

## PREDICTIVE MODEL TO CALCULATE OF HOLDUP IN HORIZONTAL BIPHASIC WATER-OIL FLOW USING AN ARTIFICIAL NEURONAL NETWORK

### MODELO PREDICTIVO PARA EL CÁLCULO DE LA FRACCIÓN VOLUMÉTRICA DE UN FLUJO BIFÁSICO AGUA-ACEITE EN LA HORIZONTAL UTILIZANDO UNA RED NEURONAL ARTIFICIAL

MSc. (c) Carlos Mauricio Ruiz Diaz<sup>1</sup>, PhD. Marlon Mauricio Hernández Cely<sup>2</sup>,  
PhD. Octavio Andrés González Estrada<sup>3</sup>, PhD Germán González Silva<sup>4</sup>, PhD. Oscar  
Mauricio Hernández Rodríguez<sup>5</sup>

<sup>1</sup>Universidad Industrial de Santander (UIS), Grupo de Investigación en Energía y Medio Ambiente (GIEMA), Bucaramanga, Colombia. E-mail: carlosruiz978@hotmail.com

<sup>2</sup>Center for Petroleum Studies (CEPETRO), School of Mechanical Engineering, UNICAMP, Brazil. E-mail: marlonhc@usp.br

<sup>3</sup>Universidad Industrial de Santander (UIS), Grupo de Investigación en Energía y Medio Ambiente (GIEMA), Bucaramanga, Colombia. E-mail: agonzale@uis.edu.co

<sup>4</sup>Universidad Industrial de Santander (UIS), Grupo de Investigación en Energía y Medio Ambiente (GIEMA), Bucaramanga, Colombia. E-mail: germangs@uis.edu.co

<sup>5</sup>Industrial Multiphase Flow Laboratory (LEMI), Sao Carlos School of Mechanical Engineering, Universidad of São Paulo, Brazil. E-mail: oscarmhr@sc.usp.br

**Abstract** This paper presents the application of an artificial neural network (ANN) in order to develop a model able to predicting the holdup of a two-phase flow composed by water and mineral oil in a horizontal pipe. The surface velocities of each fluid and the pressure differential in the pipe are used as input parameters of the multi-layer artificial neural network with back-propagation, while the volumetric fraction of the fluids was used as an output parameter in the training. The 56 experimental data were obtained in the laboratory LabPetro- CEPETRO-UNICAMP. The results of the predictive model with the best performance show a mean absolute error (AAPE) of 3.01 % and a coefficient of determination  $R^2$  of 0.9964 using 15 neurons in the hidden layer of the network and the TanSig transfer function.

**Keywords:** Holdup, multiphase flow, artificial neural network, surface speed.

**Resumen:** Este artículo presenta la aplicación de una red neuronal artificial (RNA) con el fin de desarrollar un modelo capaz de predecir la fracción volumétrica de un flujo bifásico compuesto por agua y aceite mineral en una tubería horizontal. Se utilizan las velocidades superficiales de cada fluido y el diferencial de presión en la tubería como parámetros de entrada de la red neuronal artificial multicapa con retro propagación, mientras que la fracción volumétrica de los fluidos fue utilizada como parámetro de salida en el entrenamiento de la misma. Los 56 datos experimentales con los que se trabajó se obtuvieron en el laboratorio LabPetro- CEPETRO-UNICAMP. Los resultados que arrojó el modelo predictivo con mejor rendimiento presentan un error absoluto medio porcentual (AAPE) de 3.01 % y un coeficiente de determinación  $R^2$  de 0.9964 utilizando 15 neuronas en la capa oculta de la red y la función de transferencia TanSig.

**Palabras clave:** Fracción volumétrica, flujo multifásico, red neuronal artificial, velocidad superficial.

## 1. INTRODUCCIÓN

La industria petrolera ha centrado su interés en el desarrollo de tecnologías que permiten obtener sistemas actualizados para la medición precisa de flujo multifásico, definiéndose éste como un flujo concurrente de sustancias en determinados estados o fases (sólido, líquido, gas) los cuales generan una capa de separación con mixtura entre las fases (Süßer, 2000) o patrones característicos (M. de M. F. Figueiredo, Carvalho, Fileti, & Serpa, 2020), (Tang, Sun, & Li, 2020), (Lin, Liu, Lao, & Liu, 2020), (Zeguai, Chikh, & Tadriss, 2020) derivados de los parámetros hidrodinámicos iniciales del flujo en la vertical (Descamps, Oliemans, Ooms, Mudde, & Kusters, 2006), (Rocha, de Carvalho, Estevam, & Rodriguez, 2017) y en la horizontal (Ma et al., 2020), (Yaqub, Rusli, & Pendyala, 2020). Los parámetros hidrodinámicos son identificados mediante la aplicación de distintas metodologías tales como la impedancia eléctrica (Rosa, Salgado, Ohishi, & Mastelari, 2010), variación de presión (Chalgeri & Jeong, 2019), ecos ultrasónicos (Liang, Zheng, Yu, & Sun, 2016) y análisis de imágenes ópticas (Sunde, Avdic, & Pázsit, 2005).

