilidad importante de recursos biomásicos es el empleo de la gasificación para la producción de biocombustibles, cuya aplicación a la generación de energía, calor y movilidad crece cada vez más en la actualidad ([World Energy Outlook, 2018](#)). Dentro de las tecnologías empleadas para la obtención de gas combustible se destaca el empleo de gasificadores de tipo downdraft por su posibilidad de obtener bajos porcentajes de alquitrán ([Gutiérrez, 2014](#); [Hernández, 2018](#)). Justamente, la presencia de perfiles de temperaturas superiores a los 800 °C en este tipo de reactores, ha motivado un gran interés por

el aprovechamiento energético del calor perdido por las paredes mediante el empleo de sistemas integrados de cogeneración (Bhering, Martínez y Almazán, 2017). Los trabajos de (Quiñonez y Taípe, 2017; Chidiebere, 2018; Herrera, 2019; Martínez, Lesme y Silva, 2020), constituyen ejemplos del empleo de la cogeneración para recuperar parte de la energía que se pierde al medio sin utilidad.

La gasificación de biomasa, consiste en la conversión de un caudal de materia sólida (biomasa) en un combustible gaseoso y/o líquido que puede ser quemado para liberar energía o ser utilizado para la producción de otras sustancias químicas valiosas (Basu, 2010). Este proceso requiere de un agente gasificante para reordenar la estructura molecular de la biomasa y convertirla en un combustible útil con el incremento de la relación hidrógeno-carbono (H/C).

De forma general, el proceso de gasificación depende de varios factores, entre ellos se destaca por su importancia la temperatura de pirólisis (o de pirólisis), parámetro mediante el cual se determina el rompimiento de la molécula de la biomasa por la reacción de reducción que se produce a una presión determinada dentro del reactor (Han, 2017). La precisión de este parámetro es de vital importancia para la obtención de un gas de síntesis de alta calidad, en el cual se tenga una relación adecuada de componentes gaseosos combustibles. Por esta razón, es necesario disponer de formas efectivas de estimar o predecir su valor durante el proceso de gasificación para poder corregir los parámetros de operación que se establecen sobre el reactor. Una forma efectiva de realizar estimaciones sobre este parámetro es el empleo de modelos matemáticos de predicción (Janajreh y Al Shrah, 2013; Puig, 2013).

Para la determinación de los múltiples parámetros presentes en el proceso de gasificación se han empleado diversos tipos de modelos. Los trabajos de (Shabbar, 2013; Hannula y Kurkela, 2017), utilizan modelos de equilibrio termodinámico para determinar la composición del final gas, obtenido mediante la suposición de mezclas de reactivos en un tiempo infinito. De forma similar, (Han, 2017), emplean un modelo no estequiométrico mediante el cual se determinan los parámetros a partir de la minimización de la energía libre de Gibbs sin tomar en cuenta las reacciones presentes. Por otra parte, (Sreejith, Muraleedharan y Arun, 2013), emplean un modelo de tipo cinético para predecir, además, los perfiles de temperaturas dentro del reactor, en el cual se considera la hidrodinámica y los balances de masa y de energía que se presentan durante el proceso de gasificación. Otro grupo de modelos muy empleados para la obtención de las temperaturas en el

gasificador son los derivados de la aplicación de la fluido-dinámica computacional (FDC), los cuales se basan en la solución de sistemas de ecuaciones simultáneas obtenidos principalmente por balances de energía y masa en las zonas del reactor (Puig, Bruno y Coronas, 2010; Bhattacharya, 2013).

A pesar de la amplia utilización, el modelado mediante estos tipos de modelos resulta ser muy complejo por la necesidad de incorporar en los procedimientos de cálculo parámetros termodinámicos y cinéticos que son difíciles de precisar y de los que, en la mayoría de los casos, se carece de información precisa, razones por las cuales muchos autores han desarrollado modelos basados en datos experimentales con una menor dificultad de obtención. Dentro de estos modelos destacan los desarrollados mediante las redes neuronales artificiales (RNA), los cuales han experimentado en los últimos tiempos un significativo incremento de su utilización en los procesos de gasificación (Ahmed, 2012). En este sentido, los trabajos de (Li, 2018; Gutiérrez, 2018; Gutiérrez, 2019), desarrollan investigaciones en las que se desarrollan modelos de redes neuronales artificiales para predecir parámetros de funcionamiento e indicadores de eficiencia del proceso de gasificación de biomasa.

