

Aplicación de redes neuronales artificiales: predicción de rendimientos del proceso de extracción de aceite de canola



AUTORES: SÁNCHEZ RAMIRO J.⁽¹⁾; ZÁRATE VALERIA⁽¹⁾; FERNÁNDEZ MARÍA B.^(1,2*); NOLASCO SUSANA M.^(1*)
E-mail: mbfernan@fio.unicen.edu.ar; snolasco@fio.unicen.edu.ar

⁽¹⁾ Núcleo TECSE – Facultad Ingeniería (Universidad Nacional del Centro de la Provincia de Buenos Aires) Av. Del Valle 5737 – Olavarría – Argentina

⁽²⁾ CIFICEN (Universidad Nacional del Centro de la Provincia de Buenos Aires - CONICET) Pinto 399 – Tandil – Argentina

Trabajo original preparado especialmente para A&G.

Resumen / Abstract

Las Redes Neuronales Artificiales (RNA) son una herramienta de inteligencia artificial utilizada en amplios campos del conocimiento. Una de sus aplicaciones estudiadas en la actualidad es la capacidad de modelar y realizar predicciones en sistemas complejos. En este trabajo se utilizó una RNA *feedforward* perceptron multicapa para la predicción de rendimientos de extracción de aceite de canola considerando 3 variables de entrada: tiempo de extracción, temperatura y contenido total de aceite del grano, los cuales se contrastaron con datos experimentales. El entrenamiento y ajuste de la red se realizó con datos experimentales de granos de canola de distintos contenidos de aceite total al seleccionado para la predicción. Generalmente para los rendimientos simulados se obtuvieron diferencias con respecto a los datos experimentales de 2 % b.s. y dentro del rango del error de medición experimental. Estos resultados muestran la eficacia y potencialidad del uso de las redes neuronales para la predicción del comportamiento de un proceso de extracción de aceite a partir de parámetros característicos de la materia prima y el proceso.

The Artificial Neural Networks (ANN) are artificial intelligence tools used in broad fields of knowledge, we studied applications are their ability to model and make predictions in complex systems. This paper used an RNA feedforward multilayer perceptron for predicting yields of canola oil extraction considering 3 input variables: extraction time, temperature and total oil content of the grain, which were compared with experimental data. Training and network setting was performed with experimental data from grains contents from different canola oil to total selected for prediction. Generally for differences simulated yields were obtained with respect to the experimental data of 2% b.s. and within the range of experimental error measurement. These results show the effectiveness and potential use of neural networks for predicting the behavior of a process of extracting oil from characteristic parameters of the byproducts and process.

Palabras claves / Key words

Redes neuronales artificiales; predicción; extracción de aceite; canola.

Artificial neural networks; prediction; extraction of oil; canola.

• Introducción

Las Redes Neuronales Artificiales (RNA) son técnicas estadísticas computacionales de modelado con elevada

potencia inspiradas en la forma en la que las neuronas biológicas desarrollan las funciones de aprendizaje y memoria. Presentan varias ventajas sobre las técnicas de modelado convencionales ya

que son capaces de modelar sin necesidad de suposiciones sobre la naturaleza de los mecanismos fenomenológicos, de comprender la base matemática del problema que subyace en el proceso y de

aprender relaciones lineales y no lineales entre las variables a partir de un conjunto de ejemplos (Fathi *et al.*, 2009). Las unidades fundamentales de las RNA son las neuronas (análogas a las neuronas biológicas) y los pesos, conexiones ponderadas comparables a las sinapsis en un sistema biológico. A partir de cálculos simultáneos en paralelo de sus elementos, una RNA es capaz de aprender a partir de ejemplos y generalizar permitiendo abordar distintos problemas; aún cuando los datos sean incompletos o contengan errores (Rafiq *et al.*, 2001). Se destaca la capacidad de predicción de las RNA con elevada precisión y la posibilidad de alimentación continua con nuevos datos que perfeccionan el modelo, permitiendo reducir el error de predicción a niveles relacionados con el error de medición en sí. La potencialidad de esta herramienta ofrece la posibilidad de estudiar situaciones específicas dentro de la industria, una correcta utilización de una red neuronal optimizada, y una adecuada selección de variables permitiría predecir el comportamiento de la materia prima durante el proceso a partir de parámetros característicos. Como ejemplo del alcance de esta herramienta, en este trabajo se utilizó una RNA para predecir los rendimientos de extracción de aceite de canola en un sistema determinado, a distintos tiempos y temperaturas, conociendo sólo el contenido total de aceite de la mues-

tra a estudiar; y tomando como ejemplos para el acondicionamiento de la RNA datos obtenidos de extracciones de aceite de canola de partidas con diferentes contenidos de aceite total.