Existen técnicas desarrolladas para determinar la fracción volumétrica de flujos multifase (Zhai, Jin, Gao, Wang, & Li, 2013) con implementación de técnicas intrusivas y no intrusivas (Albion, Briens, Briens, & Berruti, 2020) con el fin de no modificar temporalmente la condición real del flujo. En (Hernández-Cely & Ruiz-Díaz, 2020) se estudió una técnica no intrusiva que cuenta con un sensor basado en la permitividad eléctrica del fluido tomando como base tomografías de los patrones generados en el interior de la tubería con flujo bifásico aceite – agua. Para medir la presión diferencial y determinar la fracción volumétrica (M. M. F. Figueiredo, Goncalves, Nakashima, Fileti, & Carvalho, 2016) y (Wu, Zhou, & Wu, 2001) aplicaron una técnica de inteligencia artificial para identificar el régimen de flujo utilizando un transductor de presión diferencial de flujo multifásico. Una metodología para desarrollar sistemas VFM (caudalímetro virtual basado en datos) fue desarrollada por (AL-Qutami, Ibrahim, Ismail, & Ishak, 2018), capaz de estimar las tasas de flujo de fase con precisión a partir de los datos obtenidos en pruebas aplicando de manera directa una técnica de aprendizaje automático como las redes neuronales (Meireles, Almeida, & Simões, 2003), (Gomide, 2012).

La aplicación de las técnicas de computación blanda fueron estudiadas por (Yan et al., 2018) para la medición de flujo multifásico. (Roshani, Nazemi, & Roshani, 2017) mostraron los avances

desarrollados en medidores de flujo multifase. De manera particular, (César M. Salgado, Brandão, Pereira, & Salgado, 2014) aplicaron una metodología basada en el reconocimiento de patrones de distribución de altura de pulso de una red neuronal artificial (ANN), proponiendo un enfoque para la predicción independiente de la fracción volumétrica en flujos multifásicos, al igual que (César Marques Salgado, Pereira, Schirru, & Brandão, 2010), que innovaron en el reconocimiento de patrones de PHD por medio de la red neuronal. Cuatro modelos RBF (red neuronal de base radial) fueron desarrollados por (Roshani et al., 2017), en los cuales se identifica de manera acertada cada régimen de flujo trifásico. (Karami, Roshani, Nazemi, & Roshani, 2018) introdujeron una red híbrida en la que se emplea un algoritmo de optimización (GWO) para entrenar la red neuronal y obtener valores de error medio, así como la determinación de las velocidades de los fluidos (Roshani et al., 2018).

El objetivo del presente estudio es investigar la viabilidad de la aplicación de redes neuronales artificiales (ANN) para la predicción de la fracción volumétrica de un flujo bifásico agua-aceite en una tubería horizontal. Para ello, se entrenan varias estructuras de redes neuronales y los resultados obtenidos son comparados y permiten establecer la precisión del modelo predictivo generado al aplicar inteligencia artificial en flujos multifase.

## 2. METODOLOGÍA EXPERIMENTAL

Las pruebas experimentales fueron realizadas en las instalaciones del laboratorio experimental de petróleo “Kelsen Valente Serra” - LabPetro, localizado dentro del Centro de Estudios en Petróleo - CEPETRO, en la Universidad Estadual de Campinas – UNICAMP, dicha bancada es presentada esquemáticamente en la Figura 1. LabPetro cuenta con dispositivos tecnológicos de punta los cuales permiten desarrollar investigaciones a escala industrial.

Para esta investigación fue ajustada una línea horizontal de flujo multifásico. Los fluidos utilizados en la experimentación fueron:

- Aceite mineral Luchetti M600 con una viscosidad aproximada de 180 [cP] a temperatura ambiente y una densidad específica de 868 [kg/m<sup>3</sup>].
- Agua con una viscosidad aproximada de 1 [cP] a temperatura ambiente y una densidad específica de 1000 [kg/m<sup>3</sup>].