A pesar de la importancia que tiene en el proceso de gasificación de biomasa la predicción de la temperatura de pirólisis y de los aportes realizados por diversos autores, en el estudio bibliográfico realizado como parte de la investigación, se evidencia una carencia de trabajos dedicados a la determinación de esta variable en función de los parámetros de operación en presencia de cogeneración. Por tal motivo y tomando en consideración las referencias analizadas como punto de partida, en el presente artículo se muestra el desarrollo de un modelo de predicción de la temperatura de pirólisis en un reactor de tipo downdraft en presencia de cogeneración mediante el empleo de redes neuronales artificiales (RNA) y la realización de mediciones experimentales activas.

MATERIALES Y MÉTODOS

La temperatura de pirólisis o de pirolización, es un parámetro que presenta una gran sensibilidad en relación a la modificación de las variables de operación del gasificador. Fundamentalmente, este parámetro se regula a partir de la apertura de una válvula acoplada a un dispositivo que posibilita la succión del aire para que se produzca el denominado “efecto cigarro” requerido para la generación de gas (Gutiérrez, 2018). La regulación de esta entrada de aire a partir de la manipulación de esta válvula, controla, además, el caudal de aire de combustión que entra al reactor y por tanto permite también regular el gradiente de temperatura que se presenta en su interior. Como se puede notar, esta condición resalta la importancia que se presenta en el control de este parámetro durante la operación, pues regula las condiciones internas en las que se transforma la biomasa y de su relación con el aire de combustión depende en gran medida la composición del gas de síntesis que se obtienen finalmente, y por consiguiente su calidad.

Por otra parte, la humedad de la biomasa y la cantidad que se introduce al gasificador también constituyen parámetros cruciales que influyen en la temperatura de pirolización y en la calidad del proceso de gasificación, pues una alta presencia de humedad consume energía como parte del proceso previo de secado, además de aportar vapor de agua como parte de los gases que se generan. Atendiendo al análisis presentado anteriormente y en correspondencia con el objetivo central de esta investigación, las variables implicadas en este proceso pueden clasificarse en variables de entrada y variables de salida (Gutiérrez, 2019). Las variables de entrada pueden ser establecidas a voluntad por el operador para lograr un proceso de gasificación óptimo y una calidad requerida en el gas a obtener. En correspondencia con la necesidad de modelado y a partir del análisis realizado, las variables independientes a considerar para la predicción de la temperatura de pirólisis, se definen de la forma siguiente:

- Cantidad de biomasa, C_{bio} .
- Humedad de la biomasa, H_{bio} .
- Porcentaje de apertura de la válvula, A_{pv} .

En el caso del tipo de biomasa, se seleccionó para esta investigación la madera de eucalipto, la cual es muy valorada por su alto poder calórico (Hernández, 2018). Por lo general, cerca del 40 % de este árbol es desechado por el proceso de aserrado en

forma de astillas, corteza y aserrín, con lo cual se tiene una alta disponibilidad de este tipo de biomasa (Medina, 2014). En cuanto a las propiedades fisicoquímicas, presenta tamaños de 1 mm a 12 mm, una humedad entre un 10 % y un 20 % y una densidad aparente de 90 kg/m³ (Orozco, 2017). Las propiedades y disponibilidad mencionadas nos permiten aprovechar esta fuente energética en un proceso de gasificación de tipo downdraft.

La masa de aire que entra al reactor se controla mediante una válvula acoplada a un dispositivo Venturi en la cual se establecen porcentos de apertura para lograr modificar las condiciones internas del gasificador. El valor de por ciento de apertura de la válvula es un parámetro de fácil medición a diferencia de la cantidad de aire que entra al sistema, razón práctica por la cual es seleccionado en su lugar como variable independiente.

Como variable dependiente en la presente investigación se define la siguiente:

- Temperatura de pirólisis (o de pirolización), T_{pir} .

