



*ARN aplicada al proceso de deshidratación de gas natural por absorción con Trietilenglicol*

*ARN applied to the dehydration process of natural gas by absorption with Triethylene Glycol*

*RNA aplicado ao processo de desidratação de gás natural por absorção com Trietilenoglicol*

Daniel Antonio Chuquín-Vasco<sup>I</sup>  
[daniel.chuquin@esPOCH.edu.ec](mailto:daniel.chuquin@esPOCH.edu.ec)  
<https://orcid.org/0000-0001-9637-3140>

Bryan Alexander Jaramillo-Soza<sup>II</sup>  
[bryan.jaramillo@esPOCH.edu.ec](mailto:bryan.jaramillo@esPOCH.edu.ec)  
<https://orcid.org/0000-0002-5704-6187>

Juan Pablo Chuquín-Vasco<sup>III</sup>  
[juan.chuquin@esPOCH.edu.ec](mailto:juan.chuquin@esPOCH.edu.ec)  
<https://orcid.org/0000-0001-6680-507X>

Nelson Santiago Chuquín-Vasco<sup>IV</sup>  
[nelson.chuquin@esPOCH.edu.ec](mailto:nelson.chuquin@esPOCH.edu.ec)  
<https://orcid.org/0000-0001-8998-1156>

**Correspondencia:** [daniel.chuquin@esPOCH.edu.ec](mailto:daniel.chuquin@esPOCH.edu.ec)

Ciencias Técnicas y Aplicadas  
Artículo de Investigación

\* **Recibido:** 25 de abril de 2022 \* **Aceptado:** 20 de mayo de 2022 \* **Publicado:** 29 de Junio de 2022

- I. Ingeniero Químico, Escuela Superior Politécnica de Chimborazo (ESPOCH), Grupo de investigación en seguridad, ambiente e ingeniería (GISAI), Riobamba, Ecuador
- II. Ingeniero Químico, Investigador independiente, Riobamba, Ecuador.
- III. Ingeniero Mecánico, Escuela Superior Politécnica de Chimborazo (ESPOCH), Grupo de investigación en seguridad, ambiente e ingeniería (GISAI), Riobamba, Ecuador.
- IV. Ingeniero Mecánico, Escuela Superior Politécnica de Chimborazo (ESPOCH), Grupo de investigación en seguridad, ambiente e ingeniería (GISAI), Riobamba, Ecuador.

## Resumen

En el presente trabajo se diseñó una RNA que pueda predecir las salidas más importantes en el proceso de deshidratación de gas natural por absorción con TEG. Para la creación de la RNA se desarrolló un análisis de sensibilidad, mediante el cual se determinaron las salidas del proceso que fueron: fracción de agua en el gas a la salida, expresado en miligramos de agua por metros cúbicos estándar de gas seco, temperatura de gas seco y flujo de glicol que se pierde. Se realizaron experimentaciones para obtener un conjunto de 100 pares de datos para el entrenamiento y validación de la RNA. El software que se empleó fue MATLAB y se diseñó una RNA con 7 neuronas ocultas que se entrenó con el algoritmo de la regularización Bayesian. El MSE que se obtuvo en la fase de prueba fue de  $5.384e-04$  con un coeficiente de regresión de 0,997. Para la validación de la red se realizó un análisis estadístico con un conjunto de 20 datos adicionales, tomando en cuenta las mismas variables empleadas para el diseño. Se concluyó que con los resultados obtenidos no existió una diferencia significativa entre los valores experimentales y los valores predichos por la RNA con una confiabilidad del 95% y por tal razón puede ser empleada para la predicción en procesos de deshidratación de gas natural.

**Palabras clave:** ARN; DWSIM; gas natural; deshidratación; simulación.

## Abstract

In the present work, an RNA that can predict the most important outputs in the natural gas dehydration process by absorption with TEG was worked on. For the creation of the RNA, a sensitivity analysis was developed, through which the outputs of the process were determined, which were: fraction of water in the gas at the outlet, expressed in milligrams of water per standard cubic meters of dry gas, temperature of dry gas and glycol flow that is lost. Experiments were carried out to obtain a set of 100 pairs of data for the training and validation of the ANN. The software used was MATLAB and an ARN with 7 hidden neurons was developed and trained with the Bayesian regularization algorithm. The MSE obtained in the test phase was  $5,384e-04$  with a regression coefficient of 0.997. For the validation of the network, a statistical analysis was performed with a set of 20 additional data, taking into account the same variables used for the design. It was concluded that with the results obtained there was no significant difference between the experimental values and the values predicted by the RNA with a reliability of 95% and for this reason it can be used for the prediction in natural gas dehydration processes.

**Keywords:** ANN; DWSIM; natural gas; dehydration; simulation.

## Resumo

Neste trabalho, uma ANN foi concebida para prever os resultados mais importantes no processo de desidratação de gás natural por absorção com TEG. Para a criação da ANN, foi desenvolvida uma análise de sensibilidade, através da qual foram determinadas as saídas do processo: fracção de água no gás à saída, expressa em miligramas de água por metro cúbico padrão de gás seco, temperatura do gás seco e taxa de fluxo de glicol perdido. Foram realizadas experiências para obter um conjunto de 100 pares de dados para formação e validação da ANN. O software utilizado foi o MATLAB e um ANN com 7 neurónios escondidos foi concebido e treinado com o algoritmo de regularização Bayesian. O MSE obtido na fase de teste foi de  $5,384e-04$  com um coeficiente de regressão de 0,997. Para a validação da rede, foi realizada uma análise estatística com mais 20 conjuntos de dados, tendo em conta as mesmas variáveis utilizadas para o desenho. Concluiu-se que com os resultados obtidos não houve diferença significativa entre os valores experimentais e os valores previstos pela ANN com uma fiabilidade de 95% e por este motivo pode ser utilizada para a previsão de processos de desidratação de gás natural.

**Palavras-chave:** RNA; DWSIM; gás natural; desidratação; simulação.

## Introducción

El desarrollo de la industria petrolera trae consigo diversas formas de contaminación, que modifican el equilibrio del medio ambiente. La principal causa es la combustión de combustibles fósiles como petróleo, carbón, diesel, gasolina, provocando emisiones peligrosas que causan el efecto invernadero, la lluvia ácida y el smog. La composición del gas natural es irregular, pero su componente principal es el metano con un porcentaje mínimo de hasta el 88,5%, el resto de sustancias se encuentran en forma de gas o como líquidos.

“Existen diversas formas de realizar la deshidratación del gas, como: la absorción con glicoles, adsorción con tamices moleculares, delicuescencia, expansión-refrigeración, permeación del gas y la tecnología Twister”. (Ribón, 2010).

El método de absorción con absorbentes como el Trietilenglicol (TEG) ha sido el más utilizado en la producción industrial, que consta de dos fases. La primera es la absorción del agua presente en

el gas húmedo mediante un absorbedor, mientras que la segunda fase es la desorción del agua que queda atrapada en el solvente, paso que se da en una columna de destilación denominada regenerador. Esta segunda etapa es la más importante porque si no elimina el agua del glicol al momento que se dé su recirculación afectaría directamente a la calidad del gas (Yu et al., 2017).