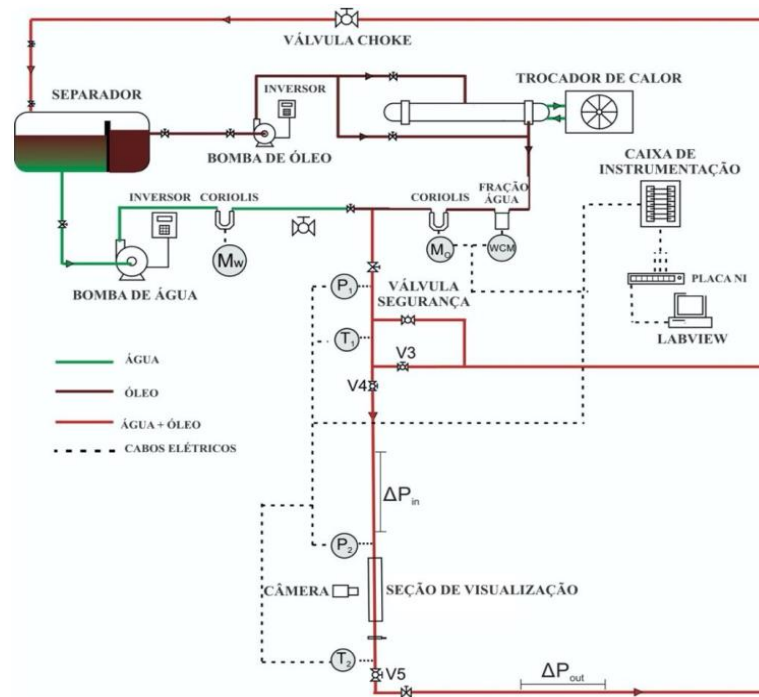


Fig. 1. Bancada experimental LabPetro – CEPETRO – UNICAMP (Ruschel, 2020)

La experimentación se desarrolló haciendo uso de una tubería horizontal de acero al carbono NBR 5580 con 15 [m] de longitud, 80 [mm] de diámetro interno y 4.5 [mm] de espesor. Además, la línea experimental cuenta con una sección de visualización de acrílico macizo de 0.5 [m] de longitud y 80 [mm] de diámetro interno, la cual se encuentra unida a la tubería por medio de dos bridas y permite observar el flujo que pasa a través de ella. Una vez los fluidos son direccionados hacia la tubería de experimentación, se proceden a hacer las mediciones necesarias de gradiente de presión, *holdup*, visualización de patrones de flujo, etc.

Los fluidos de trabajo se almacenan de manera individual en dos tanques, los cuales están instalados junto con un separador que distribuye de manera adecuada cada fluido, para luego ser impulsados al circuito mediante dos bombas helicoidales de desplazamiento positivo (una para cada fluido), una variador de frecuencia, un intercambiador de calor que se encarga de modificar la temperatura del aceite y un compresor, además, se cuenta con transductor de presión, medidores de caudal, válvulas direccionales accionadas por solenoide. También se encuentra instalada una línea auxiliar o *bypass* que es activada por una válvula automática que entra en acción una vez la presión supere los 5 [bar], con el fin de evitar la ruptura de la sección de visualización.

El análisis y tratamiento de los datos experimentales se llevó a cabo con el software MATLAB®, tomando como base las velocidades de entrada de los fluidos que fueron controladas y gradualmente modificadas con el software LabView™, aprovechando de manera directa el sistema de comunicación con el que cuenta el laboratorio.

### 2.1 Determinación de la fracción volumétrica utilizando la técnica de cierre rápido

En la línea experimental se encuentran instaladas dos válvulas que son cerradas para retener un volumen determinado de flujo bifásico aceite-agua y así, después de un proceso de estabilización, se procede a medir la altura de las sustancias al interior de la tubería, suponiendo que se tiene una sección plana de la misma.

Los caudales de aceite ( $Q_o$ ) y agua ( $Q_w$ ) que se inyectan a la tubería de experimentación son conocidos, dado que el software LabView™ controla este parámetro de entrada. Por lo cual, aplicando ecuaciones matemáticas se logra determinar la fracción volumétrica con deslizamiento de cada fluido a partir de los caudales iniciales, así:

$$\alpha_w = \frac{A_w}{A_p}, \alpha_o = \frac{A_o}{A_p}, A_p = A_o + A_w \quad (1)$$

Siendo  $\alpha_w$  y  $\alpha_o$  las fracciones volumétricas de agua y aceite respectivamente.  $A_p$  denota el área de la sección transversal de la tubería conformada por  $A_o$  y  $A_w$  que representan el área de agua y aceite respectivamente.

