

Red neuronal con entrenamiento dinámico para simulación de un sistema de intercambiadores de calor

Neural network with dynamic training for simulation of a heat exchangers system

Andres Adrian Sánchez Escalona^{1,*}; Ever Góngora Leyva¹; Yanan Camaraza Medina²

¹ Instituto Superior Minero Metalúrgico. Moa, Holguín, Cuba.

² Universidad Central Marta Abreu de las Villas, Villa Clara, Cuba

*Autor de correspondencia: sanchezescalona88@gmail.com

Recibido: 30 de mayo del 2019

Aprobado: 23 de septiembre 2019

Licencia de uso y distribución Creative Commons Reconocimiento-No Comercial 4.0 Internacional



RESUMEN/ABSTRACT

Esta investigación propuso un modelo de red neuronal artificial con entrenamiento dinámico para predecir las temperaturas de salida de ambos fluidos en un sistema de intercambiadores de calor para monoetanolamina, realizando el entrenamiento, validación y pruebas con 31 680 juegos de datos obtenidos a través del método de experimentación pasiva. Con el perceptrón multicapa 4-3-2 se lograron correlaciones superiores al 98,76 %, y se corroboró que el entrenamiento dinámico proporciona respuestas más precisas que el entrenamiento único. Aplicando el primer enfoque se calcularon errores absolutos promedio de 0,419 y 0,372 K (para las variables temperatura de salida de la amina rica y de la amina pobre, respectivamente), comparados con 2,214 y 1,181 K para el segundo. Tales desviaciones no tienen una implicación significativa en el proceso tecnológico examinado, por lo que el modelo se considera apropiado para simular el desempeño de los intercambiadores de calor objeto de estudio.

Palabras clave: intercambiador de calor; monoetanolamina; red neuronal artificial; modelación; entrenamiento.

This research proposed an artificial neural network model with dynamic training in order to predict both fluids outlet temperatures on a monoethanolamine heat exchangers system, doing the training, validation and testing with 31 680 data points gathered through the passive experimentation method. The 4-3-2 multilayer perceptron achieved correlations above 98.76 %, and it was corroborated that dynamic training strategy provided more accurate results than single training. Mean absolute errors of 0.419 and 0.372 K were obtained when applying the first approach (for rich amine and lean amine outlet temperatures as output variables, respectively), as compared to 2.214 and 1.181 K when implementing the second one. Since calculated deviations have no significant implication on the technological process under analysis, proposed model is considered appropriate for simulation of the studied heat exchangers performance.

Key words: heat exchange; monoethanolamine; artificial neural network; modeling; training.

INTRODUCCIÓN

En la actualidad la modelación y simulación son importantes para el desarrollo y control de los procesos productivos, y continuarán su progreso en paralelo con los nuevos avances de la ciencia. Está demostrado que son herramientas de ingeniería eficaces para el estudio, perfeccionamiento y optimización de diferentes sistemas.

Como citar este artículo:

Andres Adrian Sánchez Escalona, *et al.* Red neuronal con entrenamiento dinámico para simulación de un sistema de intercambiadores de calor. 2019, vol. 41, n.1, enero/abril. ISSN: 1815-5901.

Sitio de la revista: <http://rie.cujae.edu.cu/index.php/RIE>

En este ámbito, las redes neuronales artificiales (RNA) se han empleado exitosamente en varias aplicaciones de transferencia energética y en el análisis de intercambiadores de calor, ya que después de entrenadas constituyen una vía rápida y confiable para predecir el desempeño de los procesos de intercambio térmico. Otras ventajas son su simpleza, versatilidad, aproximación precisa de procesos complejos no lineales y enfoque de “caja negra”, o sea, no precisan de un conocimiento detallado del sistema que se analiza [1-2]. Varios investigadores han utilizado RNA para la modelación de intercambiadores de calor de tubos y coraza, motivados por su uso industrial difundido y como una alternativa a los métodos tradicionales de evaluación y diseño, que están basados en varias simplificaciones y correlaciones empíricas [2-3]. Los estudios iniciales se enfocaron en optimizar la estructura y tamaño de la red neuronal para minimizar los errores en las predicciones, utilizando datos experimentales obtenidos a escala de laboratorio. Tal es el caso de las investigaciones desarrolladas por Pandharipande *et al.* [4], Mandavgane y Pandharipande [5] y Xie *et al.* [6], donde el entrenamiento, validación y pruebas de las configuraciones de red analizadas se realizaron con una cantidad moderada de datos.