Bahadori & Vuthaluru, (2009) determinaron una correlación fácil en la que se puede determinar la caída del punto de rocío que se dará a partir de una determinada concentración de TEG y temperatura de la torre de absorción, sabiendo que los puntos de rocío dependen de la velocidad de circulación del TEG y número de etapas en el equilibrio. Además, Bahadori & Vuthaluru, (2009b) desarrollaron un método para dimensionar la torre de absorción para una variedad de condiciones iniciales, mediante ecuaciones algebraicas de fácil resolución pudo correlacionar la eficiencia de remoción de agua en función de la velocidad de circulación del TEG como también de su concentración.

### **Simulación de procesos de deshidratación de gas natural**

En la actualidad, la simulación es una herramienta útil para analizar una variedad de problemas en investigación, síntesis de productos y desarrollo de procesos de producción (Mostaccio, 2007). C. et al., (2015) realizaron la simulación de una planta de deshidratación de gas natural por absorción convencional utilizando el software Aspen HYSYS. Con su trabajo determinaron que se requiere de un mínimo de 53 litros/hora de TEG para producir un gas seco con 6,455 lb/MMSCF D (libras de agua por millón de pies cúbicos estándar diarios de gas procesado). Para ello fueron variando el flujo de TEG y encontraron que una tasa mayor a 70 litros/hora no generaría un mayor valor financiero al gas seco.

El Mawgoud et al., ( 2015) mediante el uso de la simulación desarrollaron una renovación de la planta de deshidratación “Akik” ubicada en Egipto logrando reducir menor consumo de energía para el funcionamiento del proceso, así como también menor costo de inversión en los equipos.

Por otro lado, Nmegbu (2014) realizó una simulación en HYSYS para determinar los parámetros más influyentes en el procesos de deshidratación de gas natural. Los parámetros que analizó fueron: tasa de circulación de glicol, número de platos en la torre de absorción, temperatura del calderín, tasa de extracción de gas. Las condiciones iniciales se obtuvieron de una planta de deshidratación ubicada en Níger. Mediante la prueba se determinó que una temperatura mayor a los 200°C en el calderín ocasiona la descomposición del glicol. Por otra parte, la utilización de gas de arrastre genera un efecto mayor que solamente aumentar la temperatura del reboiler. Para obtener una

máxima eficiencia es recomendable que el gas de arrastre ingrese a la columna después de que se haya eliminado el glicol en el hervidor.

### **Redes neuronales aplicados a procesos químicos**

Respecto al uso de redes neuronales artificiales (RNAs), Mohammadi & Richon, (2007) utilizaron RNAs para determinar el contenido de agua en el gas natural a bajas temperaturas y presiones elevadas. Debido a que el contenido de agua que existe en esas condiciones es muy pequeño por lo que los modelos clásicos presentaban una menor precisión para determinar dicho valor.

Además, Darwish & Hilal (2008) utilizaron RNAs para detectar las fallas en una planta de deshidratación de gas natural analizando las perturbaciones de la torre de absorción, la torre de destilación (regenerador) y para la planta en general. Determinaron que la principal falla en la torre de absorción se da por concentraciones anormales de BTEX (benceno, tolueno, etilbenceno y xileno) en el glicol que sale de la torre. En el regenerador encontraron que las fallas se dan por emisiones de TEG y BTEX y en menor medida por COVs (compuestos orgánicos volátiles). Por último, para la planta general se determinó que las principales fallas son por las tres respuestas anteriormente mencionadas en los equipos analizados.

Por otro lado, Ghiasi et al., (2014) notaron que la obtención de glicol de alta pureza conllevaba diferentes inconvenientes, por lo que estudiaron el efecto de la presión y temperatura en el recalentador utilizando RNAs a fin de obtener una mayor pureza de TEG. Los resultados mostraron que al modificar la temperatura (149°C a 204°C) y presión (67 kPa a 122 kPa) llegaron a obtener hasta una pureza del 99,8% de TEG con una desviación absoluta promedio de 0,30%.

Ghiasi et al., (2015) aplicaron redes neuronales MLP (perceptrón multicapa) y una LSSVM (algoritmo de máquina de vectores de soporte de mínimos cuadrados) y establecieron que la inyección de gas arrastre en el rehervidor es una manera eficaz de aumentar la pureza del TEG.

Ahmadi et al., (2014) desarrollaron un método confiable para estimar el punto de rocío del agua presente en una corriente de gas natural a diferentes concentraciones y temperaturas de TEG, aplicando RNAs del tipo PSO (optimización de enjambre de partículas) y el BP (retropropagación). Su trabajo determinó que la red entrenada con el algoritmo PSO presentó una mejor precisión en la predicción del punto de rocío del agua respecto al algoritmo BP. Por otro lado, Afshin et al., (2016) también desarrolló un método con el cual determinar la temperatura del punto de rocío del gas, usando el perceptrón multicapa y la red neuronal de función en base radial (RBF-RNA).

Determinaron que el modelo MLP muestra una superioridad sobre el modelo RBF y también sobre los modelos propuestos por (26)

Como puede notarse existen varias investigaciones que aplican RNAs en procesos de deshidratación de gas natural, pero, en la mayoría determinan la concentración del glicol y el punto de rocío del gas. En este sentido, este trabajo desarrolla una RNA que pueda predecir la pérdida de glicol del regenerador, la cantidad de agua y temperatura presente en el gas seco. Una de las ventajas de crear una RNA es que, mediante su validación, se desarrolla una herramienta que puede sustituir el proceso de la obtención de datos por investigación y/o simulación que en ocasiones resultaba un proceso tedioso y costoso. La ventaja sobre la simulación es que ANN puede aprender directamente de un proceso y dar tiempos de respuesta más cortos, lo que permite modelar los sistemas de una manera más compleja y realista (Sánchez-Escalona et al., 2018; Ye et al., 2019).

## **Metodología**

### **Descripción del Proceso**

En la Figura 1 se muestra el proceso de deshidratación de gas natural por absorción con TEG, basado en la propuesta de (18). Los equipos principales son: Torre de absorción (ABS-01), separador flash (SEP-01), columna de destilación (regenerador) y un “stripper”, adicionalmente se usaron calentadores, enfriadores y bombas, a fin de obtener las temperaturas y presiones requeridas del proceso.

El gas natural ingresa a la torre de absorción por la parte inferior mientras que el TEG lo hace por la parte superior. El gas seco sale de la torre por arriba y el glicol rico en agua por abajo. A continuación, se lleva a cabo el proceso de recuperación del TEG. El glicol rico se dirige al condensador del regenerador en el que aumenta su temperatura y con ello se pueda liberar de hidrocarburos ligeros en el separador flash, después ingresa a la torre de regeneración para desprenderse del contenido de agua que ha acumulado. Una vez que se elimina la mayor cantidad de agua, el glicol se dirige al “stripper”, y es aquí, donde a través de la inyección de gas de arrastre se logra eliminar una cantidad extra de agua para que el gas alcance una pureza del 99,5 %. El glicol pobre sale del stripper por la parte inferior y se recircula, pero antes de llegar a la torre de absorción pasa por un mezclador donde se le agrega glicol de reposición (Make-up) para solventar las pérdidas que se producen en el proceso, principalmente en el regenerador.