Para la realización de la predicción de la temperatura de pirolización que se tiene en el interior del gasificador mediante la técnica de modelado seleccionada en función de las variables independientes indicadas anteriormente, se requiere de la realización de experimentos sobre la instalación de gasificación. En base al análisis planteado anteriormente, se establece un diseño experimental de tipo 3ⁿ, con $n = 3$, en correspondencia con el número de variables independientes finales, para un total de 27 experimentos activos, a los cuales se les suma dos réplicas de control, para un total de 81 muestras experimentales totales. La consideración de una estructura de experimentación con tres niveles para cada una de las variables de entrada (nivel alto, medio y bajo), tiene como finalidad, la consideración del carácter no lineal de las relaciones entre estas variables, evaluar las interacciones que se dan entre estas variables y reflejar factores casuales como los posibles errores de medición (Cash, 2016).

Para realizar las mediciones requeridas, se utiliza como equipo básico experimental un gasificador de tipo downdraft a pequeña escala con una capacidad instalada de 5 kW, cuya relación con los equipos auxiliares requeridos para su funcionamiento se muestra en la figura 1. Como se puede observar en esta figura, el reactor es alimentado por la parte superior por una tolva y un motor acoplado a un tornillo sinfín que aseguran la cantidad de biomasa requerida en el interior del reactor. El gas de síntesis que se genera, es conducido mediante la absorción del dispositivo Venturi hacia un ciclón

para extraer el contenido de alquitrán y posteriormente es filtrado, con lo cual queda listo para su utilización. El reactor empleado lleva acoplado a la pared externa un sistema de cogeneración con un encamisado de tipo serpentín construido con tubos de cobre de 3/8”.

Para la medición de los datos de temperaturas se emplea un termómetro digital M-309 con termocuplas tipo k de cromo - aluminio, con intervalo de medición de -200 °C a 1200 °C de temperatura con un límite de error $\pm 0,4 \%$ y un cable de compensación KX. Además, se utiliza un medidor de humedad MD812 con un intervalo de medición del 5 % al 40 % y una precisión de ± 1 HR, un sensor de nivel controlado por una paleta para censar el nivel de biomasa requerido en cada experimento activo. Se le incorporó, además, una alarma digital de detección de CO de 30-999 PPM y un error de $\pm 30 \%$.




Figura 1. Esquema del sistema de gasificación establecido para la experimentación requerida.

En la realización de la experimentación se emplea para todas las combinaciones de variables un tamaño de virutas de biomasa de 2 mm a 3 mm, a una presión atmosférica constante. Los niveles de las variables independientes se establecieron según se muestra en la tabla 1.

Tabla 1. Valores establecidos para los niveles indicados de las variables independientes.

Variables independientes	Nivel		
	<i>alto</i>	<i>medio</i>	<i>bajo</i>
Cantidad de biomasa, C_{bio} [kg]	5	3	1
Humedad de biomasa, H_{bio} [%]	12	16	20
Apertura de la válvula, A_{pv} [%]	100	50	25

A partir de la combinación de cada uno de los niveles establecidos de las variables independientes, se realizan las mediciones requeridas. El objetivo de la experimentación planteada anteriormente es el de proporcionar los datos numéricos necesarios para la predicción de los valores de la temperatura de pirólisis como función de los parámetros de entrada indicados. La relación matemática entre estas variables se representa por la expresión (1):

$$T_{pir} = f(C_{bio}, H_{bio}, A_{pv}) \quad (1)$$

Dado el poco grado de relación analítica que se presentan entre las variables independientes y la variable dependiente, es necesario la utilización de una estructura de modelado que permita determinar, bajo ciertas reglas funcionales, los valores de salida del modelo según los valores de las variables indicadas como entradas, Por esta razón es necesario la utilización de técnicas avanzadas de modelado como el Deep Learning e Inteligencia Artificial (IA), dentro de las que se destacan las redes neuronales artificiales (RNA) para la predicción de datos (Pérez, 2017; Berzal, 2018).

RESULTADOS Y DISCUSIÓN

Para crear la red neuronal artificial a partir de los datos obtenidos en la experimentación realizada, se utilizó la herramienta computacional denominada Neural Net Fitting, perteneciente al Deep Learning Toolbox 14.0 de Matlab R2020a, la que permite crear RNA para la resolución de problemas de ajustes utilizando redes de tipo feed-forward con hasta dos capas ocultas de neuronas. Esta herramienta realiza toda la gestión de información de entrada y salida para poder variar operativamente la configuración de la red y visualizar el comportamiento del coeficiente de correlación (R^2) y del ajuste mediante la determinación del error cuadrado medio (MSE) con respecto a los datos seleccionados para entrenar la red y para su posterior validación.