Otros autores lograron incrementar el número de datos usado para la modelación, generando los mismos a partir de referencias bibliográficas. Moghadassi *et al.* [7], establecieron 22 redes neuronales para pronosticar diferentes propiedades de los fluidos y parámetros específicos de los intercambiadores de calor, empleando información extraída del Kern (Procesos de Transferencia de Calor), el Perry (*Chemical Engineers' Handbook*) y la norma TEMA (*Standards of the Tubular Exchanger Manufacturers Association*). Como resultado, este enfoque se limita a los fluidos y configuraciones de los equipos que fueron estudiados. Por otra parte, Iyengar [8], llevó a cabo el análisis térmico de un intercambiador de calor con un pase por la coraza y dos pases por los tubos, tomando los parámetros de diseño de un caso de estudio previamente publicado. En lugar de realizar mediciones de las variables de operación, en la investigación se utilizaron las correlaciones del Método de Kern para generar 1 080 juegos de datos. El desarrollo creciente de los autómatas programables (PLC) y los sistemas de Supervisión, Control y Adquisición de Datos (SCADA) permitió a otros investigadores realizar sus estudios a escala industrial. Jasim [9], predijo las temperaturas de salida de los fluidos en un enfriador de aire en línea, ejecutando el entrenamiento, validación y pruebas de las RNA con 200 datos experimentales recopilados en diferentes días de operación. Sundaram *et al.* [10], compararon varias arquitecturas de red, empleando una base de datos de 4 000 registros facilitada por un contribuidor. Un modelo más reciente fue publicado por Mohanty [11], cuyo propósito consistió en anticipar las temperaturas de salida de ambos fluidos y la eficiencia de un intercambiador de calor industrial expuesto a la deposición de incrustaciones. De estos trabajos sólo el segundo pone en práctica una estrategia dinámica de modelación, pero no compara los resultados con el enfoque tradicional.

En la mayoría de las investigaciones precedentes los datos utilizados para la modelación y la simulación se tomaron de la literatura clásica, o a partir de instalaciones experimentales montadas en un laboratorio. Este hecho, unido a la cantidad limitada de datos para entrenamiento y validación de las redes, no ha permitido tener en cuenta la influencia de los cambios en las perturbaciones sobre la precisión de los resultados calculados por el modelo. Tampoco se ha valorado la pérdida de generalización de las RNA cuando se realizan pronósticos a mediano y largo plazo en instalaciones industriales. Además de cubrir en cierta medida las brechas mencionadas, el propósito del presente trabajo es proponer una red neuronal con entrenamiento dinámico para la simulación de un sistema de intercambiadores de calor monoetanolamina-monoetanolamina, que prediga las temperaturas de salida de los fluidos minimizando los índices de error en la respuesta. El resto del artículo está organizado de la siguiente forma: en la segunda sección se describen los materiales y métodos, haciendo énfasis el procedimiento de obtención de los datos experimentales y en la metodología de modelación implementada; en la tercera sección se muestran los principales resultados, argumentando los mismos y comparando la estrategia de entrenamiento dinámico de la RNA con el método tradicional; en la cuarta sección se incluyen las conclusiones fundamentales planteadas durante el presente trabajo.

MATERIALES Y MÉTODOS

Descripción de la instalación y técnica experimental

Los intercambiadores de calor objeto de estudio forman parte de un circuito estándar de regeneración de monoetanolamina (MEA), instalado en una planta industrial para producción de hidrógeno. El sistema se usa para purificar el gas generado, ya que la solución de amina tiene la peculiaridad de absorber el dióxido de carbono cuando esta fría y desprenderlo al calentarse. En estas instalaciones es importante pronosticar el desempeño de los equipos de intercambio térmico, ya que sus parámetros de operación informan sobre la eficiencia de separación del dióxido de carbono y permiten controlar el proceso.

Como se observa en el diagrama (figura 1), el dióxido de carbono que contiene la corriente principal del proceso se separa en el absorbedor a contracorriente con la solución de MEA, posibilitando que el dihidrógeno gaseoso purificado salga por la parte superior del recipiente. Esta solución de amina rica (que contiene el dióxido de carbono absorbido) se bombea a través de los intercambiadores de calor MEA-MEA para incrementar su temperatura por encima de 379 K antes de entrar al reactivador. La amina pobre ya regenerada (que expulso el dióxido de carbono), con una temperatura promedio de 411 K, se bombea nuevamente hacia el absorbedor. En su trayecto de retorno se emplea para calentar la amina rica, y luego se hace fluir a través los intercambiadores MEA-agua para disminuir su temperatura hasta 313 K [12].

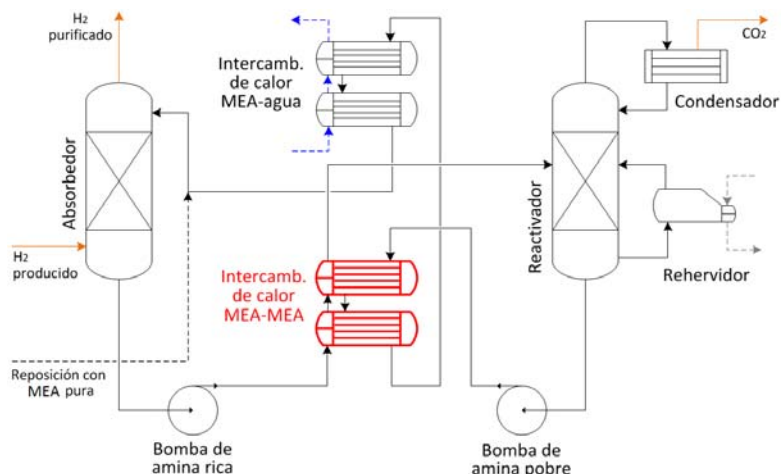


Fig. 1. Diagrama del sistema de regeneración de MEA.