La principal ventaja de colocar el “stripper” respecto al proceso convencional es poder elevar la pureza del TEG, que sin este equipo solo alcanzaría un 99 % lo cual repercutirá directamente con la calidad de gas seco obtenido.

Los datos de alimentación de gas natural, TEG y gas de arrastre, como también las condiciones de operación de los equipos usados se tomarán de (18), los mismos que se detallan en las Tablas 1-5.

**Tabla 1:** Condiciones de la alimentación de gas natural

<b>Parámetro</b>	<b>Valor</b>	<b>Unidad</b>
<b>Presión (absoluta)</b>	4137	KPa
<b>Temperatura</b>	310.90	K
<b>Flujo másico de gas natural</b>	19.19	Kg/s
<b>Fracción másica de C<sub>1</sub></b>	84.20	%
<b>Fracción másica de C<sub>2</sub></b>	15.61	%
<b>Fracción másica de H<sub>2</sub>O</b>	0.19	%

Fuente: Autores, 2022

**Tabla 2:** Condiciones de operación de la torre de absorción (ABS-01)

<b>Parámetros</b>	<b>Valor</b>	<b>Unidad</b>
<b>Presión (absoluta)</b>	4137	KPa
<b># de Platos de la columna</b>	2	-

Fuente: Autores, 2022

**Tabla 3:** Condiciones de operación del separador (SEP-01)

<b>Parámetros</b>	<b>Valor</b>	<b>Unidad</b>
<b>Presión (absoluta)</b>	532	KPa

Fuente: Autores, 2022

**Tabla 4:** Condiciones de operación de la torre de destilación (Regenerador)

<b>Parámetros</b>	<b>Valor</b>	<b>Unidad</b>
<b>Presión (absoluta)</b>	101.325	KPa
<b># de Platos de la columna</b>	3	-
<b># Plato de alimentación</b>	2	-
<b>Calor del condensador</b>	-52	kW
<b>Calor del reboiler</b>	159.5	kW

Fuente: Autores, 2022



químicos. Mediante este software se podrá reproducir virtualmente el proceso mejorado de deshidratación de gas natural con TEG y obtener el conjunto de datos necesarios para la creación de la red neuronal.

Mediante una revisión bibliográfica (Dimian et al., 2014; Kiss, 2013; Soave et al., 2010) se determinó que los paquetes termodinámicos más idóneos para el proceso son: Peng-Robinson, NRTL y UNIQUAC, por lo tanto, para el desarrollo de la simulación se empleó una combinación de los 3 paquetes termodinámicos mencionados, tanto para los equipos y las líneas de flujo, con el propósito de lograr una mejor aproximación de los resultados.

### **Análisis de Sensibilidad**

Se tomarán en cuenta 3 variables de salida específicas, las mismas que a criterio personal son las más importantes del proceso: temperatura de gas seco, fracción de agua en el gas seco y flujo de glicol perdido en el regenerador, mientras que las variables de entrada se las obtendrá a partir de un análisis de sensibilidad mostrado en la Tabla 6.

**Tabla 6:** Resultados del análisis de sensibilidad

<b>Entradas</b>		<b>Salidas</b>		
<b>Variable</b>	<b>Rango</b>	<b>Temperatura de gas seco (K)</b>	<b>Fracción de agua a la salida (%)</b>	<b>Flujo de glicol perdido (kg/s)</b>
<b>Calor del condensador (kW)</b>	25 - 100	-	-	0.00074 – 1.92E-06
<b>Fracción de agua inicial (%)</b>	0.01 - 1	312.307 – 321.72	0.0044 – 0.046	0.00047 – 7.16E-06
<b>Temperatura inicial del gas (K)</b>	290 - 417	293.63 – 415.08	0.0021 – 0.187	5.29E-06 – 0.354
<b>Presión del absorbedor (Pa)</b>	107392 - 4907126	292.36 – 317.38	0.145 – 0.0118	2.34E-05 – 1.71E-05
<b>Calor del reboiler (kW)</b>	70 - 334	-	-	9.13E-07 – 0.1551

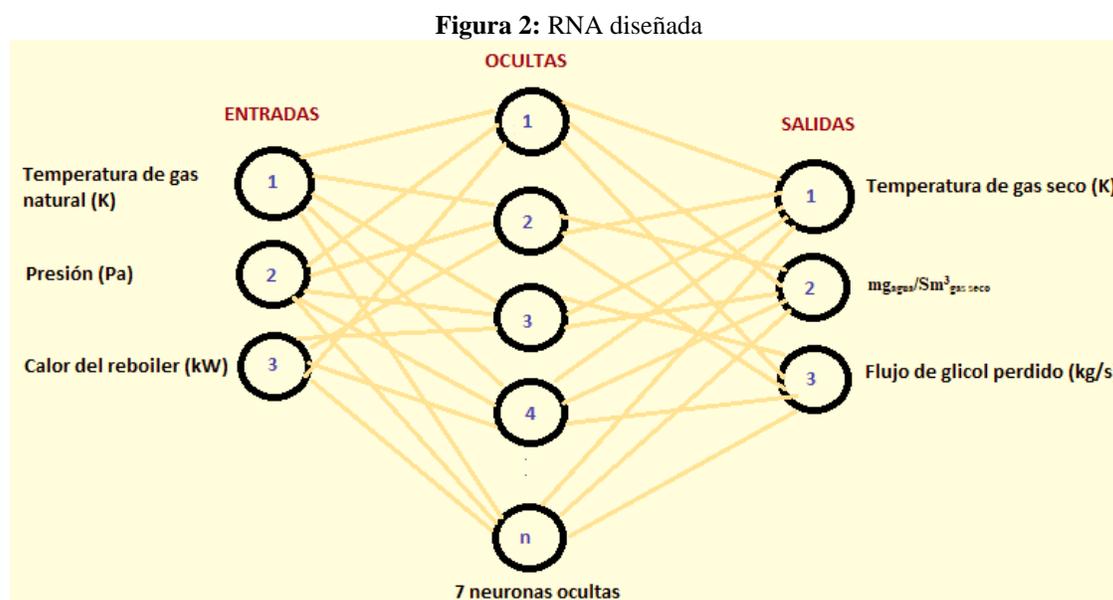
Fuente: Autores, 2022

Con base en los análisis de la Tabla 6, se optó por trabajar con una pureza constante del glicol, por lo que se eliminó la recirculación del TEG, tanto el calor del reboiler como el calor del condensador no mostraron influencia en la temperatura de gas seco ni en la fracción de agua a la salida debido a la eliminación de la recirculación, las variables que mostraron más cambio en los resultados respecto a los valores óptimos del proceso son la temperatura inicial del gas, presión del absorbedor y el calor del reboiler.

### Diseño y entrenamiento de la RNA

Después del análisis sensibilidad, se realizó el diseño de la RNA (Figura 2) con tres (3) variables de entrada: temperatura inicial del gas natural, presión del absorbedor y el calor del reboiler; y tres (3) variables de salida: temperatura de gas seco, fracción de agua en el gas seco expresado en miligramos de agua por metro cúbico estándar de gas seco ( $\text{mg}_{\text{agua}}/\text{Sm}^3_{\text{gas seco}}$ ) y flujo de glicol perdido en el regenerador.