Considerando que no existe deslizamiento entre las fases al interior de la tubería, se trabaja con la idealización de un comportamiento homogéneo cuyo parámetro fundamental es el caudal de cada sustancia. Dicho comportamiento se representa mediante las ecuaciones **¡Error! No se encuentra el origen de la referencia.)** y **¡Error! No se encuentra el origen de la referencia.)** las cuales permiten calcular el *holdup* de cada fluido.

$$\lambda_w = \frac{Q_w}{Q_w + Q_o} \quad (1)$$

$$\lambda_o = \frac{Q_o}{Q_w + Q_o} \quad (2)$$

$$\lambda_w + \lambda_o = 1 \quad (3)$$

Con  $\lambda_w$  y  $\lambda_o$  como el *holdup* de agua y aceite, respectivamente.

En el caso de las velocidades, al considerarse que de manera específica sólo un fluido pasa por el interior de la tubería ya sea aceite ( $J_o$ ) o agua ( $J_w$ ), las velocidades superficiales están definidas por las ecuaciones (4) y (5).

$$J_w = \frac{Q_w}{A_p} \quad (6)$$

$$J_o = \frac{Q_o}{A_p} \quad (7)$$

$$J = J_w + J_o \quad (8)$$

Siendo  $J$  la velocidad de una mezcla de flujo aceite - agua, igual a la suma de las velocidades superficiales de dichos fluidos.

Para determinar la velocidad superficial de los fluidos de trabajo en un flujo multifásico con deslizamiento entre las fases, se procede a calcular la velocidad de cada fase *in situ* o velocidades reales  $V_w$  y  $V_o$  en [m/s].

$$V_w = \frac{Q_w}{A_w} = \frac{Q_w}{A_p \alpha_w} = \frac{J_w}{\alpha_w} \quad (9)$$

$$V_o = \frac{Q_o}{A_o} = \frac{Q_o}{A_p \alpha_o} = \frac{J_o}{\alpha_o} \quad (10)$$

### 3. DISEÑO DE LA RED NEURONAL ARTIFICIAL

La inteligencia artificial (IA) permite establecer variedad de aplicaciones en el análisis de data experimental. Para este estudio y con el fin de

generar un modelo capaz de predecir la fracción volumétrica de agua y aceite se usó una red neuronal artificial (RNA) debido a que se basa en aprendizaje automático a partir de unos parámetros de entrada. Su estructura flexible permite establecer variaciones en las entradas y en las salidas, así como en las capas ocultas, las cuales poseen unos pesos sinápticos organizados en una matriz y unos sesgos organizados en un vector, formando un sistema capaz de almacenar conocimiento.

Uno de los tipos de red neuronal artificial más común es aquel denominado red neuronal de perceptrón multicapa, el cual se basa en una red neuronal simple. El número de capas ocultas puede ser mayor o igual que uno, siendo una red unidireccional (feedforward) donde las neuronas de la capa oculta utilizan como regla de propagación la suma de las entradas junto con los pesos sinápticos con el fin de aplicar una función de transferencia de tipo sigmoide, ya que acota la respuesta generada. Matemáticamente, la entrada neta  $S_i$  a la red neuronal se obtiene mediante la ecuación (11) propuesta por (Jorjani, Chehreh Chelgani, & Mesroghli, 2008):

$$S_i = \sum_{j=1}^m x_i w_{ij} + b_j \quad (12)$$

Donde  $j$  es el nodo de la capa oculta en el cual entra  $S_i$ ,  $x_i$  son las entradas al nodo  $j$  (o salidas de la capa inmediatamente anterior),  $w_{ij}$  son los pesos que representan el grado de relación o conexión entre los nodos  $i$  y  $j$ ,  $i$  es la cantidad de nodos y  $b_j$  es el sesgo que esta relacionado con cada nodo  $j$ .

Los términos anteriormente descritos son procesados mediante una función de transferencia, la cual determina de manera precisa la salida que se está buscando. Para este estudio se utilizaron las funciones de activación tangente hiperbólica sigmoidea (TanSig) y logarítmica sigmoidea (LogSig) (Al-rikabi et al., 2020), siendo estas las funciones de activación más comunes en el tratamiento de datos con ecuaciones no lineales definidas por las ecuaciones (11) y (12), respectivamente. Dichas funciones generan valores que se incluyen en los intervalos [0,1] y [-1,1]. Otras funciones de activación son ReLU, Unidad lineal exponencial escalada (SELU) y función de base radial entre otras.

$$\text{TanSig}(S_j) = f(S_j) = \frac{e^{S_j} - e^{-S_j}}{e^{S_j} + e^{-S_j}} \quad (11)$$

$$\text{LogSig}(S_j) = f(S_j) = \frac{1}{1 + e^{-S_j}} \quad (12)$$

Donde  $f(S_j)$  es la salida del nodo  $j$ , así como también es el elemento de entrada a los nodos de la siguiente capa. Para que la red neuronal aprenda la relación que existe entre los datos, es necesario desarrollar un entrenamiento en el cual se modifiquen los pesos y se reduzcan los errores entre los valores de entrada y los valores que arroja la red neuronal entrenada. Para desarrollar ésta fase del diseño de la red neuronal artificial, se aplicó un algoritmo denominado de retro propagación de errores o *backpropagation*, a partir de una red multicapa perceptrón obtenida utilizando la caja de herramientas que ofrece MATLAB 2019 a ®.

