

Modelo de Red Neuronal para la Predicción del Poder Calorífico (HHV) a partir del Análisis Proximal de Residuos Carbonosos

Neural Network Model to Predict the Higher Heating Value (HHV) from Proximal Analysis of Carbonaceous Waste

Investigación

María Gabriela Vanegas-García, Dr. Ulises Iván Bravo-Sánchez*, Dra. Florianne Castillo-Borja
Tecnológico Nacional de México / I T de Aguascalientes, Departamento de Ingeniería Química y Bioquímica.
Av. López Mateos 1801 Ote., Fracc. Bona Gens, Aguascalientes, Ags., México. C.P. 20256, Tel: +52 4499105002,
correo electrónico: ulisesbs@gmail.com

Resumen

Se presenta un modelo basado en Redes Neuronales Artificiales (RNA's) para la correlación del poder calorífico (HHV) de residuos carbonosos, tanto de biomásas agrícolas, como de residuos carbonosos industriales. Esto como parte de un proceso de revalorización de residuos para la generación de energía a partir de la producción de combustibles. El poder calorífico (HHV) del residuo, entre otros parámetros, determina la viabilidad de procesos de pirólisis o gasificación; por lo cual se requieren de modelos adecuados de predicción. Se obtuvo una configuración de la Red Neuronal Artificial 3-3-3-1, adecuada al número de datos y calidad de ajuste; usando como datos de entrada el Carbono Fijo (FC), la Materia Volátil (VM) y la cantidad de Cenizas (Ash) obtenidos de análisis proximales y calculando en la neurona de salida el poder calorífico (HHV). El error cuadrado medio del modelo de red neuronal es de 4.2 comparado con valores entre 5.1 a 15.7 que se obtienen con modelos existentes en la literatura.

Palabras clave: Redes neuronales, poder calorífico, análisis proximal, residuos carbonosos.

Abstract

A model based on Artificial Neural Networks is presented for the correlation of the higher heating value (HHV) of carbonaceous waste from agricultural biomass and from industrial carbonaceous waste. This is part of a waste revaluation process for the generation of energy from the production of fuels. The higher heating value (HHV) of the waste, among other parameters, determines the viability of pyrolysis or gasification processes; therefore, suitable prediction models are required. An adequate configuration was obtained for the data number and quality of adjustment, leaving a configuration of the standard artificial neural network 3-3-3-1, using as input the Fixed Carbon (FC), the Volatile Matter (VM) and the quantity of Ashes from

proximal analysis and calculating the higher heating value (HHV) in the output neuron. The mean square error of the neural network model is 4.2 compared with values between 5.1 to 15.7 that are obtained with existing models in the literature.

Keywords: Neural networks, higher heating value, proximal analysis, carbonaceous waste.

Introducción

Uno de los problemas mundiales actuales es el de proveer energía a todas las actividades antropológicas que lo requieren y cuyo origen es la dependencia y escasez de los combustibles fósiles y su reemplazo. Se han explorado diversas formas de producir energía, una de estas opciones es la obtención de combustibles alternativos a partir de biomasa de residuos de la industria agrícola para generar calor y electricidad.

El beneficio de desarrollar estos procesos aun cuando su escala puede ser pequeña, radica en que la materia prima es un residuo que se genera permanentemente; así a la vez que se genera energía se resuelve el problema de la disposición del residuo. La variedad de residuos de biomasa agrícola es amplia, pero es necesaria una caracterización para diseñar el proceso y también para conocer el potencial; entre estas características se encuentra el poder calorífico (HHV, por sus siglas en inglés), Humedad (H), Carbono Fijo (FC), Materia Volátil (VM), cantidad de Cenizas (Ash) y su composición elemental (C, H, O, N, S). La determinación del poder calorífico del residuo puede ser medido experimentalmente mediante una bomba calorimétrica, la cual mide los cambios de entalpía entre los reactantes y los productos [1]. Debido a que la determinación experimental del poder calorífico es un proceso costoso que requiere de equipo especial, las correlaciones con base en análisis proximales y elementales para la predicción del poder calorífico se han vuelto una alternativa común y viable [2]. Además, de los residuos de biomasa agrícola, existe

una generación constante de residuos domésticos orgánicos y en forma industrial residuos como aceites quemados, hules de mangueras, llantas, empaques, sellos, etc. provenientes de diversas fuentes como la industria automotriz.