Una vez validado el proceso de la simulación en DWSIM, se procedió a generar una base de 120 datos, mismos que provenían de la variación de los parámetros operación y/o funcionamientos seleccionados para el estudio. En la Tabla 7, se detalla el rango de variación de las entradas.



**Tabla 7:** Variables de entrada y restricciones de la RNA

<b>Variable</b>	<b>Temperatura de gas natural (<math>T_{\text{gas}} \text{ húmedo}</math>)</b>	<b>Presión del absorbedor (<math>P_{\text{abs}}</math>)</b>	<b>Calor del reboiler (<math>Q_{\text{reb}}</math>)</b>
<b>Unidad</b>	K	Pa	kW
<b>Valor base</b>	310.9	4137000	159.5
<b>Rango</b>	290 - 417	107392 - 4907126	70 - 334

Fuente: Autores, 2022

Con base en el estudio de Chen et al., (2020), para el entrenamiento de la red, se utilizó el 70 % del total de pares de datos (100 conjuntos de datos), mientras que el 30 % (20 conjuntos de datos) se utilizó para realizar una prueba para validar su nivel de aprendizaje. El entrenamiento de la ARN ajusta los pesos de las conexiones entre las neuronas para que la ARN haga predicciones adecuadas con respecto a los datos de salida objetivo. La validación mide los errores de predicción de la ANN para evaluar su rendimiento. El proceso de prueba evalúa la predicción de ANN usando pares de datos que no se usaron en el proceso de entrenamiento (Chuquin-Vasco et al., 2021).

Para validar la red neuronal artificial y demostrar la confiabilidad del modelo para la predicción de las principales fracciones molares en el sistema alternativo se utilizaron los indicadores de desempeño: error cuadrático medio (MSE) y coeficiente de regresión lineal (R) mediante las Ec. (1) y Ec. (2) y adicionalmente un análisis de varianza ANOVA.

$$R = \frac{n \sum_{i=1}^n (y' y) - [\sum_{i=1}^n y'] [\sum_{i=1}^n y]}{\sqrt{[n \sum_{i=1}^n y^2 - [\sum_{i=1}^n y]^2] [n \sum_{i=1}^n y'^2 - [\sum_{i=1}^n y']^2]}}, \quad (1)$$

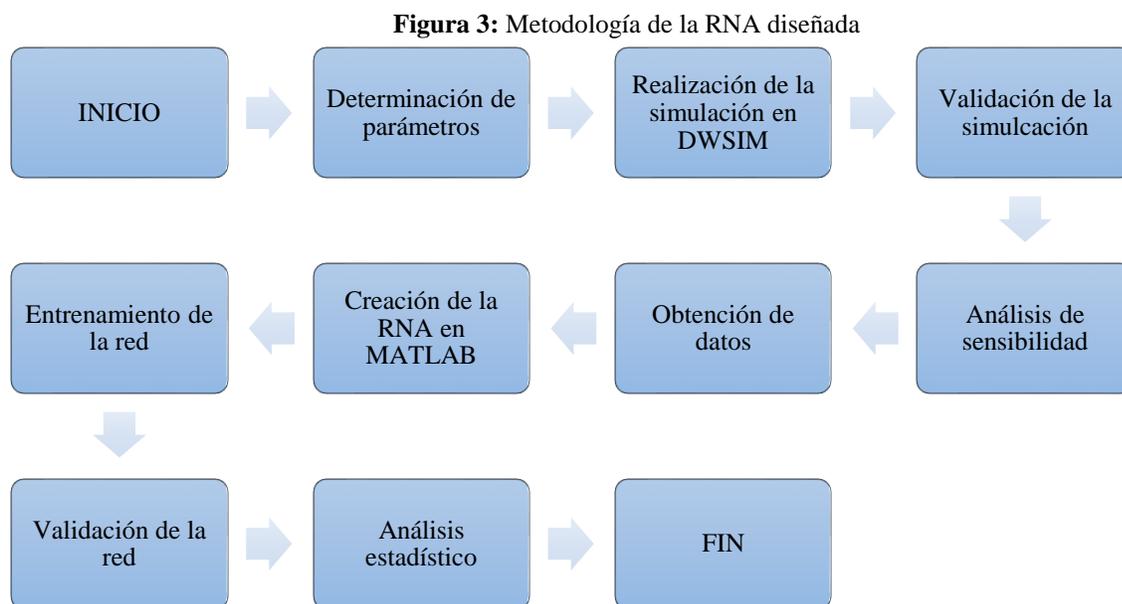
$$\text{MSE} = \frac{1}{n} \sum_{t=1}^n (y_t - y'_t)^2, \quad (2)$$

Donde n es el número de observaciones; y, son los resultados reales (salidas de la simulación en DWSIM); y' son los resultados predichos (salidas de la ARN).

### Descripción de la metodología

La primera parte del trabajo es realizar la simulación del proceso que se muestra en la Fig 1, basándose en las condiciones de los flujos de entrada y parámetros de los equipos que se especificaron anteriormente. Posterior a eso, se hace el análisis de sensibilidad a fin de determinar

las variables de entrada y salida que se ocuparan para crear la RNA. Finalmente, se realiza el entrenamiento y validación de la RNA mediante un análisis estadístico con el objetivo de evaluar su capacidad de predicción. La Fig. 3 ilustra el diagrama de flujo de la metodología.



Fuente: Autores, 2022

## Resultados

### Validación de la simulación

Para la creación de la RNA es necesario validar los resultados de la simulación en DWSIM con bibliografía. Es por eso, que se optó por utilizar el trabajo hecho por Chebbi et al., (2019) para la validación. En las Tablas 8-10 se detalla la comparación de los resultados de la validación.

**Tabla 8:** Validación de la simulación (Gas a almacenar)

Equipo	Parámetro	Chebbi et al., (2019)	DWSIM	Error (%)
ABS-01	Temperatura (K)	314.1	314.085	0.004
	Flujo másico total (kg/s)	19.156	19.156	0.002
	Fracción másica de HC (%)	99.986	99.987	0.000
	Fracción másica de agua (%)	0.013	0.0123	5.238

Fuente: Autores, 2022

**Tabla 9:** Validación de la simulación (Salida del Agua)

Equipo	Parámetro	Chebbi et al., (2019)	DWSIM	Error (%)
Regenerador	Temperatura	372	372.089	0.023
	Flujo másico total (kg/s)	0.037	0.037	0.160
	Flujo másico de agua (kg/s)	0.033	0.034	0.351

Fuente: Autores, 2022

**Tabla 10:** Validación de la simulación (TEG-REC)

Equipo	Parámetro	Chebbi et al., (2019)	DWSIM	Error (%)
Recirculación	Temperatura (K)	319.3	319.127	0.054
	Flujo másico total (kg/s)	0.643	0.643	0.017
	Fracción másica de TEG (%)	99.500	990.505	0.005

Fuente: Autores, 2022

### Selección del número de neurona en la capa oculta

Después de seguir un enfoque de prueba y error combinado el método de generación dinámica y a su vez con base en el mejor coeficiente de determinación R del entrenamiento.