La Figura 2 representa la estructura básica de la RNA utilizada, en la cual la capa de entrada está conformada por las velocidades superficiales de los fluidos aceite-agua y el diferencial de presión medido con un sensor de presión Emerson modelo Rosemount 2051-C con un nivel de incerteza de  $\pm 0,064\%$ , generando como salida las fracciones volumétricas de cada uno de ellos. La estructura de la RNA se conforma a partir de tres entradas en su capa inicial, una capa oculta compuesta por 15 neuronas y una capa de salida que incluye las fracciones volumétricas de cada fluido.




Fig. 2. Representación esquemática de la estructura RNA utilizada

### 3.1 Tratamiento para minimizar los errores seleccionando el número adecuado de neuronas

La red neuronal fue entrenada con 56 datos, este conjunto de elementos fue utilizado para desarrollar y ajustar tanto los pesos como los sesgos y así lograr un modelo preciso. La complejidad del problema está directamente relacionada con el número de neuronas que conforman tanto las capas de entrada como las de salida, al ser iguales al número de parámetros que en cada fase se incluyan de manera respectiva. El parámetro que se utiliza como determinante inicial para establecer la proximidad del modelo se genera con la minimización del error cuadrático medio, el cual sigue la ecuación (13)

$$MSE = \frac{1}{n} \sum_{m=1}^n (Y_{(Exp,m)} - Y_{(Pred,m)})^2 \quad (13)$$

Donde  $n$  es el número total de datos de entrada,  $Y_{(Pred)}$  es el valor de salida obtenido por la RNA y  $Y_{(Exp)}$  es el valor experimental de la salida.

De manera consecutiva se incluyen dos parámetros que minimizan el error generado en la selección del número adecuado de neuronas que conforman la red. El primero es denominado error absoluto medio porcentual (AAPE) expresado en la ecuación (14), debido a que es el valor descriptivo del rendimiento de las RNA desarrolladas durante el estudio e incluye el valor promedio de los datos de salida  $\bar{Y}_{(Pred,m)}$ . El segundo parámetro es el coeficiente de determinación  $R^2$ , el cual se calcula mediante la ecuación (15).

$$AAPE = \left[ \frac{1}{n} \sum_{m=1}^n \left| \frac{Y_{(Exp,m)} - Y_{(Pred,m)}}{Y_{(Exp,m)}} \right| \right] * 100 \quad (14)$$

$$R^2 = 1 - \frac{\sum_{m=1}^n (Y_{(Exp,m)} - Y_{(Pred,m)})^2}{\sum_{m=1}^n (Y_{(Exp,m)} - \bar{Y}_{(Pred,m)})^2} \quad (15)$$

## 4. RESULTADOS Y DISCUSIÓN

Las Tablas 1 y 2 muestran el entrenamiento que se realizó a las RNA con 56 datos experimentales en LabPetro asumiendo una variedad en el número de neuronas que integran la capa oculta (siguiendo la secuencia 1, 2, 3, 5, 8, 10, 12, 15 y 20) con sus respectivos pesos y sesgos aplicando las funciones LogSig y TanSig.

Tabla 1: Resultados de la variación en el número de neuronas en la camada oculta (# N.C.O) usando la función de transferencia LogSig

# N.C.O	MSE	$R^2$	AAPE %
1	0,00767	0,9640	21,93
2	0,00137	0,9936	7,23
3	0,00503	0,9764	11,62
5	0,00449	0,9789	14,24
8	0,00103	0,9952	6,56
10	0,00157	0,9926	8,12
12	0,00217	0,9898	10,75
15	0,00220	0,9897	7,58
20	0,00217	0,9898	9,87

La Tabla 1 integra los resultados obtenidos del entrenamiento y validación de la RNA con la función de transferencia LogSig. A partir de la información allí recopilada se lograron determinar los valores mínimos del AAPE, siendo estos 7,58, 7,23 y 6,56, para un número de neuronas en la capa oculta de 15, 2 y 8, respectivamente, así




como también sus coeficientes de determinación de 0,9897, 0,9936 y 0,9952.