Los intercambiadores de calor MEA-MEA son equipos de tubos y doble coraza (dos unidades en serie), con aislamiento térmico exterior. Según designación de la norma TEMA su nomenclatura es “BES”. En cada intercambiador de calor la amina rica fluye del lado de los tubos, en dos pases, mientras que la amina pobre circula por la coraza, en un solo pase. La coraza, cabezales, deflectores y las boquillas se construyeron de acero al carbono. Los tubos y las placas de tubos se fabricaron de acero inoxidable AISI 316. El sistema se diseñó para transferir 2 879 kW de calor, a través de un área total de 180 m². El monitoreo de las temperaturas a la salida de los intercambiadores de calor permite controlar la eficiencia del proceso, estimar el grado de incrustaciones y determinar cuándo se requiere añadir MEA pura al sistema para mantener la concentración entre 12 y 15 %.

Debido al régimen de producción ininterrumpido de la instalación se aplicó un experimento pasivo (diseño de investigación no experimental). Este procedimiento consiste en la observación y registro de las variables de entrada y salida del proceso en el régimen normal de trabajo del objeto investigado, sin la manipulación de las variables por parte del investigador. En su lugar, el control se ejerce sobre los niveles de los parámetros estudiados [13]. Utilizando un autómata programable (PLC) Siemens y un sistema de Supervisión, Control y Adquisición de Datos (SCADA) se realizaron lecturas del flujo másico de cada fluido, así como de ambas temperaturas a la entrada y la salida del sistema de intercambiadores de calor MEA-MEA. Se registraron las mediciones de 22 días consecutivos en intervalos de un minuto, obteniéndose una base de datos con 1 440 observaciones diarias y un total de 31 680 registros. Las características técnicas de los instrumentos de medición se detallan a continuación (tabla 1).

Tabla 1. Características técnicas de los instrumentos de medición

Parámetro	Instrumento primario	Transmisor	Precisión
Flujo	Sensor piezorresistivo y membrana metálica Endress+Hauser.	PMD75 Endress+Hauser incorporado.	± 0,05 %
Temperatura	Termopozos y termopar tipo K.	TMT-82 Endress+Hauser.	± 0,75 %

Metodología de la modelación y arquitectura de la RNA

Para predecir la temperatura de los fluidos a la salida del sistema de intercambiadores de calor MEA-MEA se utilizó un perceptrón multicapa asociado a un algoritmo de aprendizaje de retro-propagación del error, con los elementos del vector de entrada conectados solamente hacia adelante. Según Mohanraj *et al.* [2], esta arquitectura (*multilayer feed forward network*) es la configuración de redes neuronales más apropiada para la modelación y simulación de intercambiadores de calor. Como variables de entrada se utilizaron los parámetros operacionales que tienen un efecto notable en la respuesta. En tal sentido, las variables independientes seleccionadas fueron los flujos másicos, así como las temperaturas de entrada de la amina rica y de la amina pobre (figura 2) [3; 5].

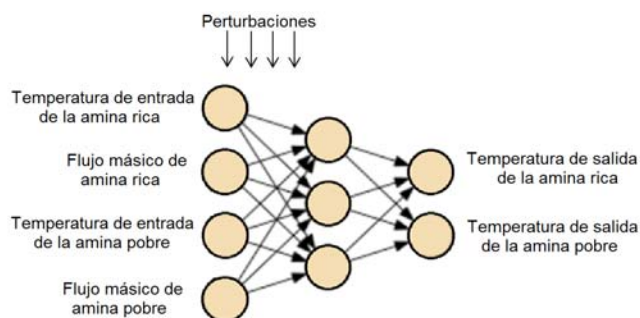


Fig. 2. Representación esquemática del modelo.

El número de neuronas en las capas de entrada y de salida se hizo coincidir con la cantidad de variables predictoras y de respuesta, respectivamente [2]. Sin embargo, la determinación del número de capas y neuronas ocultas requirió de un procedimiento más complejo. Aunque generalmente se emplea un proceso de prueba y error, en esta investigación se llevó a cabo una estrategia de crecimiento progresivo de la red, que consiste en iniciar con una estructura simple e incrementar las neuronas ocultas hasta alcanzar la precisión deseada en el pronóstico [14]. De este modo, la RNA se optimizó para una estructura 4-3-2, empleando la función de transferencia sigmoideal logística (*logsig*) en la capa oculta y de activación lineal (*purelin*) en la capa de salida. Usualmente las redes pequeñas con bajos valores en los pesos y sesgo de las neuronas generalizan mejor [14-15].

Estrategia de entrenamiento y simulación

Para establecer un criterio de comparación se analizaron dos escenarios:

1. Red neuronal con entrenamiento dinámico

Los datos experimentales correspondientes al día D , iniciando en 1, se emplearon para el entrenamiento, validación y pruebas de la RNA. Seguidamente se salvó el modelo con los pesos y sesgos de las neuronas calculados, realizando estas actividades de manera consecutiva desde $D = 1$ hasta 21. En cada ciclo se simuló el desempeño de los intercambiadores de calor para el día siguiente ($D + 1$), desde 2 hasta 22, empleando como datos de entrada los valores de las variables independientes registrados ese día y comparando el pronóstico del modelo con las mediciones realizadas en igual período para las variables de salida (figura 3a).

