

MODELADO MATEMÁTICO DE LA PIRÓLISIS DE RESIDUOS SÓLIDOS OLIVÍCOLAS

Mansilla, A.M. ; Bálsamo, N.F. ; Álvarez, D.M. ; Crivello, M.E.

Centro de Investigación y Tecnología Química, CONICET, UTN, FRC, Córdoba, Argentina.

ayelenmansilla12@gmail.com – 71900@quimica.frc.utn.edu.ar

Resumen

La industria olivícola es una actividad social y económica clave en la región noroeste de Córdoba. Ésta genera importantes cantidades de biomasa residual que se puede transformar en moléculas plataforma, de mayor valor agregado, mediante pirólisis. La pirólisis consiste en la carbonización en ausencia de oxígeno. El objetivo de este trabajo es utilizar Redes Neuronales Artificiales para obtener un modelo matemático que permita reproducir el proceso de pirólisis que transforma a los carozos de aceitunas en biolíquidos y biocarbón. Se desarrolló una red con algoritmo *backpropagation*. Para su entrenamiento se utilizó un conjunto predefinido de datos entrada/salida considerados como referencia del proceso; se utilizaron la temperatura y porcentajes de biocarbón obtenidos experimentalmente, como datos de entrada y los porcentajes de biolíquido, como salida. El algoritmo comparó el resultado obtenido con los valores que se desean obtener y así calculó un valor de error. El error se transmite hacia atrás, partiendo de la capa de salida hacia todas las capas intermedias que contribuyen directamente a ella. La red obtenida se estructuró con 5 neuronas en la capa oculta. El menor error y mayor índice de correlación entre respuestas reales y predichas fueron $3,3296 \times 10^{-7}$ y 1, respectivamente. A partir del desarrollo de modelos matemáticos se pretende proyectar la evolución de la pirólisis en distintas condiciones de operación. Esto es de interés, dado que permite predecir el rendimiento de la reacción con la consecuente disminución de tiempos y costos en ensayos experimentales.

Abstract

The olive industry is a key social and economic activity in the northwest region of Córdoba. This generates significant amounts of residual biomass that can be transformed into platform molecules, with greater added value, through pyrolysis. This consists of carbonization in the absence of oxygen. The objective of this work is to use Artificial Neural Networks to obtain a mathematical model that allows to reproduce the pyrolysis process that transforms olive pits into bioliquids and biochar. A network with backpropagation algorithm was developed. For their training, a predefined set of input / output data considered as a process reference was used; temperature and percentages of biochar obtained experimentally were used as input data and the percentages of bioliquid, as output. The result obtained by the algorithm was compared with the values to be obtained and an error was calculated. The error was transmitted backwards, starting from the output layer towards all the intermediate layers that directly to it. The network obtained was structured with 5 neurons in the hidden layer. The lowest error and highest correlation index between real and predicted responses were 3.3296×10^{-7} and 1. From the development of mathematical models, it is intended to project the evolution of pyrolysis under different operating conditions. This is of interest, since it allows predicting the performance of the reaction with the consequent reduction in times and costs in experimental tests.

Palabras clave: Biomasa Residual, Aceitunas Verdes, Redes Neuronales Artificiales, Backpropagation.

INTRODUCCIÓN

La pirólisis convencional y catalítica de biomasa, ha sido de gran interés, dado que permite obtener combustibles y otros productos químicos a partir de fuentes renovables. [1].

La biomasa residual de la industria olivícola se constituye de relevantes cantidades de lignina, celulosa y hemicelulosa [2]. Estas macromoléculas orgánicas se transforman durante el proceso de pirólisis y de allí se obtienen biolíquidos (*bio-oils*) y biocarbones (*bio-char*), como productos que pueden ser revalorizados. [3].

Las Redes Neuronales Artificiales (RNA) son herramientas matemáticas útiles para modelar diferentes procesos [4]. Esto permite simularlos y predecirlos sin el requerimiento de nuevas experimentaciones.

Las redes se componen de capas de nodos interconectados entre sí, que imitan las neuronas biológicas del cerebro humano y reproducen su comportamiento. Pueden ser de entrada, intermedias o salida.

El proceso de armado de una red neuronal consta de dos etapas: aprendizaje y validación, a partir de la cual se corrobora su capacidad de predicción.

Durante el entrenamiento, el algoritmo neuronal tiende a minimizar los errores entre los valores deseados y los obtenidos experimentalmente mediante una técnica de optimización numérica llamada gradiente descendente. Éste se obtiene de la regla delta, la cual modifica los pesos a fin de localizar el punto en el espacio de pesos donde se encuentra el mínimo global de la superficie [5]. Esto se puede llevar adelante considerando parámetros de aprendizaje ajustables como la tasa de aprendizaje y el coeficiente *momentum*, el cual logra que la red ignore los mínimos locales, en la superficie del error. El entrenamiento termina cuando la red aprende el objetivo específico preestablecido o cuando la salida se acerca a la deseada con el mínimo de error posible [6].