*Tabla 2: Resultados de la variación en el número de neuronas en la camada oculta (# N.C.O) usando la función de transferencia TanSig*

# N.C.O	MSE	$R^2$	AAPE %
1	0,00541	0,9746	14,33
2	0,00151	0,9929	8,87
3	0,00337	0,9842	8,81
5	0,00305	0,9857	14,12
8	0,00095	0,9955	6,60
10	0,00079	0,9963	5,03
12	0,00123	0,9942	6,48
15	0,00077	0,9964	3,01
20	0,01085	0,9491	23,14

La Tabla 2 presenta los resultados obtenidos integra al entrenar la RNA con la función de transferencia TanSig, determinando como valores mínimos del AAPE a 6,6, 5,03 y 3,01 y coeficiente de determinación de 0,9955, 0,9963 y 0,9964 para 8, 10 y 15 neuronas, respectivamente.

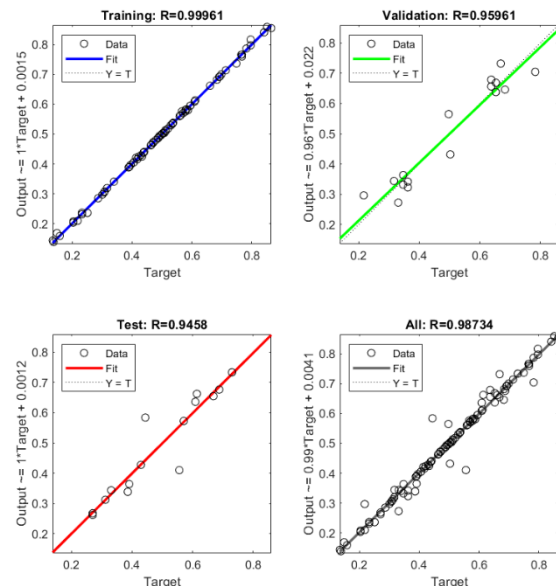
Analizando esta información se logró determinar que la RNA óptima para desarrollar el modelo predictivo de fracción volumétrica para los fluidos agua y aceite es aquella que integra la función de transferencia TanSig con dos capas. La capa oculta está compuesta por 15 neuronas y logra un AAPE 3,01 % calculado con la Ecuación (14), un coeficiente de determinación  $R^2$  igual a 0,9964 calculado con la Ecuación (15) y un error medio cuadrático (MSE) de 0,00077, permitiendo concluir que de manera comparativa, dicho modelo predictivo es el mejor de los 18 que se simularon, al presentar los mejores resultados en los cálculos y en la simulación.



*Fig. 3. Variación del error medio cuadrático (MSE) a partir del cambio de época en la RNA de configuración [2-1-15].*

La Figura 3 muestra el comportamiento del error cuadrático medio (MSE) en cada una de las fases de diseño y prueba de la RNA seleccionada que sigue la secuencia [2-1-15], con un valor mínimo de 0,00077 para 15 neuronas en la capa oculta.

La Figura 4 muestra de manera secuencial los resultados obtenidos en las fases de entrenamiento, validación, prueba y general, así como también sus respectivos  $R$  y regresión:



*Fig. 4. Desempeño de la RNA entrenada con los datos experimentales obtenidos en LabPetro.*

## 5. CONCLUSIONES

Se implementó un modelo de RNA para predecir la fracción volumétrica de agua y aceite que forman un flujo bifásico en una tubería horizontal. Se estudió el reconocimiento de las velocidades superficiales de los fluidos y el diferencial de presión en las entradas de la RNA, la cual tuvo en su mejor desempeño un error absoluto medio porcentual (AAPE) de 3,01 % y un coeficiente de determinación  $R^2$  de 0,9964 para todos los datos experimentales medidos en LabPetro.

El modelo de red neuronal óptimo para los datos experimentales utilizados es aquella que tiene una capa de entrada, una capa oculta conformada por 15 neuronas con su respectivo vector de pesos y de sesgos y una capa de salida compuesta por los resultados de las fracciones volumétricas de la predicción.

Conociendo los valores de las velocidades superficiales y del diferencial de presión en la tubería, se puede predecir con precisión la fracción volumétrica de un flujo bifásico haciendo uso de redes neuronales.