2. Red neuronal con entrenamiento único

Los datos experimentales correspondientes al día 1 se emplearon para el entrenamiento, validación y pruebas de la RNA. Seguidamente se salvó el modelo con los pesos y sesgos de las neuronas calculados, realizando esta actividad una sola vez. Luego se simuló el desempeño de los intercambiadores de calor para el día $D + 1$, repitiendo esta operación desde 2 hasta 22. Como datos de entrada para la simulación se utilizaron los valores de las variables independientes registrados el día $D + 1$, mientras que el pronóstico del modelo se comparó con las mediciones realizadas en igual período para las variables de salida (figura 3b).

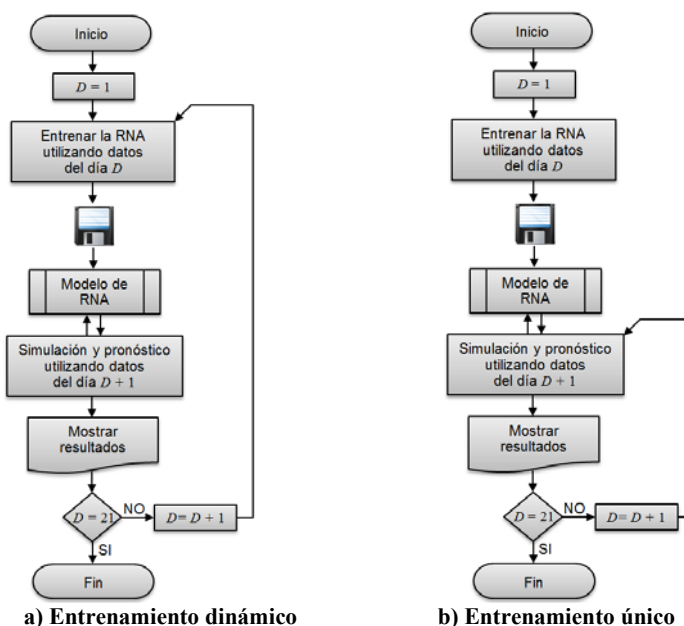


Fig. 3. Escenarios de entrenamiento y simulación implementados.

En el proceso de entrenamiento de la RNA los vectores de entrada y de salida se normalizaron dentro del rango 0 y 1, utilizando la ecuación (1), con el propósito mejorar la eficiencia del algoritmo y disminuir el tiempo de convergencia. Como función de control se empleó el error cuadrático medio, según la ecuación (2), asociada al algoritmo de aprendizaje Levenberg-Marquardt. El 60 % de los datos se utilizó para el entrenamiento, el 20 % para la validación y el otro 20 % para las pruebas, bajo la premisa de que cada juego de datos fuera representativo del total de las observaciones en el rango experimental analizado [2; 10].

$$\mathbf{Y}_{norm} = [y_i - \min(\mathbf{Y})] / [\max(\mathbf{Y}) - \min(\mathbf{Y})] \quad (1)$$

$$mse = \frac{1}{n} \cdot \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Donde: \mathbf{Y} – vector con datos primarios; \mathbf{Y}_{norm} – vector con datos normalizados; mse – error cuadrático medio; y – valor medido experimentalmente; \hat{y} – valor predicho por el modelo; n – tamaño de la muestra (total de observaciones en el rango experimental analizado).

Levenberg-Marquardt es un algoritmo numérico de optimización de segundo orden que combina las ventajas de los métodos Gauss-Newton y gradiente descendente. Por lo general, para problemas de aproximación de funciones con RNA de tamaño moderado, tiene mayor estabilidad y converge más rápido que otros algoritmos de aprendizaje. El procedimiento se fundamenta en una aproximación de la matriz Hessiana y el cálculo del gradiente a partir de la matriz Jacobiana que contiene las primeras derivadas de los errores, según se muestra en las ecuaciones (3) y (4), [7, 15].

$$\mathbf{H} = \mathbf{J}^T \mathbf{J} \quad (3)$$

$$\mathbf{g} = \mathbf{J}^T \mathbf{e} \quad (4)$$

Donde: \mathbf{H} – aproximación de la matriz Hessiana; \mathbf{g} – gradiente; \mathbf{e} – vector con los errores de la red; \mathbf{J} – matriz Jacobiana que contiene las primeras derivadas de los errores de la red con respecto a los pesos y sesgos de las neuronas, siguiendo la estructura indicada en la ecuación (5).

$$\mathbf{J} = \begin{bmatrix} \partial e_1(w) / \partial w_1 & \partial e_1(w) / \partial w_2 & \cdots & \partial e_1(w) / \partial w_n \\ \partial e_2(w) / \partial w_1 & \partial e_2(w) / \partial w_2 & \cdots & \partial e_2(w) / \partial w_n \\ \vdots & \vdots & \ddots & \vdots \\ \partial e_N(w) / \partial w_1 & \partial e_N(w) / \partial w_2 & \cdots & \partial e_N(w) / \partial w_n \end{bmatrix} \quad (5)$$

El comportamiento adaptativo del algoritmo, sustentado en la ecuación (6), es capaz de garantizar una solución óptima en la mayoría de los casos.