En la Tabla 11, se resumen los ensayos seleccionados con los valores correspondientes de correlación lineal (R) y de error cuadrático medio (MSE) para varias topologías de red. En base al análisis, luego del proceso de entrenamiento, se determina que la estructura óptima de la RNA (MSE min =7.56E-4 y R máx = 0.997) emplea el algoritmo regularización bayesiana (BR) y tiene una capa oculta con 10 neuronas. La ventaja de un algoritmo BR es su capacidad para predecir relaciones complejas y su capacidad para tomar decisiones menos sesgadas (Garoosiha et al., 2019; Suliman & Omarov, 2018).

**Tabla 11:** Valores de R y MSE para determinar el número óptimo de neuronas en la capa oculta

# De neuronas	Tipo de algoritmo	MSE	R
10	Levenberg-Marquardt	1.20E-03	0.995
	Regularización Bayesiana	7.56E-04	0.997
20	Levenberg-Marquardt	2.24E-03	0.990
	Regularización Bayesiana	1.87E-03	0.990
40	Levenberg-Marquardt	1.31E-02	0.942
	Regularización Bayesiana	4.17E-03	0.981
60	Levenberg-Marquardt	1.80E-02	0.936
	Regularización Bayesiana	3.03E-03	0.985
80	Levenberg-Marquardt	9.62E-02	0.709
	Regularización Bayesiana	3.29E-03	0.985
100	Levenberg-Marquardt	2.97E-02	0.858
	Regularización Bayesiana	1.93E-03	0.990

Fuente: Autores, 2022

### Entrenamiento y fase de evaluación de la RNA

Las principales pruebas de validación para la modelación de procesos son el error cuadrático medio (MSE) y el coeficiente de correlación lineal R. La Tabla 12 muestra el valor de los parámetros para las fases de entrenamiento y prueba de la RNA.

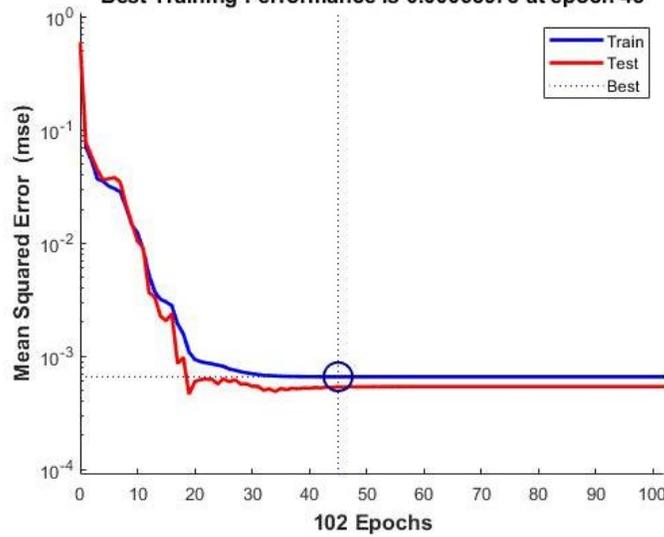
**Tabla 12:** Valores de R y MSE de la RNA diseñada para el proceso

Etapa	MSE	R
Entrenamiento	6.59E-04	0.996
Evaluación	5.38E-04	0.997

Fuente: Autores, 2022

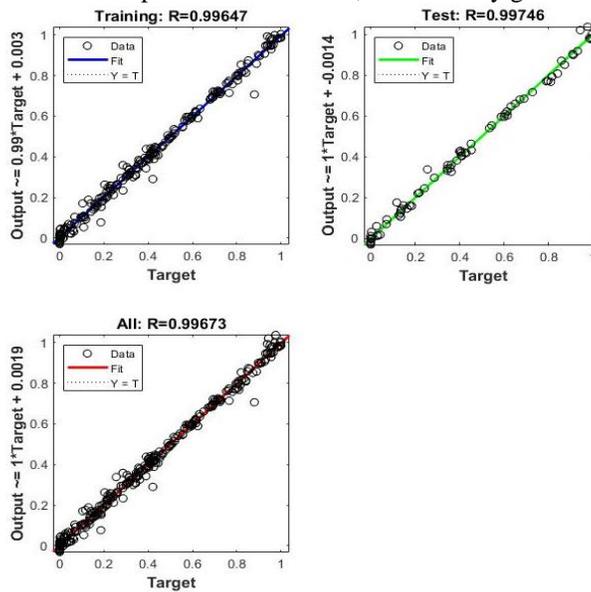
Como se observa en la Tabla 12 los valores del MSE son muy cercanos a 0 y el R está próximo al 1, lo que sugiere que la RNA funciona de forma adecuada y que las predicciones se realizan con gran precisión. Las Figuras 4 y 5 muestran la evolución del MSE y R respectivamente.

**Figura 4:** Evolución del MSE en la RNA  
**Best Training Performance is 0.00065978 at epoch 45**



Fuente: Autores,2022

**Figura 5:** R de la etapa de entrenamiento, evaluación y global de la RNA



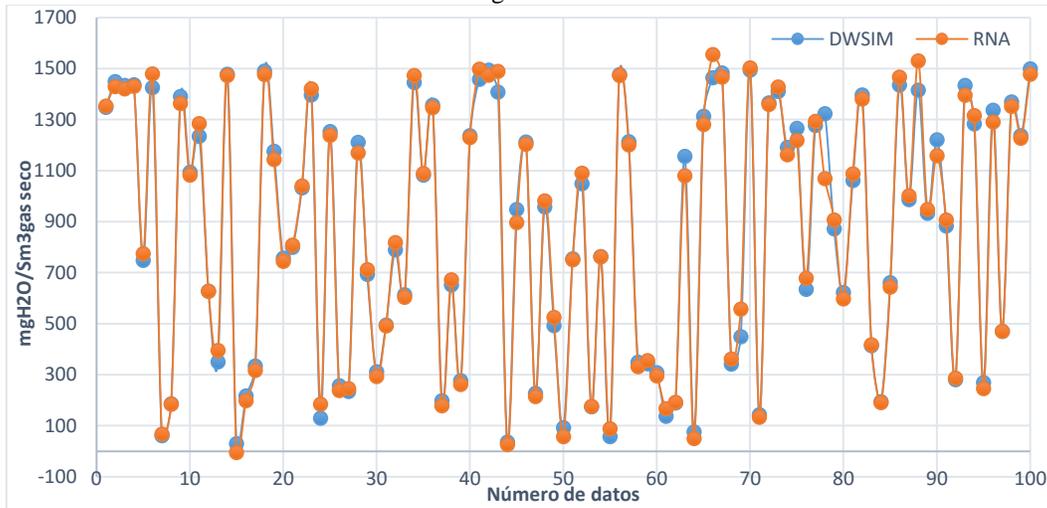
Fuente: Autores,2022

### Modelo de predicción de la RNA

Las Figuras 6, 7, 8 muestran las predicciones (RNA) y los valores experimentales (DWSIM) para la temperatura de gas seco, los miligramos de agua por metro cúbico estándar de gas seco y el flujo