Para el entrenamiento de la red se adoptó un 15 % de los datos de entrada para la validación, un 15 % para la verificación y el 70 % restante para el entrenamiento. Al no tenerse información previa sobre una configuración recomendada para el desarrollo y entrenamiento de la red, se realizaron un conjunto de corridas de entrenamiento donde se varió el número de neuronas y los tipos de funciones transferenciales disponibles en el Neural Net Fitting Toolbox de Matlab. Para ello se considera además la selección aleatoria de los porcentos de datos referidos anteriormente con los cuales se realizaron 20 corridas de entrenamiento y validación. En base a este análisis y las pruebas realizadas sobre los datos disponibles, se selecciona una red neuronal de nueve neuronas en la capa oculta y una neurona en la capa se salida, cuya estructura es mostrada en detalles en la figura 2.




Figura 2. Esquema de la RNA diseñada y generado automáticamente por MatLab R2020a.

La función de transferencia empleada para la realización del ajuste en la capa oculta de la red diseñada es la función tangente sigmoideal, la cual entrega una salida que se encuentra en el rango de (-1.0 a 1.0) y es utilizada con frecuencia para el ajuste de datos en problemas similares al estudiado (Berzal, 2018). Para el entrenamiento de la red diseñada se empleó el algoritmo de regularización bayesiana, el cual, si bien requiere más tiempo de cálculo para la determinación de los coeficientes de pesos en los nodos de la red, resultó ser el más adecuado para el ajuste de los datos. Para ello se realizaron pruebas a priori con todas las opciones de algoritmos disponibles a emplear. Las pruebas consistieron en la ejecución de múltiples entrenamientos seleccionando grupos aleatorios de datos de entrada y de salida para comparar los resultados finales en cuanto a la capacidad de ajuste de la red a los datos suministrados.

A partir de los entrenamientos realizados sobre la red diseñada anteriormente, se determinaron los coeficientes óptimos de pesos w y los coeficientes bias b para la capa oculta (w_{co} y b_{co}) y para la capa de salida (w_{cs} y b_{cs}). Los valores correspondientes de estos coeficientes de la RNA obtenidos se muestran en las expresiones matriciales (2), (3), (4) y (5) siguientes:

$$b_{co} = \begin{bmatrix} 3,795636 \\ 2,553018 \\ -0,009157 \\ 0,600495 \\ -1,205612 \\ -0,824699 \\ -2,843462 \\ -2,378540 \\ 1,548063 \end{bmatrix} \quad (2)$$

$$w_{co} = \begin{bmatrix} 0,250925 & 1,433653 & 3,704588 \\ -0,80185 & 1,098090 & 3,274848 \\ 3,808825 & 2,208874 & 1,122379 \\ 2,929013 & -2,142238 & -3,604274 \\ -1,235479 & -1,963103 & -3,812475 \\ -2,328979 & -0,842666 & 0,864409 \\ -1,023145 & 0,028469 & 1,237071 \\ -2,345875 & 1,556005 & 0,989057 \\ 2,283316 & -0,400162 & 1,167253 \end{bmatrix} \quad (3)$$

$$b_{cs} = -0,620528 \quad (3)$$

$$b_{cs} = [0,329996 \ -0,337229 \ -0,170393 \ -0,227099 \ -0,371660 \ -0,604037 \ -0,470231 \ -0,222621 \ -0,907917] \quad (3)$$

El porcentaje de ajuste obtenido mediante la predicción de la red neuronal artificial es de $R^2 = 0,9371$, lo que equivale a un 93,71 % de ajuste, con un error cuadrado medio $MSE = 21,4237$. Para el analizar la bondad de ajuste de la RNA realizada, se hace el gráfico de ajustes de los valores estimados y los valores predichos para el 100 % de los datos de entrada.

El gráfico correspondiente a la figura 3 muestra cada uno de los valores de temperatura de pirólisis predichos mediante la red desarrollada para el proceso de gasificación de la madera de eucalipto con presencia de cogeneración, objeto de estudio en la investigación.