En la revalorización de residuos se agrega una característica de complejidad para el diseño de procesos, que es la composición del residuo y por lo tanto de la carencia de modelos termodinámicos para el cálculo de propiedades; las cuales son necesarias para el diseño de equipos de separación, o de cinéticas de reacción para el diseño de reactores. Por ello, en lugar de determinar la composición como en cualquier proceso convencional, esta se caracteriza en función de sus componentes elementales (C, H, N, O, S) o de análisis proximales que proporcionan el contenido de Carbono Fijo (FC), Materia Volátil (VM), contenido de Ceniza (Ash) y Humedad Relativa (H) [3], [4] representing the three stages of gasification (devolatilization, partial oxidation, and steam reforming, [5], [6]. Con estos datos y modelos apropiados se puede hacer el cálculo de propiedades como el poder calorífico (HHV), la densidad y entalpía entre otras. Generalmente estos modelos no están incorporados a los simuladores o su capacidad de predicción es limitada debido a la gran variedad de residuos no convencionales que existen en la actualidad. Sin embargo, se pueden incorporar al simulador tanto componentes, como modelos de predicción.

El objetivo de este trabajo es correlacionar el poder calorífico de diferentes residuos con sus análisis proximales mediante el entrenamiento de modelos de redes neuronales artificiales estándar. Con estos modelos se valora el potencial de un residuo como posible fuente de energía en algún proceso como pirólisis o gasificación, así como la posible incorporación del modelo predictivo en un simulador de procesos.

Fundamentos teóricos

El campo de la termoquímica es una de las piezas fundamentales en nuestra sociedad moderna dependiente de la energía. Los análisis proximales y elementales de biomasa y residuos industriales carbonosos son necesarios para el diseño de procesos de producción de combustibles o generación de energía, mientras que el poder calorífico (HHV) determina la cantidad de energía que se puede generar de estos combustibles. Los procesos que buscan la conversión de residuos de biomasa, lignocelulósicos o de materiales carbonosos provenientes de la industria del hule, que contemplan la producción de energía en este proceso de valorización son los más importantes. Por ello es determinante, para la proyección de estos

procesos de valorización, el conocer el poder calorífico que puede proporcionar el residuo a considerar. La determinación directa de este parámetro requiere de equipo especializado y personal técnico calificado. Debido a esto, se han generado modelos a partir de información de análisis elemental, proximal para diferentes tipos de residuos [1], [7], [8].

Dentro de los procesos de conversión de residuos carbonosos a combustible y posteriormente energía encontramos a la pirólisis y la gasificación. El proceso de pirólisis consiste en la descomposición térmica de moléculas en ausencia de oxígeno para la obtención de productos de menor peso molecular (líquidos, gases, carbón residual) [9]. La pirólisis se puede clasificar en tres tipos dependiendo de las condiciones ambientales: pirólisis lenta (velocidad de calentamiento lenta, temperaturas inferiores a 500 °C), pirólisis moderada (temperatura de 500 °C) y pirólisis rápida (velocidades altas de calentamiento, temperaturas superiores a 500 °C y tiempos de residencia menor a 2s) [10].

Los productos de la pirólisis dependen principalmente de las condiciones térmicas del proceso. Tanto el nivel de temperatura como los cambios de esta respecto al tiempo inciden en el rendimiento del proceso. Por ejemplo, en la pirólisis rápida (flash) arriba de 700 °C y velocidades de calentamiento muy rápidas (1000 °C/min) la disrupción molecular es muy violenta y los fragmentos son expulsados rápidamente que no hay tiempo de un acomodo molecular, como ocurre a velocidades bajas de calentamiento, lo cual reduce la probabilidad de la formación de carbón [11].