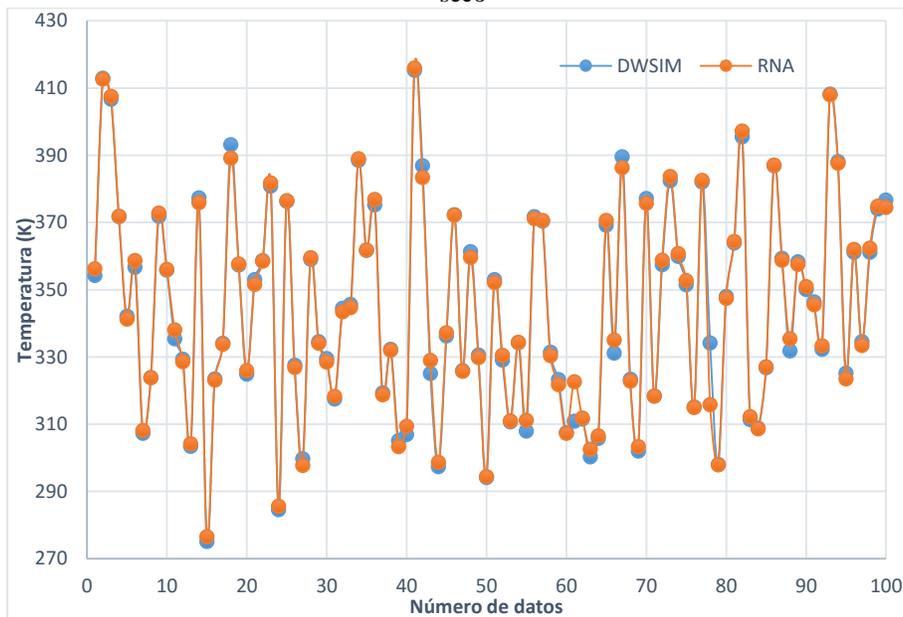
de glicol perdido. Se puede evidenciar que las diferencias existentes entre dichos valores (predichos y reales) son despreciables.

**Figura 6:** Comparación entre las experimentaciones (DWSIM) y las predicciones (RNA) del residuo de agua en el gas seco

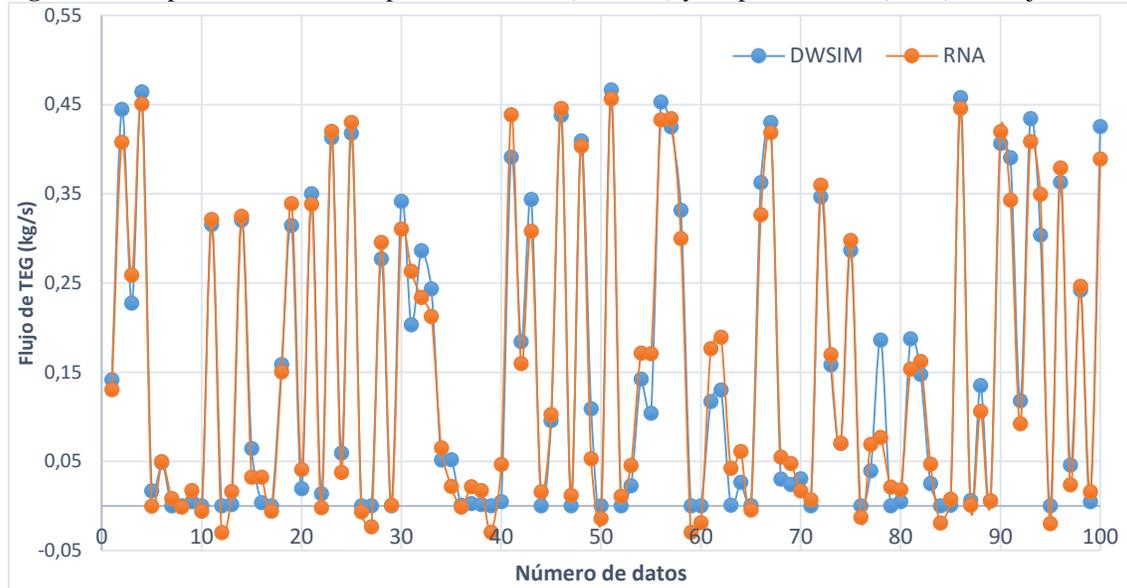


Fuente: Autores,2022

**Figura 7:** Comparación entre las experimentaciones (DWSIM) y las predicciones (RNA) de la temperatura del gas seco



Fuente: Autores,2022

**Figura 8:** Comparación entre las experimentaciones (DWSIM) y las predicciones (RNA) del flujo de TEG

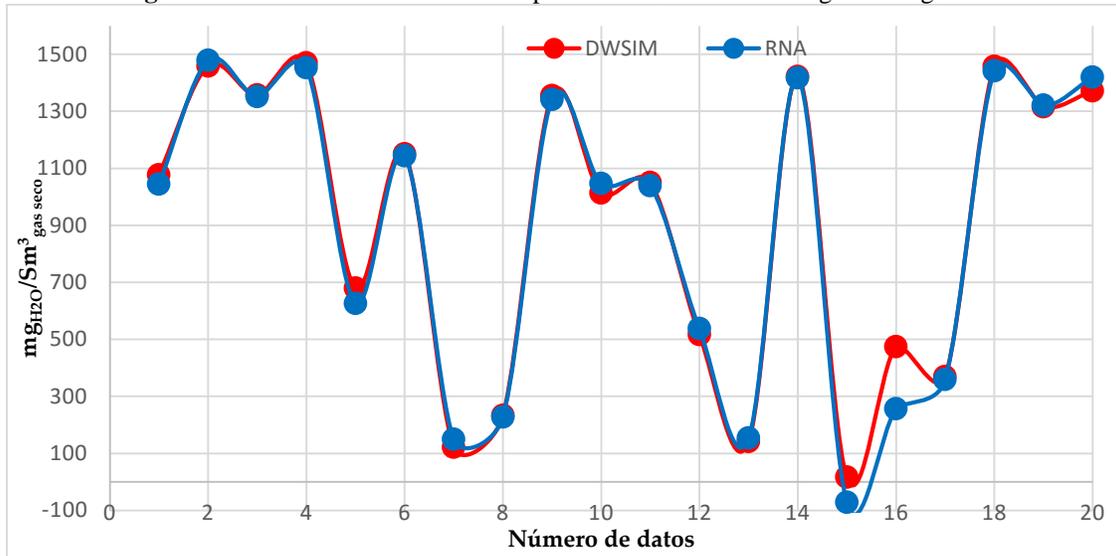
Fuente: Autores,2022

Como se observa en la Figura 8 hay una mayor dispersión de los valores respecto a las Figuras 6-7, esto se debe a la presencia de datos atípicos que incluyen valores negativos o excesivamente pequeños que se obtuvieron por parte de la RNA. El error porcentual promedio en la predicción del flujo de TEG fue de 8,96%, mientras que para los  $\text{mg}_{\text{H}_2\text{O}}/\text{Sm}^3_{\text{gas seco}}$  el error fue de: 6,57% y para la temperatura de gas seco fue de 0,39%.