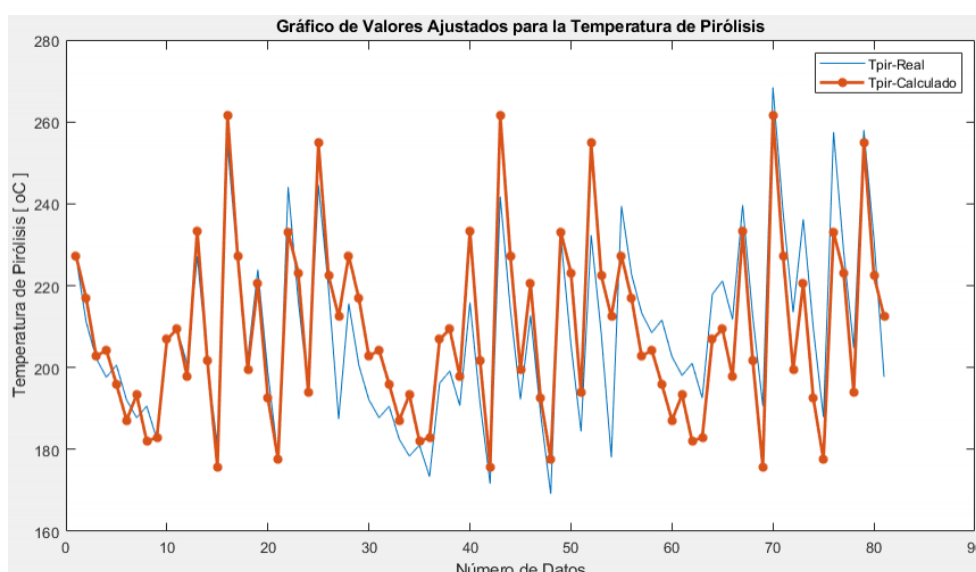


Figura 3. Ajuste de la RNA desarrollada para la predicción de la temperatura de pirólisis.

Como se puede apreciar en la figura, el ajuste mostrado por la RNA es satisfactorio por lo cual se considera válida para la realización de predicciones sobre la temperatura de pirólisis que se obtienen durante el proceso de gasificación, sin la necesidad de realizar los costosos experimentos necesarios para determinar o precisar los coeficientes y parámetros termodinámicos y cinéticos requeridos por otros modelos físicos, lo cual resulta más complejo, aunque es válido destacar la necesidad de reentrenamiento periódico de esta red, incorporando nuevos valores a partir de la realización de experimentos pasivos para mejorar progresivamente su ajuste a los datos reales suministrados.

CONCLUSIONES

El trabajo realizado permite extraer las siguientes conclusiones principales:

El análisis realizado sobre los factores que inciden en el proceso de gasificación, asociados a la determinación de la temperatura de pirólisis presente en el interior del reactor, permitió la identificación adecuada de las variables independientes y dependientes necesarias para la realización del diseño estadístico experimental requerido para la obtención de los datos necesarios para el modelado.

La realización de las mediciones experimentales permitió el desarrollo del modelado para la predicción de la temperatura de pirólisis obtenida durante el proceso de

gasificación de la madera de eucalipto mediante el desarrollo de una red neuronal artificial.

La aplicación de las herramientas modernas de análisis y modelado implementadas en Matlab, permitieron el desarrollo de un modelo de red neuronal artificial de tipo feed-forward con una capa oculta de nueve neuronas, a las que se les identificaron los coeficientes bias (b) y los coeficientes de pesos de los nodos (w) mediante el entrenamiento con el 70 % de los datos de entrada para la realización de predicciones de la temperatura de pirólisis en la gasificación de la biomasa estudiada en esta investigación bajo la presencia de un sistema de cogeneración.

La red neuronal artificial obtenida, permite la predicción de la temperatura de pirólisis resultante de la gasificación de la madera de eucalipto con un error de 4,6 °C y un ajuste del 93,71 %, lo cual permite realizar una adecuada predicción sobre el valor de este parámetro de trabajo del gasificador, como alternativa a la carencia de procedimientos analíticos de alta precisión para su determinación y la dificultad que presenta el desarrollo de modelos físicos sobre este complejo proceso.