La pirólisis involucra cambios simultáneos de composición química y estado físico, los cuales son irreversibles. Este proceso consta de tres etapas claramente diferenciadas: en la primera etapa se produce una descomposición lenta con producción de pequeñas cantidades de agua, óxidos de carbono, hidrógeno y metano entre otros gases ligeros. Esto es consecuencia tanto de la ruptura de enlaces debido a alta temperatura a la que se lleva el proceso como de la liberación de gases retenidos en el material carbonoso.

La segunda etapa se conoce como descomposición térmica activa; la temperatura aumenta y se produce una fragmentación más profunda de las moléculas con carbono, con la formación de hidrocarburos condensables y alquitranes. Esta etapa comienza alrededor de los 360 °C y finaliza cuando se han alcanzado temperaturas alrededor de los 560 °C aproximadamente. Por último, la tercera etapa, que transcurre a temperaturas superiores a los 600 °C, se caracteriza por la eliminación gradual de hidrógeno y otros heteroátomos. Durante todo el proceso de pirólisis la cantidad de componentes tanto gaseosos

como líquidos puede variar desde un 25 a un 70% en peso aproximadamente.

La cantidad de líquido combustible generado en el proceso de pirólisis depende de una serie de factores y variables como: *temperatura y velocidad de calentamiento*. El carbón sufre una gran variedad de cambios, tanto físicos como químicos, cuando se incrementa la temperatura desde la ambiente hasta el final de la última fase, 1000 °C aproximadamente. Si la temperatura de reacción es demasiado baja, las reacciones de descomposición no se producirán con la extensión debida y la obtención de gases y alquitranes será incompleta y, por tanto, el rendimiento en estos productos será bajo. A temperaturas de reacción altas, se producirán rupturas térmicas de los alquitranes y será por tanto pequeño el rendimiento en líquidos. Así pues, es necesario determinar la temperatura a la cual se produce el máximo rendimiento. *El tipo de carbón* influye fuertemente en el comportamiento de la pirólisis. Los carbones de bajo rango (lignitos) contienen oxígeno que durante el proceso de pirólisis se desprenden como agua y óxidos de carbono.

Los carbones bituminosos contienen una menor cantidad de oxígeno y, por tanto, producen un menor volumen de agua y de óxidos de carbono que hidrocarburos gaseosos cuando se pirolizan. *El tipo de reactor* es otro de los parámetros más influyentes en el proceso. Su importancia se basa en aspectos claves como los tiempos de residencia y la transferencia de calor, influyendo en los mecanismos que pueden controlar la velocidad de pirólisis. En reactores de lecho fijo, la etapa controlante de la velocidad es la transferencia de calor. Esto supone una limitación en la velocidad de calentamiento y un tiempo de residencia elevado. Los reactores de lecho fluidizado se adaptan mejor a los procesos continuos. En ellos la transferencia de calor a las partículas de carbón es muy rápida y pueden alcanzarse altas velocidades de calentamiento. *La presión*, en el proceso de pirólisis en atmósfera inerte a presión reducida aumenta el rendimiento en alquitranes. *El tamaño de la partícula* influye sobre los mecanismos de transferencia de calor. A mayor tamaño de la partícula, menor velocidad de reacción y menor rendimiento en gases y líquidos. Otros factores que pueden influir son la presencia de materiales inorgánicos y reacciones secundarias [12], [13].