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{e} \quad (6)$$

Donde: \mathbf{X}_k – valores actuales de los pesos; \mathbf{X}_{k+1} – nuevos valores de los pesos calculados como función gradiente; μ – factor de ponderación de Levenberg, ajustable en cada paso del proceso de iteración.

Las etapas de modelación y simulación se efectuaron con MATLAB R2013a. Como criterios de evaluación de la calidad del pronóstico se utilizaron el coeficiente de correlación de Pearson, el error absoluto promedio y el error relativo promedio, determinados a partir de las ecuaciones (7), (8) y (9) respectivamente. Estos parámetros son indicadores apropiados para analizar el comportamiento general de los datos simulados con respecto a la recta de regresión determinada para la muestra [16,17].

$$R = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})(y_i - \bar{y})}{\left[\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2 \cdot \sum_{i=1}^n (y_i - \bar{y})^2 \right]^{1/2}} \quad (7)$$

$$\bar{E} = \frac{1}{n} \cdot \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

$$\bar{e} = \frac{1}{n} \cdot \sum_{i=1}^n (|y_i - \hat{y}_i| / y_i) \cdot 100\% \quad (9)$$

Donde: R – coeficiente de correlación de Pearson; \bar{E} – error absoluto promedio; \bar{e} – error relativo promedio.

RESULTADOS Y DISCUSIÓN

Grado de asociación entre los valores predichos y los experimentales

Al emplear el perceptrón 4-3-2 para determinar las temperaturas de la amina rica y de la amina pobre a la salida del sistema de intercambiadores de calor MEA-MEA se obtuvieron valores de las predicciones próximos a los de la respuesta esperada. Los valores calculados del coeficiente de correlación, dentro del rango 0,98761 - 0,99997, ratifican que el grado de asociación entre el pronóstico y las observaciones experimentales es confiable. Estos resultados son coherentes con los publicados por otros investigadores que utilizaron RNA para la modelación de intercambiadores de calor de tubos y coraza (tabla 2).

A pesar de la proximidad de los resultados, la red neuronal con entrenamiento dinámico reportó valores de correlación superiores a los logrados mediante el entrenamiento único para la mayoría de las predicciones (figura 4).

Tabla 2. Comparación de los resultados con otras investigaciones.

Investigación	Estructura del perceptrón	Correlación obtenida
Pandharipande <i>et al.</i> [4]	4-15-15-15-2	95,0 - 98,0 %
Mandavgane y Pandharipande [5]	4-15-15-15-2	98,0 - 99,5 %
Xie <i>et al.</i> [6]	8-6-5-3	92,0 %
Moghadassi <i>et al.</i> [7]	Varias	96,0 - 100,0 %
Iyengar [8]	4-6-3	98,0 - 99,0 %
Jasim [9]	3-16-16-16-2	100,0 %
Sundaram <i>et al.</i> [10]	1-10-1	56,8 %
Esta investigación	4-3-2	98,8 - 100,0 %

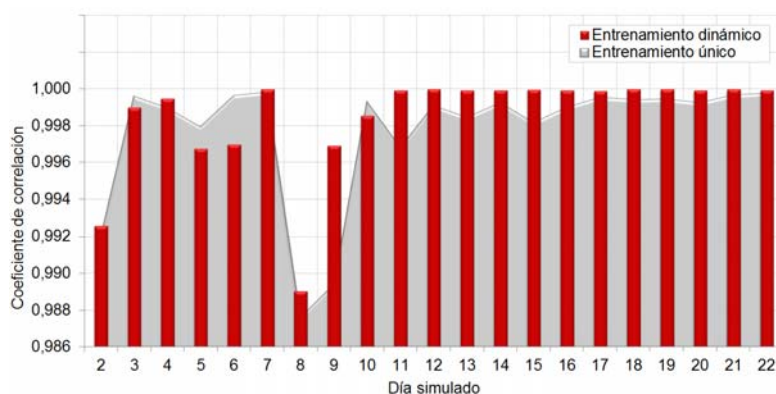


Fig. 4. Coeficientes de correlación obtenidos durante las predicciones.

Precisión del pronóstico

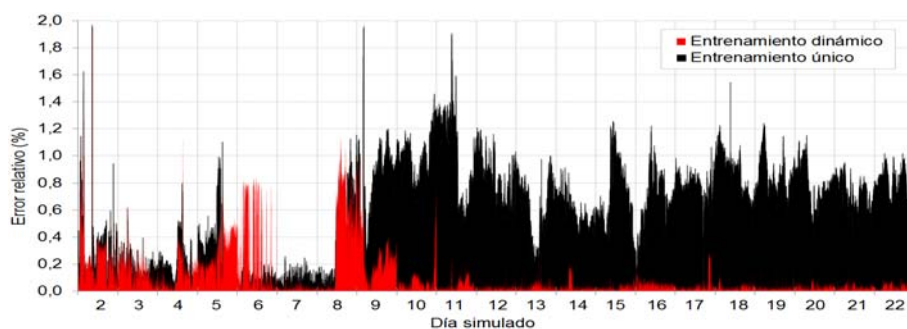
Ambos escenarios de modelación se consideran apropiados para simular el desempeño de los intercambiadores de calor MEA-MEA en condiciones cambiantes de operación, ya que los índices de error calculados no tienen una implicación significativa en el proceso tecnológico examinado (tabla 3). Este enfoque de “caja negra” empleado en la modelación y simulación del objeto de estudio no sólo elude el cálculo del coeficiente global de transferencia de calor, sino que ofrece una alternativa para evaluar el desempeño de los equipos teniendo en cuenta que las propiedades termo-físicas de las soluciones de amina dependen de varios parámetros (temperatura, presión, fracción másica y carga de CO₂), no están totalmente caracterizadas y son difíciles de obtener [18].