REFERENCIAS BIBLIOGRÁFICAS

- Ahmed, T. Y. *et al.* 2012. «Mathematical and computational approaches for design of biomass gasification for hydrogen production: A review. Renewable and Sustainable». *Energy Reviews*, Vol. 16, pp. 2304-2315. <<https://doi.org/10.1016/j.rser.2012.01.035>>
- Basu, P. 2010. *Biomass Gasification and Pyrolysis: practical design and theory*. 1st Edition, Academic Press Elsevier, ISBN: 9780080961620, Kidlington, Oxford, UK.
- Berzal, F. 2018. *Redes Neuronales & Deep Learning*. Edición en español, Granada. España.
- Bhattacharya, A. *et al.* 2013. «Modeling of hydrogen production process from biomass using oxygen blown gasification». *IntHydrogen Energy*, Vol, 37, pp. 18782–90. <<https://doi.org/10.1016/j.ijhydene.2012.09.131>>
- Bhering, A.; Martínez, A.; Almazán, O. 2017. «Advanced exergy analysis and environmental assesment of the steam cycle of an incineration system of municipal solid waste with energy recovery». *Energy Conversion and Management*, Vol. 157, pp. 195-214. <<https://doi.org/10.1016/j.enconman.2017.11.083>>

- Cash, P. *et al.* 2016. «Experimental Design Research Approaches, Perspectives, Applications». *Experimental Design Research Series*, Springer International Publishing Switzerland, ISBN: 978-3-319-33779-1. <<https://doi.org/10.1007/978-3-319-33781-4>>
- Chidiebere, C. *et al.* 2018. «Modelling of down-draft gasification of biomass - an integrated pyrolysis, combustion and reduction process». *Applied Thermal Engineering*, Vol. 142, pp. 444 - 456. <<https://doi.org/10.1016/j.applthermaleng.2018.06.079>>
- Gutiérrez, E. *et al.* 2014. «Análisis de un sistema de gasificación de biomasa tipo downdraft». *Rev. Aporte Santiaguino*, Vol. 7, No. 2, pp. 32 – 38, ISSN: 2070-836X. <<http://dx.doi.org/10.32911/as.2014.v7.n2.472>>
- Gutiérrez, E. *et al.* 2018. «Modelado por redes neuronales artificiales de los indicadores de desempeño de operación en instalaciones de gasificación termoquímica downdraft». *Rev. Aporte Santiaguino* Vol. 11, No. 2, pp. 211-224, ISSN-L 2616-9541. <<http://dx.doi.org/10.32911/as.2018.V11.n2.576>>
- Gutiérrez, E. *et al.* 2019. «Modelado de indicadores de operación de un gasificador downdraft por redes neuronales para biomasa Eichhornia Crassipes». *Ingeniería Energética*, Vol. 40, No. 3, pp. 212-222. <http://scielo.sld.cu/scielo.php?script=sci_abstract&pid=S1815-59012019000300212>
- Han, J. *et al.* 2017. «Modeling downdraft biomass gasification process by restricting chemical reaction equilibrium with Aspen Plus». *Energy Conversion and Management*, Vol. 153, pp. 641–648. <<https://doi.org/10.1016/j.enconman.2017.10.030>>
- Hannul, I.; Kurkela, E. 2017. «A parametric modeling study for pressurized steam blown fluidised-bed gasification of wood». *Biomass Bioenergy*, Vol. 38, pp58–67, <<https://doi.org/10.1016/j.biombioe.2011.02.045>>
- Hernández, K. 2018. *Análisis de eficiencia energética a través de la determinación del poder calorífico de la biomasa forestal en forma de briqueta de la especie eucalyptus grandis, para la región del Municipio de Palencia en el Departamento de Guatemala*. Tesis de Máster, Facultad de ingeniería, Universidad San Carlos de Guatemala, Guatemala. <<http://www.repositorio.usac.edu.gt/10920/1/Kevin%20Roberto%20Hern%C3%A1ndez%20Tavico.pdf>> [Consulta: 19-03-2021]

Determinación y Evaluación de la Temperatura de Piroloxización para el Proceso de Cogeneración en Gasificación tipo Downdraft con el Uso de Redes Neuronales Artificiales (RNA).