Otro proceso complementario a la pirólisis es la gasificación de residuos, ésta es una tecnología diseñada para obtener un gas de síntesis o *syngas*, es decir, un producto que puede ser empleado como combustible, producto químico o energía. Puede definirse como un proceso pirolítico optimizado por el cual una sustancia sólida o líquida, con alto contenido en carbono, es transformada en una mezcla combustible gaseosa

mediante oxidación parcial con aplicación de calor. La diferencia entre la incineración y la gasificación radica en la presencia de oxígeno. En la incineración, el proceso es de combustión completa en presencia de oxígeno, mientras que en la gasificación y pirólisis, la reducción se realiza en ausencia o a baja concentración de oxígeno, evitando las emisiones a la atmósfera de CO₂. La pirólisis y la gasificación son dos formas de tratamiento térmico en las que los residuos se calientan a altas temperaturas con una cantidad de oxígeno limitada. El proceso se lleva a cabo en un contenedor sellado a alta presión. Convertir el material en energía es más eficiente que la incineración directa, se genera energía que puede recuperarse y usarse, mucha más que en la combustión simple [3], [14], [15].

Por otra parte, durante las últimas décadas las redes neuronales artificiales (RNA's) se han convertido en una herramienta poderosa en la identificación de patrones, caracterización de sistemas no lineales, detección de errores en datos, filtrado de señales. Entre sus aplicaciones se encuentran el reconocimiento y síntesis de voz, reconocimiento de patrones visuales, análisis de mercado, aplicaciones militares, diagnóstico médico entre muchas más. En el área de ingeniería química se siguen usando para el desarrollo de modelos como para la estimación de parámetros en procesos [16], como modelo alternativo del cálculo de flash en un simulador de proceso para disminuir el tiempo de cómputo [17], como parte de un sistema de control en la producción de metanol vía pirólisis de biomasa [18], etc. Con el paso de los años, su implementación ha pasado de códigos y software en desarrollo, a la implementación en software de uso general como Matlab y Octave entre otros, con características para usuario final. Las implementaciones de RNA's podemos encontrarlas en diferentes etapas y formas del modelo matemático, puede ser una o más RNA's el modelo en sí, completamente empírico y únicamente relacionando las entradas con las salidas presentes en el conjunto de entrenamiento. O bien, pueden ser implementadas en esquemas de reconocimiento de series de tiempo altamente no lineales como parte de un integrador numérico. En otros casos, puede combinarse con un modelo determinista y solo calcular parámetros del modelo o ser una parte del modelo.

Las Redes Neuronales Artificiales (RNA's) son modelos empíricos que nacen de la inquietud de modelar sistemas nerviosos, dos de sus propiedades más importantes al caracterizar sistemas no lineales son su naturaleza no paramétrica y su cualidad como 'aproximadores universales' [19]. Se ha demostrado que las redes neuronales llamadas de alimentación hacia adelante o estándar, son capaces de generar modelos con gran capacidad predictiva aún en presencia de comportamiento caótico. Las RNA's aprenden

patrones de activación, esto es, el aprendizaje es igual a la determinación de los valores de las conexiones que permiten a todos los nodos o neuronas alcanzar el estado de activación correcto para un patrón dado de entradas. Una vez que el patrón de activación está establecido, las salidas resultantes permiten a la red clasificar un patrón de entrada.

Las redes neuronales son modelos que en su estructura contienen neuronas (nodos) como unidades de procesamiento. Estas se encuentran distribuidas en diferentes tipos de capas (niveles). La transferencia de información entre cada capa es por medio de conexiones llamados pesos (W_{ijk}), los cuales conectan cada neurona de un nivel inferior a todas las neuronas del siguiente nivel, lo que se conoce como patrón de conectividad. Existen tres tipos de capas, de alimentación o entrada, ocultas y de salida. La primera capa alimenta las variables independientes del modelo, las capas ocultas procesan la información y son las responsables de la captura de las relaciones no lineales presentes en el conjunto de entrenamiento y por último está la capa de salida donde converge la solución del sistema. Para el entrenamiento de las redes neuronales se establece minimizar la función de energía que es el *Error cuadrado medio* entre el valor experimental menos el predicho por la red neuronal para cada dato en el conjunto de entrenamiento. Para asegurar que el modelo de red neuronal es adecuado, se entrena una serie de modelos con diferentes configuraciones y parámetros (*pesos y umbrales*) de inicio de forma aleatoria. Se usa un aprendizaje supervisado para detener el entrenamiento con base en la determinación de la misma función de energía para un conjunto de datos diferentes llamado de Validación cruzada, esto permite que el modelo sea general y no particularice al conjunto de entrenamiento [20].