### Validación de la RNA

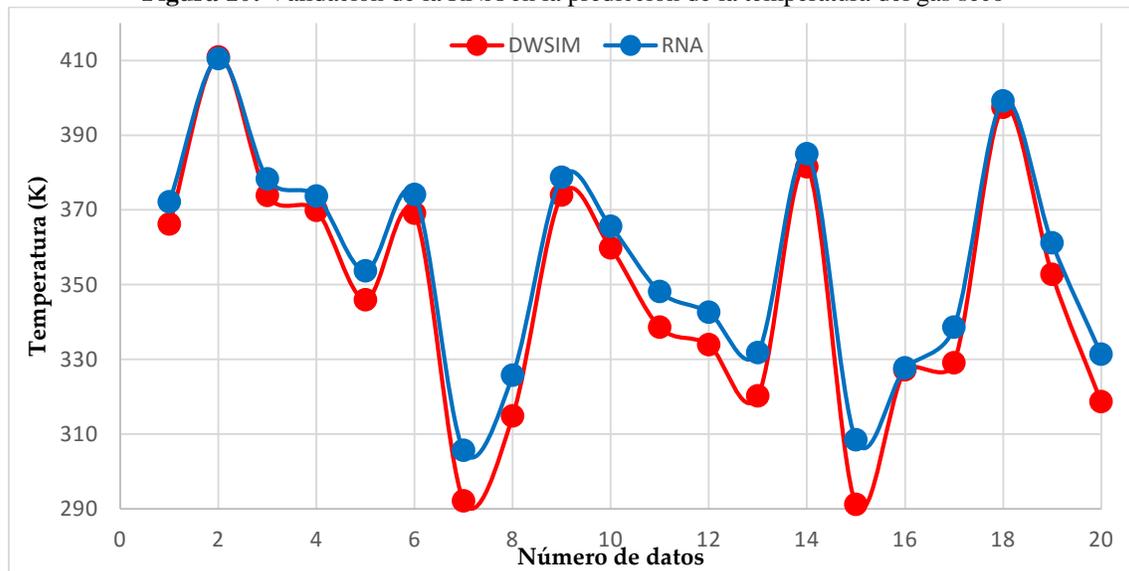
La capacidad predictiva de la RNA de la se probó con un conjunto de 20 datos de entrada aleatorios desconocidos por la RNA. Los resultados (Figuras 9 – 11) muestran una superposición entre los datos experimentales (DWSIM) y las predicciones (RNA). Esto indica que ANN tiene una buena capacidad predictiva de las salidas analizadas. Sin embargo, se pueden observar datos atípicos. Por tal razón, se desarrolló un análisis estadístico ANOVA para validar estadísticamente la funcionalidad de la RNA diseñada. La Tabla 13 muestra los resultados de ANOVA, para todos los casos, los valores P (P-value) son mayores que 0,05, lo que indica que no existe una diferencia estadísticamente significativa entre las medias de las observaciones y las predicciones. Estas pruebas estadísticas revelan que la ANN construida es estadísticamente válida para la predicción del flujo de TEG,  $\text{mg}_{\text{H}_2\text{O}}/\text{Sm}^3_{\text{gas seco}}$  y la temperatura del gas seco.

Figura 9: Validación de la RNA en la predicción del residuo de agua en el gas seco



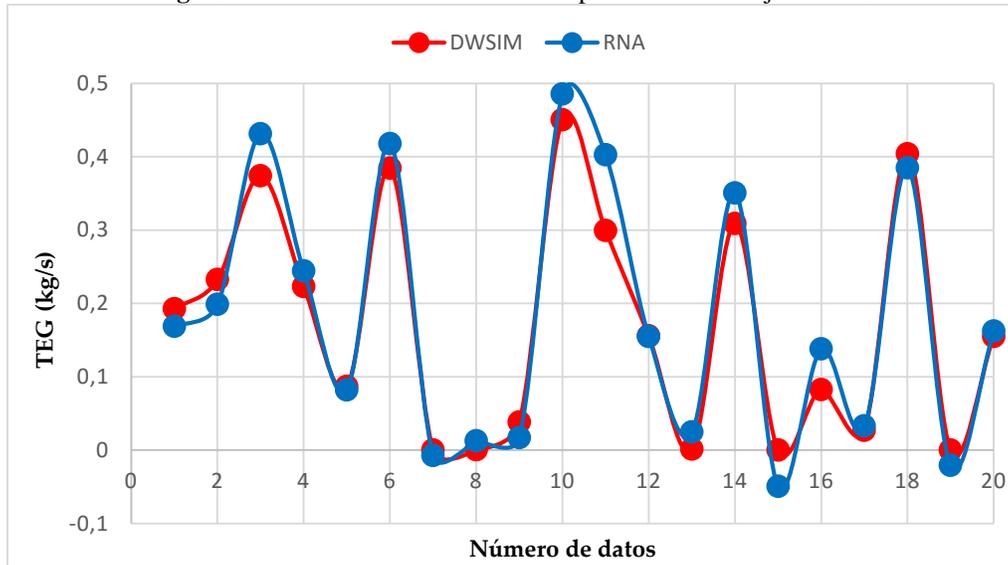
Fuente: Autores,2022

Figura 10: Validación de la RNA en la predicción de la temperatura del gas seco



Fuente: Autores,2022

**Figura 11:** Validación de la RNA en la predicción del flujo de TEG



Fuente: Autores, 2022

**Tabla 13:** ANOVA

Fuente	Suma de cuadrados	G1	Cuadrado medio	Razón-F	Valor-P
<b>Residuo de agua en el gas seco (mg<sub>H2O</sub>/Sm<sup>3</sup><sub>gas seco</sub>)</b>					
Entre grupos	2413.11	1	2413.11	0.01	0.9271
Intra grupos	1.08E+07	38	284782		
Total (Corr.)	1.08E+07	39			
<b>Temperatura de gas seco (K)</b>					
Entre grupos	525.13	1	525.13	0.55	0.4637
Intra grupos	36410.7	38	958.176		
Total (Corr.)	36935.8	39			
<b>Flujo de TEG perdido (kg/s)</b>					
Entre grupos	0.0011651	1	0.0011651	0.04	0.8376
Intra grupos	1.03921	38	0.0273476		
Total (Corr.)	1.04038	39			

Fuente: Autores, 2022

## Conclusiones

En el presente trabajo se diseñó una RNA con la finalidad de predecir productos en el proceso de deshidratación de gas natural por absorción con Trietilenglicol, a partir de un conjunto 120 datos obtenidos por simulación en DWSIM. Las entradas y salidas de la RNA se determinaron a partir de un análisis de sensibilidad dando como resultado 3 variables de entrada y 3 de salida.

La RNA fue entrenada con el algoritmo de la regularización Bayesiana con 10 neuronas ocultas. El MSE y R calculados fueron de  $5.382E-04$  y  $0,996$  respectivamente. Adicionalmente se validó la red mediante un análisis ANOVA comparando los valores simulados y los valores predichos, y basándose en los resultados se deduce que con un nivel de significancia del 95% no existe una diferencia significativa entre los valores simulados y los predichos, por lo que se acepta la RNA creada y se recomienda su uso para procesos de deshidratación de gas natural por absorción con TEG.