Tabla 3. Índices de error calculados durante el proceso de simulación.


Variable dependiente	Escenario	\bar{E} (K)	$\bar{\epsilon}$ (%)
Temperatura de salida amina rica	Entrenamiento dinámico	0,419	0,108
	Entrenamiento único	2,214	0,574
Temperatura de salida amina pobre	Entrenamiento dinámico	0,372	0,104
	Entrenamiento único	1,181	0,329

En el período analizado (22 días) se considera que la red neuronal con entrenamiento único no perdió la capacidad de generalización, ya que además de reproducir con exactitud los datos para los cuales fue entrenada (99,89 % de correlación y 0,438 K² error cuadrático medio) se lograron predicciones confiables frente a los juegos de datos nuevos [2, 15, 17].

No obstante, para poder determinar de forma concluyente si el modelo pierde o no su capacidad de generalización cuando se realizan pronósticos a mediano y largo plazo, se tendrían que analizar mayores intervalos de tiempo de operación en la instalación industrial estudiada. A pesar de lo antes expuesto, las diferencias entre los valores de error corroboran que la red con entrenamiento dinámico proporciona respuestas más precisas (figura 5).



a) Variable dependiente: temperatura de salida de la amina rica.



b) Variable dependiente: temperatura de salida de la amina pobre.

Fig. 5. Valores de error relativo calculados durante las predicciones.

Durante la operación real de los intercambiadores de calor las condiciones de operación varían por diversas razones internas o externas al proceso. Según Medina-Flores *et al.* [19], ejemplo de este tipo de disturbio son el incremento o reducción de la producción y los cambios climatológicos. Otras perturbaciones que ejercen influencia en el desempeño de los equipos estudiados son las variaciones en la concentración de la solución de MEA (ya que introducen cambios en las propiedades termo-físicas del fluido), la pureza de la materia prima utilizada para reposición, y el factor de incrustaciones debido a la formación y deposición de sales estables en condiciones de alta temperatura [20-21]. La mayoría de estas variaciones tienen un comportamiento aleatorio, difícil de controlar por el investigador en instalaciones industriales. Otras describen un proceso cíclico o que evoluciona en función del tiempo, por lo que existe mayor probabilidad de que a mediano y largo plazo los valores de las perturbaciones difieran crecientemente unos de otro.

Bajo estas circunstancias la respuesta aprendida por la RNA no estará condicionada únicamente por las variables independientes, ya que también reflejará la influencia de las perturbaciones, aunque de forma implícita y en menor grado. Como en plazos de tiempo iguales o inferiores a 24 h existe alta probabilidad de que los cambios en las perturbaciones no sean significativos en este caso de estudio (condiciones climáticas estables, no se añade MEA al proceso diariamente, la degradación de la amina y la deposición de elementos incrustantes ocurre paulatinamente), el modelo realizó predicciones más precisas cuando la red se entrenó periódicamente utilizando los datos registrados el día anterior. Al determinar las ecuaciones de regresión lineal para los errores relativos previamente mostrados (remitirse a la figura 5), se identificó una tendencia decreciente de las desviaciones al aplicar el escenario de entrenamiento dinámico, que contrasta con una evolución creciente para el caso con entrenamiento único (tabla 4).

Tabla 4. Tendencia lineal de los errores relativos con el transcurso del tiempo

Variable dependiente	Escenario	Ecuación de regresión
Temperatura de salida amina rica	Entrenamiento dinámico	$e = -0,000009 \cdot t + 0,2456$
	Entrenamiento único	$e = 0,000020 \cdot t + 0,2159$
Temperatura de salida amina pobre	Entrenamiento dinámico	$e = -0,000006 \cdot t + 0,1960$
	Entrenamiento único	$e = 0,000003 \cdot t + 0,2896$

Donde: e – error relativo; t – tiempo transcurrido (en minutos).

CONCLUSIONES

Se propuso una RNA para la simulación del sistema de intercambiadores de calor MEA-MEA, capaz de predecir las temperaturas de salida de los fluidos minimizando los índices de error en la respuesta. La estructura de red optimizada consistió en un perceptrón multicapa 4-3-2, con función de transferencia sigmooidal logística en la capa oculta y de activación lineal en la capa de salida, entrenada con el algoritmo Levenberg-Marquardt.