El objetivo de este trabajo es la correlación del poder calorífico de diferentes residuos con sus análisis proximales mediante el entrenamiento de modelos de redes neuronales artificiales (RNA's). Con estos modelos se valora el potencial de un residuo como posible fuente de energía en algún proceso como pirólisis o gasificación, así como su posible incorporación en un simulador de procesos para la predicción de esta variable.

Materiales y métodos

Se emplea una red neuronal artificial estándar (RNA) de cuatro capas, la capa de entrada queda determinada por los datos del análisis proximal de los residuos, esto es: una neurona para el Carbono Fijo (CF), otra para la Materia Volátil (MV) y la tercera para el contenido de Cenizas. Dos capas intermedias u ocultas, cuyo tamaño se varía para encontrar la estructura adecuada

para el modelo, buscando un compromiso entre el menor tamaño de la red (menos parámetros), el ajuste adecuado de los datos (minimización del error) y la generalidad del modelo (capacidad predictiva). Por último, una neurona en la capa de salida donde se determina el poder calorífico (HHV) del residuo. En la Figura 1 se muestra el esquema de la RNA final, esta cuenta con 3 neuronas de entrada, 3 en cada capa oculta y 1 en la capa de salida.




Figura 1. Modelo de red neuronal estándar de alimentación hacia adelante para la correlación y predicción del poder calorífico (HHV) a partir de datos de análisis proximal.

Para el cálculo de la activación de cada neurona se denota la salida que procesa la j -ésima neurona en la i -ésima capa como V_{ij} (Ec. 1). Las conexiones entre las neuronas se representan matemáticamente por medio de los pesos W . Así, W_{ijk} es el peso (conexión) entre la j -ésima neurona en la i -ésima capa con respecto de la k -ésima neurona en la $(i-1)$ -ésima capa. La salida Y de la neurona j en la capa i se calcula como la sumatoria de las salidas de la capa $i-1$ multiplicadas por el peso respectivo que las conecta con la neurona ij . A esta sumatoria se le adiciona un parámetro llamado umbral Θ , el cual va asociado a la neurona ij . A esta salida se aplica una función de activación, que para las capas de entrada y salida es la función identidad. Para las capas ocultas, que capturan la no linealidad de los datos, la función de activación $\sigma(Y)$, es generalmente una función discriminante (monotónica creciente o sigmoide) pues este tipo es apropiado para aproximar una función no lineal mediante la construcción de redes neuronales (Ec. 2), [20].

$$V_{ij} = \sigma(Y_{ij}) = \sigma \left(\sum_{k=1}^{n_{i-1}} W_{ijk} V_{(i-1)k} + \Theta_{ij} \right) \quad (1)$$

$$\sigma(x) = \frac{1}{2} (1 + \tanh(x)) \quad (2)$$

Una función sigmoide tiene como característica que para alcanzar sus límites de 0 y 1 se requiere de introducir datos de pequeña y gran magnitud al sistema respectivamente. De este modo, la región útil de la función de activación es aproximadamente entre 0.1 y 0.9; por lo tanto, las variables de entrada como de

salida a la RNA son escaladas linealmente dentro de este rango.