## Referencias

1. Afshin, T., Ali, B. H., Hossein, M., Saeid, N., Meysam, B., Moonyong, L., Alireza, B., & Adel, N. M. (2016). Prediction of water formation temperature in natural gas dehydrators using radial basis function (RBF) neural networks. *Natural Gas Industry B*, 3(2), 173–180. <https://doi.org/10.1016/j.ngib.2016.06.002>
2. Ahmadi, M. A., Soleimani, R., & Bahadori, A. (2014). A computational intelligence scheme for prediction equilibrium water dew point of natural gas in TEG dehydration systems. *Fuel*, 137(August), 145–154. <https://doi.org/10.1016/j.fuel.2014.07.072>
3. Bahadori, A., & Vuthaluru, H. B. (2009a). Rapid estimation of equilibrium water dew point of natural gas in TEG dehydration systems. *Journal of Natural Gas Science and Engineering*, 1(3), 68–71. <https://doi.org/10.1016/j.jngse.2009.08.001>
4. Bahadori, A., & Vuthaluru, H. B. (2009b). Simple methodology for sizing of absorbers for TEG (triethylene glycol) gas dehydration systems. *Energy*, 34(11), 1910–1916. <https://doi.org/10.1016/j.energy.2009.07.047>
5. C., E. C., N., U. C., E., O. E., & J., I. O. (2015). Natural Gas Dehydration With Triethylene Glycol (Teg). *European Scientific Journal*, 11(30), 1857–7881. <https://ejournal.org/index.php/esj/article/view/6352>
6. Chebbi, R., Qasim, M., & Abdel Jabbar, N. (2019). Optimization of triethylene glycol dehydration of natural gas. *Energy Reports*, 5, 723–732. <https://doi.org/10.1016/j.egyr.2019.06.014>
7. Chen, Y., Song, L., Liu, Y., Yang, L., & Li, D. (2020). A review of the artificial neural network models for water quality prediction. *Applied Sciences (Switzerland)*, 10(17). <https://doi.org/10.3390/app10175776>

8. Chuquin-Vasco, D., Parra, F., Chuquin-Vasco, N., Chuquin-Vasco, J., & Lo-iacono-, V. (2021). *Prediction of methanol production in a carbon dioxide hydro- generation plant using neural networks*.
9. Darwish, N. A., & Hilal, N. (2008). Sensitivity analysis and faults diagnosis using artificial neural networks in natural gas TEG-dehydration plants. *Chemical Engineering Journal*, 137(2), 189–197. <https://doi.org/10.1016/j.cej.2007.04.008>
10. Dimian, A. C., Bildea, C. S., & Kiss, A. A. (2014). Introduction in Process Simulation. In *Integrated Design and Simulation of Chemical Processes* (Second, Vol. 35, pp. 35–71). Elsevier. <https://doi.org/10.1016/B978-0-444-62700-1.00002-4>
11. El Mawgoud, H. A., Elshiekh, T. M., & Khalil, S. A. (2015). Process simulation for revamping of a dehydration gas plant. *Egyptian Journal of Petroleum*, 24(4), 475–482. <https://doi.org/10.1016/j.ejpe.2015.01.001>
12. Garoosiha, H., Ahmadi, J., & Bayat, H. (2019). The assessment of Levenberg–Marquardt and Bayesian Framework training algorithm for prediction of concrete shrinkage by the artificial neural network. *Cogent Engineering*, 6(1). <https://doi.org/10.1080/23311916.2019.1609179>
13. Ghiasi, M. M., Bahadori, A., & Zendehboudi, S. (2014). Estimation of triethylene glycol (TEG) purity in natural gas dehydration units using fuzzy neural network. *Journal of Natural Gas Science and Engineering*, 17, 26–32. <https://doi.org/10.1016/j.jngse.2013.12.008>
14. Ghiasi, M. M., Bahadori, A., Zendehboudi, S., & Chatzis, I. (2015). Rigorous models to optimise stripping gas rate in natural gas dehydration units. *Fuel*, 140(October), 421–428. <https://doi.org/10.1016/j.fuel.2014.09.084>
15. Kiss, A. A. (2013). *Advanced distillation technologies - Design, Control and Applications* (J. Wiley (ed.); First). Wiley. <https://studylib.es/doc/8807869/-anton-a.-kiss--advanced-distillation-technologies-z-lib>
16. Mohammadi, A. H., & Richon, D. (2007). Use of artificial neural networks for estimating water content of natural gases. *Industrial and Engineering Chemistry Research*, 46(4), 1431–1438. <https://doi.org/10.1021/ie060494u>
17. Mostaccio, D. J. (2007). *Simulación de altas prestaciones para modelos orientados al individuo*. 146.

- <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Simulacion+de+altas+p+restaciones+para+modelos+orientados+al+individuo#0>
18. Nmegbu Chukwuma Godwin Jacob. (2014). Optimization of Triethylene Glycol (Teg) Dehydration in a Natural Gas Processing Plant. *International Journal of Research in Engineering and Technology*, 03(06), 346–350. <https://doi.org/10.15623/ijret.2014.0306064>
  19. Ribón, H. (2010). Métodos De Deshidratación De Gas Natural. *Revista ...*, 8, 55–64. <http://revistas.uis.edu.co/index.php/revistafuentes/article/view/1633>
  20. Sánchez-Escalona, A. A., Góngora-Leyva, E., & Zalazar-Oliva, C. (2018). Predicción de la resistencia térmica de las incrustaciones en los enfriadores de ácido sulfhídrico. *Minería y Geología*, 34(3), 90–100. [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S1993-80122018000300008&lng=es&nrm=iso&tlng=es](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1993-80122018000300008&lng=es&nrm=iso&tlng=es)
  21. Soave, G., Gamba, S., & Pellegrini, L. A. (2010). SRK equation of state: Predicting binary interaction parameters of hydrocarbons and related compounds. *Fluid Phase Equilibria*, 299(2), 285–293. <https://doi.org/10.1016/j.fluid.2010.09.012>
  22. Suliman, A., & Omarov, B. (2018). Applying Bayesian Regularization for Acceleration of Levenberg Marquardt based Neural Network Training. *International Journal of Interactive Multimedia and Artificial Intelligence*, 5(1), 68. <https://doi.org/10.9781/ijimai.2018.04.004>
  23. Ye, R. P., Ding, J., Gong, W., Argyle, M. D., Zhong, Q., Wang, Y., Russell, C. K., Xu, Z., Russell, A. G., Li, Q., Fan, M., & Yao, Y. G. (2019). CO<sub>2</sub> hydrogenation to high-value products via heterogeneous catalysis. In *Nature Communications* (Vol. 10, Issue 1). Springer US. <https://doi.org/10.1038/s41467-019-13638-9>
  24. Yu, G., Dai, C., Wu, L., & Lei, Z. (2017). Natural Gas Dehydration with Ionic Liquids. *Energy and Fuels*, 31(2), 1429–1439. <https://doi.org/10.1021/acs.energyfuels.6b02920>