El objetivo de este trabajo es el desarrollo de una RNA capaz de reproducir el proceso

pirolítico de obtención de biolíquidos y biocarbones, a partir de los residuos sólidos provenientes de la industria olivícola.

DESARROLLO

El proceso de transformación del residuo sólido de aceituna verde se llevó adelante mediante pirólisis a temperaturas de 300, 350, 400 y 450 °C, con previo acondicionamiento de tamaño y humedad de la muestra. Se pesaron los carozos constituyentes de la biomasa y luego se determinaron los porcentajes de biolíquidos y biocarbones generados. A continuación se detallan estos valores en la tabla 1:

Tabla 1: Porcentajes de Biolíquidos y Biocarbones a Temperaturas de operación.

Temperaturas (°C)	Biolíquidos (%)	Biocarbones (%)
300	7,5972	45,7825
350	15,8724	37,7511
400	15,9525	36,0651
450	16,7133	31,8872

La red neuronal se desarrolló bajo el algoritmo *backpropagation*. Para el entrenamiento se consideraron como datos de entrada, las temperaturas de trabajo y porcentajes de biocarbones. De salida, se consideraron los porcentajes correspondientes de biolíquidos. Se realizaron interpolaciones de los datos experimentales mediante splines, con el fin de aportar más datos al proceso de creación de la red.

Se empleó una función cúbica para incluir y representar la evolución de la tendencia relativa al porcentaje de los líquidos obtenidos a las distintas temperaturas (ecuación 2, figura 1).

$$y = 1,1834 * 10^5 x^3 - 0,014065 x^2 + 5,5504 x - 711,2 \quad (2)$$

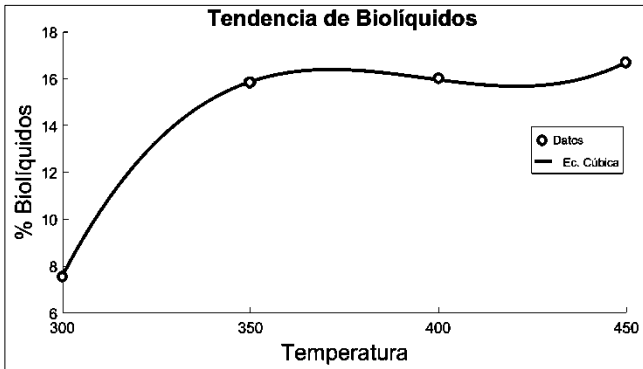


Figura 1: Función cúbica de Biolíquidos.

La norma de residuos, fue de $6,8551 \times 10^{-13}$ lo que indica una buena bondad del ajuste.

En tanto la función determinada para los biocarbones fue (ecuación 3, figura 2):

$$y = -1,1783 \times 10^{-5}x^3 + 0,0136x^2 - 5,2865x + 722,13 \quad (3)$$

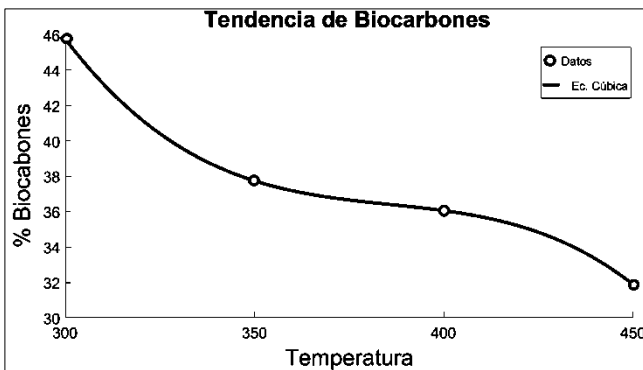


Figura 2: Función cúbica de Biocarbones

En este caso, se observó buena aproximación de la función, al igual que en el caso anterior, evidenciando una norma de residuos de $5,4379 \times 10^{-13}$.

La aplicación dividió los datos de entrada y salida en tres: 70% se utilizaron para el entrenamiento de la red, 15% para su validación y el 15% restante para evaluar la capacidad de predicción del modelo.

En todos los ensayos, para evaluar los resultados de la red, se empleó el menor error cuadrático (*Mean Squared Error-MSE*, ecuación 4) y mayor índice de correlación (R), la similitud en la evolución los errores de validación y simulación y la inexistencia de sobre-aprendizaje de las redes.

$$MSE = \frac{1}{n} \sum_{j=1}^p (Y_j^t - Y_j)^2 \quad (4)$$

Donde p es el número de entrenamiento, Y los valores predichos e Y^t los experimentales.

Se probaron varias configuraciones de RNA, considerando variaciones de funciones y cantidad de neuronas en la capa oculta.