El entrenamiento se basa en la minimización del error medio absoluto entre los datos experimentales y los predichos por la red. Esta RNA se implementa en Excel utilizando la herramienta Solver con el método GRG Nonlinear que utiliza el gradiente reducido generalizado [21], [22]. Se hace un entrenamiento supervisado, tal que se detiene el entrenamiento cuando el error medio absoluto del conjunto de validación aumenta aun cuando el error medio absoluto del conjunto de entrenamiento sigue disminuyendo. El conjunto de entrenamiento consta de datos de análisis proximales [7], [8] con su respectivo poder calorífico reportado (HHV).

$$E = \frac{100\%}{np} \sum_{i=1}^{np} \left| \left(\frac{HHV_{pred} - HHV_{exp}}{HHV_{exp}} \right) \right| \quad (3)$$

Además, por cada tamaño de red, se usaron diversos conjuntos de entrenamiento obtenidos a partir del mismo conjunto de datos experimentales, usando de la base de datos el 80 % para entrenar y el 20 % para validar. También cada red se entrena al menos tres veces con conjuntos de parámetros aleatorios diferentes para las conexiones (*pesos y umbrales*). Estas pruebas lo que buscan es determinar la estructura adecuada de la RNA, ya que una vez encontrada, esta se puede ajustar al mismo conjunto de entrenamiento con diferentes valores de inicio y los conjuntos finales de parámetros, aunque pueden ser distintos el comportamiento aprendido por la RNA será el mismo.

Resultados y discusión

Se entrenaron modelos con diferentes configuraciones para encontrar el tamaño de red apropiado para la cantidad de datos y asegurar la generalidad del modelo. En la Tabla 1 se presentan los parámetros de la RNA seleccionada como el mejor modelo de todos los modelos entrenados. Con estos parámetros ahora la RNA puede funcionar como modelo predictivo.

Tabla 1. Parámetros de la red neuronal
RNA 1 (3-3-3-1)

Capa	Neurona en la capa actual	Neurona de la capa anterior			Umbral
		1	2	3	
2	1	0.1956	0.4298	0.9495	-0.6973
	2	0.1370	6.2484	-0.3480	-3.6690
	3	-5.2388	0.7161	-4.7528	3.8418
3	1	1.0233	1.0704	1.3196	1.5670
	2	2.4954	0.0357	0.3591	-1.1782
	3	0.5489	-6.9769	1.3085	0.0518
4	1	0.2286	-2.1042	-0.2798	1.8776

En la Tabla 2 se presentan los factores de escalamientos para las entradas y salidas de la red. En la Tabla 3 se muestran algunos modelos reportados en la literatura [1], [7], [8], [23]–[25] y tres modelos de Redes Neuronales con la configuración final seleccionada (3-3-3-1). En la Figura 2 se compara el poder calorífico (HHV) experimental contra el predicho por el modelo de RNA 1.

Tabla 2. Factores de escalamiento para las entradas y salidas de la RNA.

Variable	a	b
FC	0.008839779	0.176022099
VM	0.008920607	0.108206958
Ash	0.010299987	0.100309
HHV	0.027818346	0.256617289

Tabla 3. Comparación del error cuadrado medio de los modelos en la predicción del potencial calorífico (HHV).

Modelo	DRM	Referencia
RNA 1 (3-3-3-1)	4.257	Este trabajo
RNA 2 (3-3-3-1)	4.584	Este trabajo
RNA 3 (3-3-3-1)	4.651	Este trabajo
$HHV = 19.914 - 0.2324Ash$	10.45	Sheng y Acevedo, [24]
$HHV = -3.0368 + 0.2218VM + 0.2601FC$	9.246	Sheng y Acevedo, [24]
$HHV = 0.3536FC + 0.1559VM - 0.0078Ash$	5.114	Parikh y col., [7]
$HHV = 354.3FC + 170.8VM$	6.020	Cordero y col., [8]
$HHV = 35.430 - 183.5VM - 354.3Ash$	6.329	Cordero y col., [8]
$HHV = -10.8141 + 0.3133(VM + FC)$	15.72	Jiménez y González, [25]
$HHV = 0.1905VM + 0.2521Fc$	7.712	Yin, [1]

Además, atendiendo a la idea de usar este modelo como parte de un proceso de revalorización de residuos, se probó la capacidad predictiva con datos de tres muestras de EPDM que es un residuo abundante de hule de la industria automotriz. Los datos de este residuo no estuvieron presentes ni en los conjuntos de entrenamiento y ni en los de validación. Los resultados ofrecen un poder calorífico que lo ubica en la media de los residuos reportados en la literatura (ver Tabla 4). Por lo anterior, este residuo se puede considerar para el diseño de un proceso de producción de combustible alterno.