Herrera, R. 2019. *Análisis térmico de un gasificador tipo downdraft al combustionar residuos forestales*. Tesis de Grado, Facultad de Mecánica, SPOCH, Riobamba, Ecuador. <<http://dspace.espoch.edu.ec/bitstream/123456789/13243/1/15T00721.pdf>> [Consulta: 20-04-2021]

Janajreh, I.; Al-Shrah, M. 2013. «Numerical and experimental investigation of downdraft gasification of woodchips». *Energy Conversion and Management*, Vol. 65, pp. 783-792. <<https://doi.org/10.1016/j.enconman.2012.03.009>>

Li, Y. *et al.* 2018. «Simulation of biomass gasification in a fluidized bed by artificial neural network (ANN)». *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, Vol. 40, No. 5, pp. 544-548. <<https://doi.org/10.1080/15567036.2016.1270372>>

Martínez, A.; Lesme, R.; Silva, E. 2020. «Thermodynamic assessment of the integrated gasification-power plant operating in the sawmill industry: An energy and exergy analysis». *Renewable Energy*, Vol. 147, pp. 1151-1163. <<https://doi.org/10.1016/j.renene.2019.09.045>>

Medina, S. *et al.* 2014. *Atlas Energético de la República del Ecuador*. ESIN Consultora S. A. 1ra Edición, pp. 150 <<http://biblioteca.olade.org/opac-tmpl/Documentos/cg00194.pdf>> [Consulta: 22-04-2021]

Orozco, L. 2017. *Levantamiento y análisis del potencial energético aprovechable de la biomasa forestal en el cantón Riobamba y su viabilidad a través de gasificación tipo downdraft*, Tesis de Máster, Facultad de Ingeniería Mecánica, EPN, Quito, Ecuador. <<https://bibdigital.epn.edu.ec/bitstream/15000/18894/1/CD-8286.pdf>> [Consulta: 22-04-2021]

Pérez, C. (2017) *Redes Neuronales a través de Ejemplos: Aplicaciones con MATLAB*. ISBN: 978-1978319974, Granada, España.

Puig, M.; Bruno, J.C.; Coronas, A. 2010. «Review and analysis of biomass gasification models». *Renewable and Sustainable Energy Reviews*. Vol. 14, No. 9, pp. 2841-2851. <<https://doi.org/10.1016/j.rser.2010.07.030>>

Puig, M.; *et al.* 2013. «Artificial neural network models for biomass gasification in fluidized bed gasifiers». *Biomass and Bioenergy*, Vol. 49, pp. 279-89. <<https://doi.org/10.1016/j.biombioe.2012.12.012>>

- Quiñonez, A.; Taipe, C. 2017. *Optimización termodinámica de un gasificador tipo downdraft para la implementación de un Sistema generador de vapor para aplicaciones térmicas*, Tesis de Grado, Carrera de Ingeniería Mecatrónica, ESPE, Quito, Ecuador. <<http://repositorio.espe.edu.ec/xmlui/bitstream/handle/21000/12836/T-ESPE-053727.pdf?sequence=1&isAllowed=ys>> [Consulta: 05-05-2021]
- Shabbar, S. *et al.* 2013. «Thermodynamic equilibrium analysis of coal gasification using Gibbs energy minimization method». *Energy Conversion and Management*, Vol. 65, pp. 755-63. <<https://doi.org/10.1016/j.enconman.2012.02.032>>
- Sharma, T. *et al.* 2018. «An Experimental and Theoretical Study of the Gasification of Miscanthus Briquettes in a Double-Stage Downdraft Gasifier: Syngas, Tar, and Biochar Characterization». *Energies*, Vol. 11, No. 3225, pp. 2-10. <<https://doi.org/10.3390/en11113225>>
- Sreejith, C.; Muraleedharan, C.; Arun, P. 2013. «Performance prediction of fluidised bed gasification of biomass using experimental data-based simulation models». *Biomass Conversion and Biorefinery*, Vol. 3, No. 4, pp. 283-304. <<https://link.springer.com/article/10.1007/s13399-013-0083-5>>
- World Energy Outlook. 2018. *International Energy Agency, OECD/IEA* 2018. <<https://webstore.iea.org/download/summary/190?fileName=Spanish-WEO-2018-ES.pdf>> [Consulta: 10-05-2021]

Recepción: 05/08/2021

Aceptación: 03/09/2021

Correspondencia:

Eduardo Gutiérrez Gualotuña

ergutierrez@espe.edu.ec