• **Materiales y métodos**

Extracciones

Se utilizaron 3 partidas de granos de canola con distinto contenido de aceite total (40,6±0,6; 45,2±0,9 y 46,3±0,3 %bs; determinaciones realizadas según norma IUPAC 1.122, IUPAC, 1992), para cada partida se molieron las muestras en un molino de cuchillas y se seleccionó un rango de tamaño de partículas 0,425-1 mm en un tamiz vibratorio. Posteriormente la extracción del aceite por solvente (hexano) se realizó en un sistema batch agitado a temperatura constante (25, 40, 50 y 60 °C) para distintos tiempos de extracción (5-1080 minutos). La mezcla (aceite + solvente) se separó mediante centrifugación (14069 G, 5 minutos; equipo Thermo SCIENTIFIC, SORVALL LEGEND X1) y el solvente se evaporó empleando un evaporador rotatorio (R-3000 Büchi). Los ensayos se realizaron por duplicado, el rendimiento de extracción se determinó expresándose como porcentaje de aceite en base seca (%bs).

Red Neuronal Artificial

A través del Software MATLAB R2013b, se utilizó una red perceptrón *feedforward* multicapa (MLP, por sus siglas en inglés) totalmente interconectada. La estructura perceptrón multicapa es una de las más comunes (Rafiq *et al.*, 2001; Fathi *et al.*, 2009; Shokri *et al.*, 2011 Ramzi *et al.*, 2015), consta de una o más entradas que representan las variables independientes, una capa de salida con neuronas que representan las variables dependientes y una o más capas ocultas (Hagan *et al.*, 1996) que contiene neuronas para ayudar a capturar la no linealidad en el sistema. La capa oculta correlaciona las entradas *x* con las salidas *y*, a través de una serie de pesos *w* interconectados matemáticamente (Shokri *et al.*, 2011):

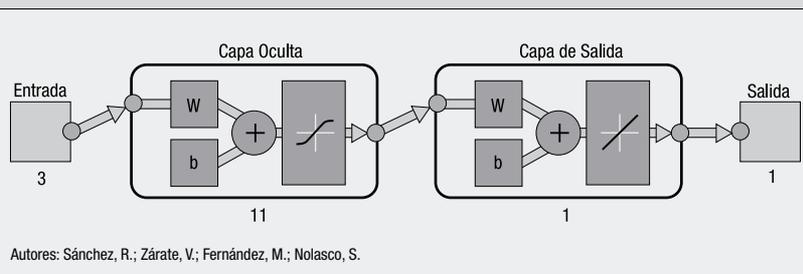
$$y_i = f\left(\sum_{j=1}^n w_{ij}x_j + b_i\right) \quad (1)$$

Donde *w_{ij}* es el peso del *i*-ésimo vector de entrada que es conectado a la *j*-ésima neurona; *n* es el número de entradas a la neurona; *b_i* es el umbral asociado con la neurona *j*-ésimo, y *f* es la función de activación que le confiere el comportamiento no lineal a la neurona. La función de activación puede ser lineal o no lineal (tangente hiperbólica o comúnmente función sigmoide) dependiendo de la topología de la red. Con el fin de asegurar un modelado exitoso, se deben considerar dos factores importantes. En primer lugar, el número de capas y en segundo lugar el número de neuronas en cada capa oculta. Puesto que muchos problemas prácticos de modelado con redes neuronales pueden resolverse con una capa oculta (Rafiq *et al.*, 2001), se utilizó una RNA con dos capas (una capa oculta y una capa de salida), tomando como función de activación la tangente hiperbólica para la capa oculta y una función lineal para la capa de salida. Se utilizó un algoritmo de retro propagación (*Backpropagation*, BP) como algoritmo de entrenamiento supervisado, ya que proporciona un ajuste rápido

Tabla 1 - Selección de datos para entrenamiento, validación y predicción de la RNA.