Figura 2. Poder calorífico (HHV) experimental contra el predicho por el modelo de RNA.

Tabla 4. Valor de poder calorífico (HHV) predicho por el modelo de RNA para tres tipos de EPDM con diferente proporción de etileno.

% de etileno en EPDM	HHV (MJ/kg)
48	25
55	24
65	23

Conclusiones

Se obtuvo un modelo de RNA para la predicción del poder calorífico (HHV) de diferentes residuos de biomasa y residuos industriales con contenido de carbón en su estructura. Se comparó con correlaciones reportadas en la literatura y se logra la disminución del error de predicción comparada con los otros modelos. La ventaja de usar modelos de RNA es que no se requiere una forma de modelo *a priori* y se pueden seguir adicionando datos para su reentrenamiento.

Agradecimientos

Los autores agradecen el Tecnológico Nacional de México por el apoyo al proyecto 6393.18-P en la Convocatoria 2018 de Apoyo a la Investigación Científica y Tecnológica en los Programas Educativos de los Institutos Tecnológicos Federales y Centros.

Referencias

- [1] C.-Y. Yin, “Prediction of higher heating values of biomass from proximate and ultimate analyses,” *Fuel*, vol. 90, no. 3, pp. 1128–1132, Mar. 2011.
- [2] M. Qi, H. Luo, P. Wei, and Z. Fu, “Estimation of low calorific value of blended coals based on support vector regression and sensitivity analysis in coal-fired power plants,” *Fuel*, vol. 236, no. May 2018, pp. 1400–1407, 2019.
- [3] S. Begum, M. G. Rasul, and D. Akbar, “A numerical investigation of municipal solid waste gasification using aspen plus,” *Procedia Eng.*, vol. 90, pp. 710–717, 2014.
- [4] M. Niu, Y. Huang, B. Jin, and X. Wang, “Simulation of Syngas Production from Municipal Solid Waste Gasification in a Bubbling Fluidized Bed Using Aspen Plus,” *Ind. Eng. Chem. Res.*, vol. 52, no. 42, pp. 14768–14775, 2013.
- [5] H. Y. Ismail, A. Abbas, F. Azizi, and J. Zeaiter, “Pyrolysis of waste tires: A modeling and parameter estimation study using Aspen Plus?,” *Waste Manag.*, vol. 60, pp. 482–493, 2017.
- [6] P. Lestinsky and A. Palit, “Wood Pyrolysis Using Aspen Plus Simulation and Industrially Applicable Model,” *Geosci. Eng.*, vol. LXII, no. 1, pp. 11–16, 2016.
- [7] J. Parikh, S. A. Channiwalla, and G. K. Ghosal, “A correlation for calculating HHV from proximate analysis of solid fuels,” *Fuel*, vol. 84, no. 5, pp. 487–494, 2005.
- [8] T. Cordero, F. Marquez, J. Rodriguez-Mirasol, and J. Rodriguez, “Predicting heating values of lignocellulosics and carbonaceous materials from proximate analysis,” *Fuel*, vol. 80, no. 11, pp. 1567–1571, 2001.
- [9] J. A. Ospina and S. Villada-Gil, “Métodos para Caracterizar Combustibles Líquidos y Gaseosos Obtenidos de Llantas en Desuso a Través de las Normas ASTM.,” *Rev. Ing. “Lámpsakos,”* vol. 3, no. 6, pp. 23–31, 2011.
- [10] E. Amini, M. S. Safdari, J. T. DeYoung, D. R. Weise, and T. H. Fletcher, “Characterization of pyrolysis products from slow pyrolysis of live and dead vegetation native to the southern United States,” *Fuel*, vol. 235, no. September 2018, pp. 1475–1491, 2019.
- [11] C. A. Zaror and D. L. Pyle, “The pyrolysis of biomass: A general review,” *Proc. Indian Acad. Sci. Sect. C Eng. Sci.*, vol. 5, no. 4, pp. 269–285, 1982.
- [12] B. Tian, Y. Y. Qiao, Y. Y. Tian, and Q. Liu, “Investigation on the effect of particle size and heating rate on pyrolysis characteristics of a