La red neuronal que demostró mejor aproximación fue creada mediante una capa oculta con 5 neuronas con función de transferencia sigmoidea, seguida por otra de salida con una neurona, con lineal. (Figura 3). La función de transferencia sigmoidea (Figura 4) es continua, no decreciente y derivable, lo que confiere la no linealidad del modelo pirolítico. [5] [7].




Figura 3: Estructura de la RNA




Figura 4: Función sigmoidea

En la figura 5 (a-b) se observan la evolución de los errores y de los R en el entrenamiento, validación y test de la red creada. Tal como se puede observar, esta R es 1. Lo que se condice con el valor de error obtenido de $3,3296 \times 10^{-7}$.




Figura 5: a) Evolución de los MSE durante el entrenamiento, validación y simulación de las RNA con función sigmoidea y lineal con 5 neuronas.

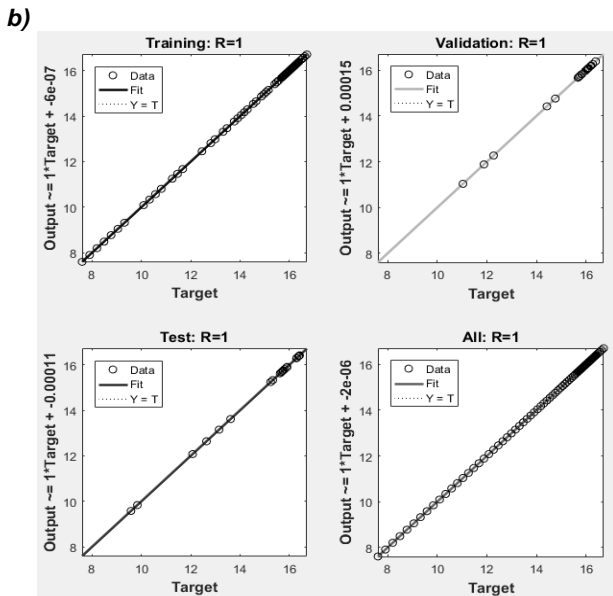


Figura 5: b) Evolución de los R durante el entrenamiento, validación y simulación de las RNA con función sigmoidea y lineal con 5 neuronas.

CONCLUSIONES

La red neuronal propuesta se entrena y valida posibilitando la obtención de modelos capaces de explicar matemáticamente la pirólisis de los residuos sólidos de aceitunas. Para completar este estudio, sería de interés evaluar el desempeño del modelo con datos experimentales como podrían ser los obtenidos a temperaturas distintas a las consideradas.

El desarrollo de modelos matemáticos es de interés por consecuente disminución de tiempos y costos en ensayos experimentales.

AGRADECIMIENTOS

Al financiamiento otorgado a través de la beca EVC-CIN y de la Universidad Tecnológica Nacional. A mis directoras de Beca EVC-CIN.

REFERENCIAS

[1] Lin Mei Wu, Chun Hui Zhou, Dong Shen Tong, Wei Hua Yu. (2014). Catalytic Thermochemical Processes for Biomass Conversion to Biofuels and Chemicals. En Bioenergy Research: Advances and Applications (243-254). USA.

[2] Li Li, Jack S. Rowbotham H. Christopher Greenwell. Philip W. Dyer. (2013). An Introduction to Pyrolysis and Catalytic Pyrolysis:

Versatile Techniques for Biomass Conversion. En New and Future Developments in Catalysis (173-208). UK.

[3] François Xavier Collard. Joël Blin. (2014). A review on pyrolysis of biomass constituents: Mechanisms and composition of the products obtained from the conversion of cellulose, hemicelluloses and lignin. En Renewable and Sustainable Energy Reviews (594-608).

[4] Dipal Baruah, D.C. Baruah, M.K. Hazarika. Artificial neural network based modeling of biomass gasification in fixed bed downdraft gasifiers. Biomass and Bioenergy 98 (2017) 264-271.

[5] Y.-S. Parque, S. Lek. (2016). Artificial Neural Networks: Multilayer Perceptron for Ecological Modeling. En Developments in Environmental Modelling (123-140).

[6] Kiran M. Desai, Shrikant A. Survase, Parag S. Saudagar, S.S. Lele, Rekha S. Singhal. Comparison of artificial neural network (ANN) and response surfacemethodology (RSM) in fermentation media optimization: Case studyof fermentative production of scleroglucan. Biochemical Engineering Journal 41 (2008) 266–273.

[7] C. Hervás-Martínez, R.M García-Gimeno, A.C. Martínez-Estudillo, F.J. Martínez-Estudillo, G. Zurera-Cosano. Improving Microbial Growth Prediction By Product Unit Neural Networks. Journal of food science vol 71 (2006) 31-38.

[8] Zoltan Kalman Nagy. Model based control of a yeast fermentation bioreactor using optimally designed artificial neural networks. Chemical Engineering Journal vol 127 (2007) 95-109.