## REFERENCIAS

- AL-Qutami, T. A., Ibrahim, R., Ismail, I., & Ishak, M. A. (2018). Virtual multiphase flow metering using diverse neural network ensemble and adaptive simulated annealing. *Expert Systems with Applications*, 93, 72–85. <https://doi.org/10.1016/j.eswa.2017.10.014>
- Al-rikabi, H. M. H., Al-ja, M. A. M., Ali, A. H., & Abdulwahed, S. H. (2020). *Microprocessors and Microsystems Generic model implementation of deep neural network activation functions using GWO-optimized SCPWL model on FPGA*. 77. <https://doi.org/10.1016/j.micpro.2020.103141>
- Albion, K. J., Briens, L., Briens, C., & Berruti, F. (2020). *Técnicas de medición de flujo multifásico para transporte de pulpa*. 9, 1–4.
- Chalgeri, V. S., & Jeong, J. H. (2019). Flow regime identification and classification based on void fraction and differential pressure of vertical two-phase flow in rectangular channel. *International Journal of Heat and Mass Transfer*, 132, 802–816. <https://doi.org/10.1016/j.ijheatmasstransfer.2018.12.015>
- Descamps, M., Oliemans, R. V. A., Ooms, G., Mudde, R. F., & Kusters, R. (2006). Influence of gas injection on phase inversion in an oil-water flow through a vertical tube. *International Journal of Multiphase Flow*, 32(3), 311–322. <https://doi.org/10.1016/j.ijmultiphaseflow.2005.10.006>
- Figueiredo, M. de M. F., Carvalho, F. de C. T., Fileti, A. M. F., & Serpa, A. L. (2020). Flow pattern classification in water-air vertical flows using a single ultrasonic transducer. *Experimental Thermal and Fluid Science*, 119(January). <https://doi.org/10.1016/j.expthermflusci.2020.110189>
- Figueiredo, M. M. F., Goncalves, J. L., Nakashima, A. M. V., Fileti, A. M. F., & Carvalho, R. D. M. (2016). The use of an ultrasonic technique and neural networks for identification of the flow pattern and measurement of the gas volume fraction in multiphase flows. *Experimental Thermal and Fluid Science*, 70, 29–50. <https://doi.org/10.1016/j.expthermflusci.2015.08.010>
- Gomide, F. A. (2012). Redes neurais artificiais para engenharia e ciências aplicadas: curso prático. *Sba: Controle & Automação Sociedade Brasileira de Automação*, 23(5), 649–652. <https://doi.org/10.1590/s0103-17592012000500011>
- Hernández-Cely, M. M., & Ruiz-Díaz, C. M. (2020). Estudio de los fluidos aceite-agua a través del sensor basado en la permitividad eléctrica del patrón de fluido. *Revista UIS Ingenierías*, 19(3), 177–186. <https://doi.org/10.18273/revuin.v19n3-2020017>
- Jorjani, E., Chehreh Chelgani, S., & Mesroghli, S. (2008). Application of artificial neural networks to predict chemical desulfurization of Tabas coal. *Fuel*, 87(12), 2727–2734. <https://doi.org/10.1016/j.fuel.2008.01.029>
- Karami, A., Roshani, G. H., Nazemi, E., & Roshani, S. (2018). Enhancing the performance of a dual-energy gamma ray based three-phase flow meter with the help of grey wolf optimization algorithm. *Flow Measurement and Instrumentation*, 64(October), 164–172. <https://doi.org/10.1016/j.flowmeasinst.2018.10.015>
- Liang, F., Zheng, H., Yu, H., & Sun, Y. (2016). Gas-liquid two-phase flow pattern identification by ultrasonic echoes reflected from the inner wall of a pipe. *Measurement Science and Technology*, 27(3). <https://doi.org/10.1088/0957-0233/27/3/035304>
- Lin, Z., Liu, X., Lao, L., & Liu, H. (2020). Prediction of two-phase flow patterns in upward inclined pipes via deep learning. *Energy*, 210, 118541. <https://doi.org/10.1016/j.energy.2020.118541>
- Ma, Y., Liu, W., Wu, H., Liu, Y., Lyu, J., & Cai, Z. (2020). Visualization experiment of gas-liquid flow pattern downstream of single-orifice plates in horizontal pipes under an intermittent upstream flow. *Experimental Thermal and Fluid Science*, 119(September 2019), 110206. <https://doi.org/10.1016/j.expthermflusci.2020.110206>
- Meireles, M. R. G., Almeida, P. E. M., & Simões, M. G. (2003). A comprehensive review for industrial applicability of artificial neural networks. *IEEE Transactions on Industrial Electronics*, 50(3), 585–601. <https://doi.org/10.1109/TIE.2003.812470>
- Rocha, D. M., de Carvalho, C. H. M., Estevam, V., & Rodriguez, O. M. H. (2017). Effects of water and gas injection and viscosity on volumetric fraction, pressure gradient and phase inversion in upward-vertical three-phase pipe flow. *Journal of Petroleum Science and Engineering*, 157(March), 519–529. <https://doi.org/10.1016/j.petrol.2017.07.05>