		Contenido de aceite (%bs)	Temperatura (°C)	Tiempo (min)	Datos totales
Entrenamiento y validación	Canola 1	40,6	25; 40; 50 y 60	5-1080	59
	Canola 2	46,4	25; 40; 50 y 60	5-1080	
Predicción	Canola 3	45,2	40; 50 y 60	5-1080	21

Figura 1. Diagrama esquemático del modelo óptimo de RNA *feedforward* multicapa encontrado.



y es fácilmente aplicable (Shokri *et al.*, 2011), y para el ajuste de los pesos se empleó el algoritmo Levenberg-Marquardt. Los parámetros de entrada de la red fueron tiempo, temperatura y contenido total de aceite, y el rendimiento de extracción de aceite en porcentaje en base seca (%bs) como respuesta de salida. Los datos de rendimientos fueron separados en dos set, el primero (datos de entrenamiento y validación de la red) se utilizó para ajustar y optimizar los parámetros de la RNA, y un segundo set de datos se utilizó para evaluar la capacidad de predicción de la misma. En la Tabla 1 se especifica la selección de datos.

• Resultados y discusión

La cantidad óptima de neuronas en la capa oculta se determinó minimizando la diferencia entre los valores experimentales y los predichos por la red para el grupo de entrenamiento y validación. En la Figura 1 se muestra un esquema de la RNA seleccionada como óptima para el modelado del sistema estudiado. La misma se compone de 3 entradas (Tiempo, Temperatura, Contenido de aceite total), 1 salida (Rendimiento de extracción) y 11 neuronas en una capa oculta. Los rendimientos predichos por la red, los rendimientos experimentales y los errores, como diferencia entre los valores experimentales medidos y los predichos por la RNA, se muestra en la Figura 2.

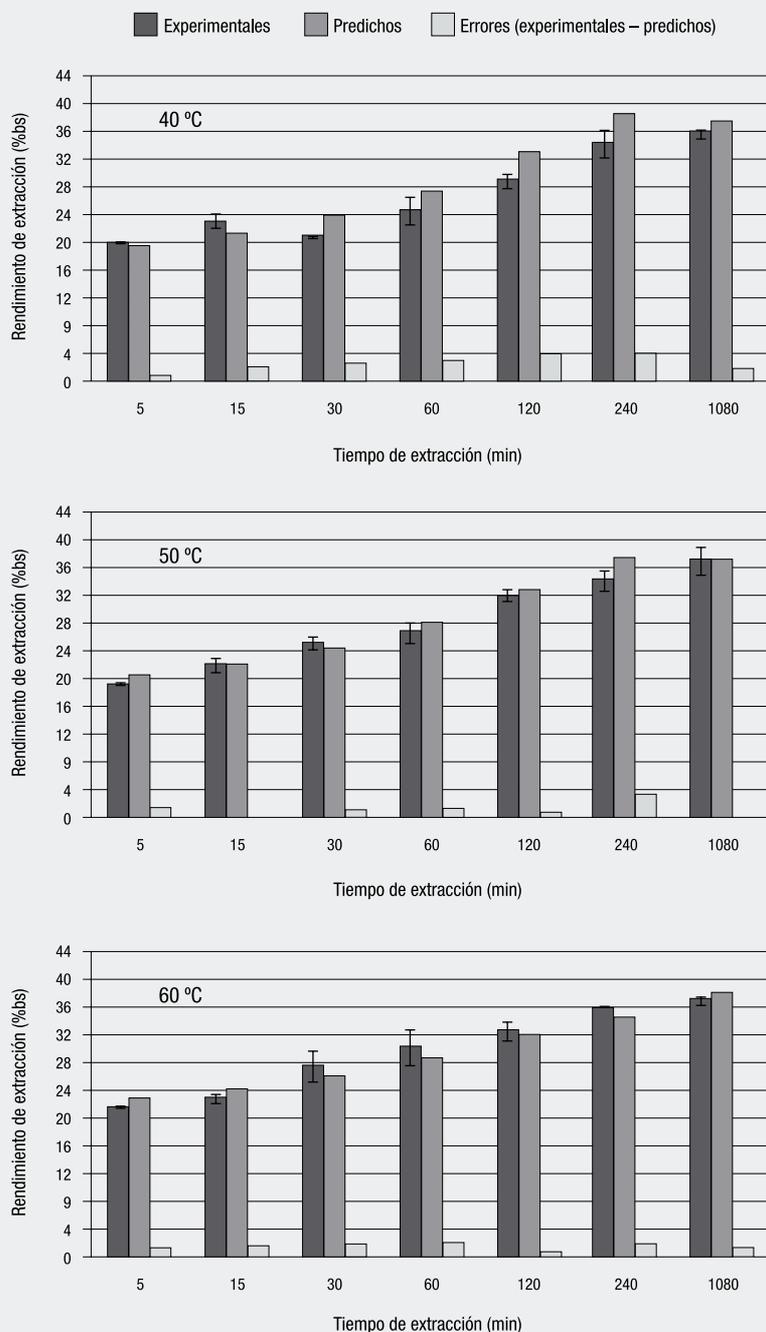
En ningún caso la diferencia entre los rendimientos experimentales y simulados supera el 4 % aceite (b.s.); mientras que el 71% de los datos simulados presenta una diferencia por debajo de 2 % (b.s.) de aceite. Cabe mencionar que en muchos casos la diferencia de predicción fue inferior o igual al error asociado a la metodología de medición del rendimiento experimental. Las redes neuronales artificiales presentan mayor precisión de predicción para valores intermedios de temperatura con respecto al rango de entrenamiento; lo que se evidencia en los resultados obtenidos para 50 °C, los