El escenario de entrenamiento dinámico proporcionó respuestas más precisas que el entrenamiento único. Mediante el primero se obtuvieron correlaciones entre 98,90 y 100,00 %, así como errores absolutos promedio de 0,419 y 0,372 K para las variables temperatura de salida de la amina rica y de la amina pobre, respectivamente. En el segundo caso la correlación fluctuó entre 98,76 y 99,98 %, mientras que los índices de error promediaron 2,214 y 1,181 K para las mismas variables de respuesta.

Aunque la red neuronal con entrenamiento único no perdió la capacidad de generalización durante los 22 días analizados, ya que logró predicciones confiables frente a juegos de datos diferentes a los utilizados en el entrenamiento, se infiere que los cambios en las perturbaciones al transcurrir el tiempo influyeron en la precisión de los resultados del modelo. Este hecho reafirma al método de entrenamiento progresivo de la red como mejor escenario predictor, recomendándose su implementación práctica.

REFERENCIAS

- [1] Kamble, L. V.; *et al.*, “Heat Transfer Studies using Artificial Neural Network – a Review”. *International Energy Journal*. 2014, v. 14, p. 25-42. Disponible en: <http://www.ericjournal.ait.ac.th/index.php/eric/article/viewFile/1066/431>. ISSN 1513-718X.
- [2] Mohanraj, M.; *et al.*, “Applications of artificial neural networks for thermal analysis of heat exchangers – A review”. *International Journal of Thermal Sciences*. 2015, v. 90, p. 150-172. Disponible en: <https://bxscience.enschool.org/ourpages/auto/2014/9/5/42400025/example%209.pdf>. ISSN 1290-0729. DOI: 10.1016/j.ijthermalsci.2014.11.030
- [3] Nitsche, M. y Gbadamosi, R. O. “Heat exchanger design guide: A practical guide for planning, selecting and designing of shell and tube exchangers”. Oxford, Reino Unido: Butterworth Heinemann / Elsevier. 2016, p.270. Disponible en: <https://www.elsevier.com/books/heat-exchanger-design-guide/nitsche/978-0-12-803764-5>. ISBN 978-0-12-803764-5.
- [4] Pandharipande, S. L.; *et al.*, “Optimizing ANN architecture for shell and tube heat exchanger modelling”. *Indian Journal of Chemical Technology*. 2004, v. 11, n. 6, p. 804-810. Disponible en: <http://nopr.niscair.res.in/handle/123456789/9550>. ISSN 0975-0991.
- [5] Mandavgane, S. A. y Pandharipande, S. L. “Application of optimum ANN architecture for heat exchanger modelling”. *Indian Journal of Chemical Technology*. 2006, v. 13, n. 6, p. 634-639. Disponible en: <http://nopr.niscair.res.in/handle/123456789/7106>. ISSN 0975-0991.
- [6] Xie, G. N.; *et al.* “Heat transfer analysis for shell and tube heat exchangers with experimental data by artificial neural networks approach”. *Applied Thermal Engineering*. 2007, v. 27, n. 5, p. 1096-1104. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1359431106002699>. ISSN 1359-4311. DOI: 10.1016/j.applthermaleng.2006.07.036