- bituminous coal by TG-FTIR,” *J. Anal. Appl. Pyrolysis*, vol. 121, pp. 376–386, 2016.
- [13] E. Hu *et al.*, “Effect of the Moisture Content in Coal on the Pyrolysis Behavior in an Indirectly Heated Fixed-Bed Reactor with Internals,” *Energy and Fuels*, vol. 31, no. 2, pp. 1347–1354, 2017.
- [14] N. Ramzan, A. Ashraf, S. Naveed, and A. Malik, “Simulation of hybrid biomass gasification using Aspen plus: A comparative performance analysis for food, municipal solid and poultry waste,” *Biomass and Bioenergy*, vol. 35, no. 9, pp. 3962–3969, 2011.
- [15] J. Tian, F. Ni, and M. Chen, “Application of pyrolysis in dealing with end-of-life vehicular products: A case study on car bumpers,” *J. Clean. Prod.*, vol. 108, no. 800, pp. 1177–1183, 2015.
- [16] I. Estiati *et al.*, “Comparison of artificial neural networks with empirical correlations for estimating the average cycle time in conical spouted beds,” *Particuology*, vol. 42, pp. 48–57, 2019.
- [17] J. P. Poort, M. Ramdin, J. van Kranendonk, and T. J. H. Vlugt, “Solving vapor-liquid flash problems using artificial neural networks,” *Fluid Phase Equilib.*, vol. 490, pp. 39–47, 2019.
- [18] N. H. Kasmuri, S. K. Kamarudin, S. R. S. Abdullah, H. A. Hasan, and A. M. Som, “Integrated advanced nonlinear neural network-simulink control system for production of bio-methanol from sugar cane bagasse via pyrolysis,” *Energy*, pp. 261–272, 2019.
- [19] K. Hornik, M. Stinchcombe, and H. White, “Multilayer feedforward networks are universal approximators,” *Neural Networks*, vol. 2, no. 5, pp. 359–366, 1989.
- [20] J. Hilera and V. Martínez, *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*, no. January, 1995.
- [21] A. Drud, “CONOPT: A GRG code for large sparse dynamic nonlinear optimization problems,” *Math. Program.*, vol. 31, no. 2, pp. 153–191, 1985.
- [22] A. S. Drud, “CONOPT -- A Large-Scale GRG Code,” *ORSA J. Comput.*, vol. 6, no. 2, pp. 207–216, 1994.
- [23] S. A. Channiwala and P. P. Parikh, “A unified correlation for estimating HHV of solid, liquid and gaseous fuels,” *Fuel*, vol. 81, no. 8, pp. 1051–1063, 2002.
- [24] C. Sheng and J. L. T. Azevedo, “Estimating the higher heating value of biomass fuels from basic analysis data,” *Biomass and Bioenergy*, vol. 28, no. 5, pp. 499–507, 2005.
- [25] L. Jiménez and F. González, “Study of the physical and chemical properties of lignocellulosic residues with a view to the production of fuels,” *Fuel*, vol. 70, no. 8, pp. 947–950, 1991.
- Recibido:** 22 de marzo de 2019
- Aceptado:** 28 de junio de 2019