cuales presentaron errores inferiores con respecto a las temperaturas restantes (40 y 60 °C).

Cabe destacar que la eficiencia de una RNA depende de la existencia de alguna relación entre la/s respuestas a estudiar

y las variables seleccionadas, por lo cual la correcta selección de las mismas es un aspecto fundamental. Por otro lado la precisión del modelo aumenta al incrementar la alimentación de datos, la red “aprende” de forma continua sobre lo ya aprendido. En este contexto, la utiliza-

Figura 2 - Rendimientos de extracción experimentales y predichos por la RNA.



Autores: Sánchez, R.; Zárate, V.; Fernández, M.; Nolasco, S.

ción de ésta herramienta a nivel industrial es promisorio teniendo en cuenta el funcionamiento de un proceso industrial donde pueden recopilarse datos de proceso continuamente.

• Conclusiones

Los resultados obtenidos muestran la capacidad de las redes neuronales artificiales para modelar y predecir variables de proceso; y la potencialidad de su utilización para simular el comportamiento de la materia prima ante un determinado proceso conociendo características de fácil y económica determinación a escala de laboratorio, ya que a medida que aumenta el número de datos de entrenamiento se incrementa la precisión de la predicción. A su vez, se pudo observar la capacidad de la red para captar la relación existente entre las variables, demostrando la potencialidad del uso

de esta herramienta de inteligencia artificial para el modelado y la predicción de procesos complejos que dependen de múltiples variables a partir de un conjunto de datos experimentales, así como su capacidad de captar el comportamiento del fenómeno aún procesando datos con ruido.

Referencias

- Fathi, M., Mohebbi, M., Razavi, S. M. A. (2011). Application of image analysis and artificial neural network to predict mass transfer kinetics and color changes of osmotically dehydrated kiwifruit. *Food and Bioprocess Technology*, 4(8), 1356-1367.
- Rafiq, M. Y., Bugmann, G., Easterbrook, D. J. (2001). Neural network design for engineering applications. *Computers & Structures*, 79(17), 1541-1552.
- IUPAC. (1992). *Standard Methods for the Analysis of Oils, Fats and Derivatives*, 7th edn. C. Paquot and A. Hautfenne, International Union of Pure and Applied Chemistry, Blackwell Scientific. Oxford.

- Shokri, A., Hatami, T., Khamforoush, M. (2011). Near critical carbon dioxide extraction of Anise (*Pimpinella Anisum* L.) seed: Mathematical and artificial neural network modeling. *The Journal of Supercritical Fluids*, 58(1), 49-57.
- Ramzi, M., Kashaninejad, M., Salehi, F., Mahoonak, A. R. S., Razavi, S. M. A. (2015). Modeling of rheological behavior of honey using genetic algorithm-artificial neural network and adaptive neuro-fuzzy inference system. *Food Bioscience*, 9, 60-67.
- Hagan, M. T., Demuth, H. B., Beale, M. H. *Neural network design*, 1996. PWS Pub, Boston, London.

• Reconocimientos

Los autores agradecen el financiamiento a la Facultad de Ingeniería (Universidad Nacional del Centro de la Provincia de Buenos Aires), a CONICET y a la ANPCyT (Agencia Nacional de Promoción Científica y Tecnológica). También agradecen en forma especial AL HIGH TECH S.R.L. (Argentina) por donar la canola utilizada durante este trabajo ■