- [7] Moghadassi, A. R.; *et al.*, “An expert model for the shell and tube heat exchangers analysis by artificial neural networks”. *ARNP Journal of Engineering and Applied Sciences*. 2011, v. 6, n. 9, p. 78-93. Disponible en: http://www.arnpjournals.com/jeas/research_papers/rp_2011/jeas_0911_558.pdf . ISSN 1819-6608.
- [8] Iyengar, A. S. “Thermal analysis of shell and tube heat exchangers using artificial neural networks”. *Ethiopian Journal of Science and Technology*. 2015, v. 8, n. 2, p. 107-120. Disponible en: <https://www.ajol.info/index.php/ejst/article/download/128192/117741>. ISSN 2312-6019. DOI: 10.4314/ejst.v8i2.5
- [9] Jasim, H. H. “Estimated Outlet Temperatures in Shell-and-Tube Heat Exchanger Using Artificial Neural Network Approach Based on Practical Data”. *Al-Khwarizmi Engineering Journal*. 2013, v. 9, n. 2, p. 12-20. Disponible en: <https://www.iasj.net/iasj?func=fulltext&aId=74861> . ISSN 18181171 23120789.
- [10] Sundaram, N. M.; *et al.*, “Artificial Neural Network Approach for Dynamic Modelling of Heat Exchanger for Data Prediction”. *Indian Journal of Science and Technology*. 2016, v. 9, n. S1, p. 1-7. Disponible en: <http://www.indjst.org/index.php/indjst/article/viewFile/86189/78174> . ISSN 0974-5645. DOI: 10.17485/ijst/2016/v9iS1/86189
- [11] Mohanty, D. K. “Application of neural network model for predicting fouling behaviour of a shell and tube heat exchanger”. *International Journal of Industrial and Systems Engineering*. 2017, v. 26, n. 2, p. 228-246. Disponible en: <https://www.inderscienceonline.com/doi/abs/10.1504/IJISE.2017.083674> . ISSN 1748-5045. DOI: 10.1504/IJISE.2017.10004388
- [12] Xue, B., *et al.*, “A comparative study of MEA and DEA for post-combustion CO₂ capture with different process configurations”. *International Journal of Coal Science & Technology*. 2017, v. 4, n. 1, p. 15-24. Disponible en: <https://link.springer.com/article/10.1007/s40789-016-0149-7> . ISSN 2198-7823. DOI: 10.1007/s40789-016-0149-7
- [13] Edmonds, W. A. y Kennedy, T. D. “An applied guide to research designs: quantitative, qualitative, and mixed methods”. 2da ed. Los Angeles, Estados Unidos: SAGE Publications. 2017, p. 364. Disponible en: <https://www.amazon.es/Applied-Guide-Research-Designs-Quantitative/dp/1483317277> . ISBN 9781483317274.
- [14] Naphon, P.; *et al.*, “Artificial neural network analysis on the heat transfer and friction factor of the double tube with spring insert”. *International Journal of Applied Engineering Research*. 2016, v. 11, n. 5, p. 3542-3549. Disponible en: https://www.researchgate.net/publication/319015549_Artificial_neural_network_analysis_on_the_heat_transfer_and_friction_factor_of_the_double_tube_with_spring_insert . ISSN 0973-9769.
- [15] Kayri, M. “Predictive Abilities of Bayesian Regularization and Levenberg-Marquardt Algorithms in Artificial Neural Networks”. *Mathematical and Computational Applications*. 2016, v. 21, n. 2, p. 1-11. Disponible en: <https://www.mdpi.com/2297-8747/21/2/20/pdf> . ISSN 2297-8747. DOI: 10.3390/mca21020020
- [16] Ramos-Ruiz, G. y Fernández-Bandera, C. “Validation of Calibrated Energy Models: Common Errors”. *Energies*. 2017, v. 10, p. 1-19. Disponible en: <https://www.mdpi.com/1996-1073/10/10/1587> . ISSN 1996-1073. DOI:10.3390/en10101587
- [17] Aguilar, R. M.; Torres, J. M. y Martín, C. A. “Aprendizaje automático en la identificación de sistemas. Un caso de estudio en la predicción de la generación eléctrica de un parque eólico”. *Revista Iberoamericana de Automática e Informática Industrial*. 2019, v. 16, n. 1, p.114-127. Disponible en: <https://polipapers.upv.es/index.php/RIAI/article/view/9421/10806> . ISSN 1697-7920. DOI: 10.4995/riai.2018.9421
- [18] Sánchez-Escalona, A. A.; *et al.*, “Monoethanolamine Heat Exchangers Modeling Using the Buckingham Pi Theorem”. *Mathematical Modelling of Engineering Problems*. 2019, v. 6, n. 2, p. 197-202. Disponible en: <http://iieta.org/journals/mmep/paper/10.18280/mmep.060207> . ISSN 2369-0747. DOI: 10.18280/mmep.060207
- [19] Medina-Flores, J. M.; *et al.*, “Simulación dinámica de intercambiadores de calor sujetos a perturbaciones”. En: *XVI Congreso Internacional Anual de la SOMIM*, Monterrey, Nuevo León, México. 2010, p. 1-7. Disponible en: http://somim.org.mx/memorias/memorias2010/A5/A5_149.pdf . ISBN 978-607-95309-2-1
- [20] Fytianos, G.; *et al.*, “Effect of MEA’s degradation products on corrosion at CO₂ capture plants”. *Energy Procedia*. 2014, v. 63, p. 1869-1875. Disponible en: <https://www.sciencedirect.com/science/article/pii/S1876610214020104> . ISSN 1876-6102. DOI: 10.1016/j.egypro.2014.11.195

- [21] Hartono, A.; *et al.*, “Physical properties of partially CO₂ loaded aqueous monoethanolamine (MEA)”. *Journal of Chemical & Engineering Data*. 2014, v. 59, n. 6, p. 1808-1816. Disponible en: <https://pubs.acs.org/doi/10.1021/je401081e> . ISSN: 1520-5134. DOI: 10.1021/je401081e

CONFLICTO DE INTERESES

Los autores declaran que no existen conflictos de intereses

CONTRIBUCIÓN DE LOS AUTORES

Andres Adrian Sánchez-Escalona: <https://orcid.org/0000-0002-9770-210X>

Formuló el diseño teórico y experimental de la investigación para modelación y simulación del sistema de intercambiadores de calor. Aplicó la técnica experimental y recogida de datos. Implementó los procedimientos de cálculo y la programación en MATLAB. Lideró el análisis de datos e interpretación de los resultados. Participó en el análisis de los resultados y en la revisión y redacción del informe final.

Ever Góngora-Leyva : <https://orcid.org/0000-0001-5418-5512>

Colaboró con la metodología de la investigación. Estableció las condiciones para realización exitosa del experimento pasivo puesto en práctica. Realizó precisiones sobre la idea del estudio y el estado del arte. Verificó las rutinas y funciones escritas en MATLAB. Participó en el análisis e interpretación de los datos y los resultados obtenidos, con aportes relevantes, así como en el análisis de los resultados y en la revisión y redacción del informe final.

Yanan Camaraza Medina: <https://orcid.org/0000-0003-2287-7519>

Participó en el análisis e interpretación de los datos y los resultados obtenidos, con aportes relevantes. Contribuyó con el análisis de los resultados y en la revisión y redacción del informe final.