- 5
- Rosa, E. S., Salgado, R. M., Ohishi, T., & Mastelari, N. (2010). Performance comparison of artificial neural networks and expert systems applied to flow pattern identification in vertical ascendant gas-liquid flows. *International Journal of Multiphase Flow*, 36(9), 738–754. <https://doi.org/10.1016/j.ijmultiphaseflow.2010.05.001>
- Roshani, G. H., Hanus, R., Khazaei, A., Zych, M., Nazemi, E., & Mosorov, V. (2018). Density and velocity determination for single-phase flow based on radiotracer technique and neural networks. *Flow Measurement and Instrumentation*, 61(March), 9–14. <https://doi.org/10.1016/j.flowmeasinst.2018.03.006>
- Roshani, G. H., Nazemi, E., & Roshani, M. M. (2017). Intelligent recognition of gas-oil-water three-phase flow regime and determination of volume fraction using radial basis function. *Flow Measurement and Instrumentation*, 54(October 2016), 39–45. <https://doi.org/10.1016/j.flowmeasinst.2016.10.001>
- Ruschel, R. H. (2020). *Proposição de modelo de fluxo de deslizamento para escoamento líquido-líquido horizontal*. Campinas, Brasil.
- Salgado, César M., Brandão, L. E. B., Pereira, C. M. N. A., & Salgado, W. L. (2014). Salinity independent volume fraction prediction in annular and stratified (water-gas-oil) multiphase flows using artificial neural networks. *Progress in Nuclear Energy*, 76, 17–23. <https://doi.org/10.1016/j.pnucene.2014.05.004>
- Salgado, César Marques, Pereira, C. M. N. A., Schirru, R., & Brandão, L. E. B. (2010). Flow regime identification and volume fraction prediction in multiphase flows by means of gamma-ray attenuation and artificial neural networks. *Progress in Nuclear Energy*, 52(6), 555–562. <https://doi.org/10.1016/j.pnucene.2010.02.001>
- Sunde, C., Avdic, S., & Pázsit, I. (2005). Classification of two-phase flow regimes via image analysis and a neuro-wavelet approach. *Progress in Nuclear Energy*, 46(3–4), 348–358. <https://doi.org/10.1016/j.pnucene.2005.03.015>
- Süßer, M. (2000). Flow Measurement Handbook: Industrial Designs, Operating Principles, Performance and Applications. In *Cryogenics* (Vol. 40). [https://doi.org/10.1016/s0011-2275\(00\)00051-5](https://doi.org/10.1016/s0011-2275(00)00051-5)
- Tang, W., Sun, Z. chuan, & Li, W. (2020). Visualization of flow patterns during condensation in dimpled surface tubes of different materials. *International Journal of Heat and Mass Transfer*, 161. <https://doi.org/10.1016/j.ijheatmasstransfer.2020.120251>
- Wu, H., Zhou, F., & Wu, Y. (2001). Intelligent identification system of flow regime of oil-gas-water multiphase flow. *International Journal of Multiphase Flow*, 27(3), 459–475. [https://doi.org/10.1016/S0301-9322\(00\)00022-7](https://doi.org/10.1016/S0301-9322(00)00022-7)
- Yan, Y., Wang, L., Wang, T., Wang, X., Hu, Y., & Duan, Q. (2018). Application of soft computing techniques to multiphase flow measurement: A review. *Flow Measurement and Instrumentation*, 60(February), 30–43. <https://doi.org/10.1016/j.flowmeasinst.2018.02.017>
- Yaqub, M. W., Rusli, R., & Pendyala, R. (2020). Experimental study on gas-liquid-liquid three-phase flow patterns and the resultant pressure drop in a horizontal pipe upstream of the 90° bend. *Chemical Engineering Science*, 226, 115848. <https://doi.org/10.1016/j.ces.2020.115848>
- Zeguai, S., Chikh, S., & Tadriss, L. (2020). Experimental study of air-water two-phase flow pattern evolution in a mini tube: Influence of tube orientation with respect to gravity. *International Journal of Multiphase Flow*, 132. <https://doi.org/10.1016/j.ijmultiphaseflow.2020.103413>
- Zhai, L. S., Jin, N. De, Gao, Z. K., Wang, Z. Y., & Li, D. M. (2013). The ultrasonic measurement of high water volume fraction in dispersed oil-in-water flows. *Chemical Engineering Science*, 94, 271–283. <https://doi.org/10.1016/j.ces.2013.02.049>