

## ARTÍCULOS

Tendencia corrosiva por CO<sub>2</sub> del gas natural basada en su composición mediante Redes Neuronales Artificiales

CO<sub>2</sub> corrosion trend of natural gas based on its composition using Artificial Neural Networks

Tomás Darío Marín-Velásquez<sup>1</sup>



[tmarin@udo.edu.ve](mailto:tmarin@udo.edu.ve)

<sup>1</sup> Universidad de Oriente.  
Unidad de Postgrado. 6201.  
Maturín, Estado Monagas, Venezuela.

### FIGEMPA: Investigación y Desarrollo

Universidad Central del Ecuador, Ecuador

ISSN-e: 2602-8484

Periodicidad: Semestral

vol. 18, núm. 2, 2024

[revista.figempa@uce.edu.ec](mailto:revista.figempa@uce.edu.ec)

Recepción: 02 enero 2024

Aprobación: 27 junio 2024

DOI: <https://doi.org/10.29166/revfig.v18i2.5989>

Autor de correspondencia:

[tmarin@udo.edu.ve](mailto:tmarin@udo.edu.ve)



Esta obra está bajo una Licencia Creative Commons Atribución 4.0 Internacional (CC BY 4.0)

**Cómo citar:** Marín-Velásquez, T. D. (2024). Tendencia corrosiva por CO<sub>2</sub> del gas natural basada en su composición mediante Redes Neuronales Artificiales. *FIGEMPA: Investigación y Desarrollo*, 18(2), 01-13.

<https://doi.org/10.29166/revfig.v18i2.5989>

### RESUMEN

La corrosión es un problema recurrente en la industria del gas natural, debido a la presencia de gases corrosivos como el CO<sub>2</sub> y el H<sub>2</sub>S que en presencia de agua pueden atacar el acero y producir daños y fugas que generen accidentes y contaminación, es por ello que la predicción de la tendencia del gas natural hacia la corrosión es fundamental para desarrollar estrategias de inhibición y mitigación de este proceso. El objetivo del estudio fue desarrollar una Red Neuronal Artificial (RNA) entrenada con datos de composición de muestras de gas natural para predecir la tendencia corrosiva, como método alternativo que pueda ser utilizado como una herramienta predictiva eficiente. La RNA se entrenó con una muestra de 46 gases naturales y 11 componentes por cada una, además de la presión y la temperatura como condiciones operacionales, lo que representa un total de 598 datos de entrenamiento de la RNA, además se utilizaron 8 muestras adicionales para la validación externa del modelo. La RNA que desarrolló fue dentro de los principios de la estadística Bayesiana, con una arquitectura de Perceptrón Multicapa. Se obtuvo que la RNA es capaz de clasificar correctamente el 95,65% de la tendencia corrosiva de las muestras, siendo aquellas con tendencia no corrosiva las que presentaron el menor porcentaje de predicción (75%). La predicción de las muestras externas siguió la tendencia esperada, con menor capacidad para clasificar a las no corrosivas, y las muestras con posible corrosión y corrosivas fueron predichas en 80%. Se concluye que la RNA es una herramienta eficiente para la predicción de la tendencia corrosiva del gas natural en presencia de CO<sub>2</sub> y su efectividad depende de que se utilicen muestras con todos los componentes necesarios para entrenar la misma, además puede ser mejorada al introducir otros parámetros como la cantidad de agua presente.

**Palabras claves:** corrosión; predicción; gas natural; RNA; tendencia



[tmarin@udo.edu.ve](mailto:tmarin@udo.edu.ve)

<sup>1</sup> Universidad de Oriente.  
Unidad de Postgrado. 6201.  
Maturín, Estado Monagas, Venezuela.

#### FIGEMPA: Investigación y Desarrollo

Universidad Central del Ecuador, Ecuador

ISSN-e: 2602-8484

Periodicidad: Semestral

vol. 18, núm. 2, 2024

[revista.figempa@uce.edu.ec](mailto:revista.figempa@uce.edu.ec)

Recepción: 02 enero 2024

Aprobación: 27 junio 2024

DOI: <https://doi.org/10.29166/revfig.v18i2.5989>

Autor de correspondencia:

[tmarin@udo.edu.ve](mailto:tmarin@udo.edu.ve)



Esta obra está bajo una Licencia Creative Commons Atribución 4.0 Internacional (CC BY 4.0)

**Cómo citar:** Marín-Velásquez, T. D. (2024). Tendencia corrosiva por CO<sub>2</sub> del gas natural basada en su composición mediante Redes Neuronales Artificiales. *FIGEMPA: Investigación y Desarrollo*, 18(2), 01-13.

<https://doi.org/10.29166/revfig.v18i2.5989>

#### ABSTRACT

Corrosion is a recurrent problem in the natural gas industry, due to the presence of corrosive gases such as CO<sub>2</sub> and H<sub>2</sub>S that in the presence of water can attack steel and produce damages and leaks that generate accidents and contamination, that is why the prediction of the tendency of natural gas towards corrosion is essential to develop strategies to inhibit and mitigate this process. The objective of the study was to develop an Artificial Neural Network (ANN) trained with composition data of natural gas samples to predict the corrosive tendency, as an alternative method that can be used as an efficient predictive tool. The ANN was trained with a sample of 46 natural gases and 11 components for each one, in addition to pressure and temperature as operational conditions, representing a total of 598 training data of the ANN, also 8 additional samples were used for external validation of the model. The ANN that developed was within the principles of Bayesian statistics, with a Multilayer Perceptron architecture. It was obtained that the ANN is able to correctly classify 95.65% of the corrosive tendency of the samples, being those with non-corrosive tendency the ones that presented the lowest prediction percentage (75%). The prediction of the external samples followed the expected trend, with lower capacity to classify the non-corrosive ones, and the samples with possible corrosion and corrosive were predicted in 80%. It is concluded that ANN is an efficient tool for predicting the corrosive tendency of natural gas in the presence of CO<sub>2</sub> and its effectiveness depends on using samples with all the necessary components to train it, and it can be improved by introducing other parameters such as the amount of water present.

**Keywords:** corrosion; prediction; natural gas; ANN; tendency

## INTRODUCCIÓN

La corrosión es un problema que se manifiesta a nivel mundial afectando de forma importante a la industria del petróleo y el gas natural, por lo que el estudio de los mecanismos que generan el proceso y la tendencia corrosiva de los componentes del petróleo y el gas natural son vitales para un tratamiento efectivo de la corrosión (Valdez, Schorr y Bastidas, 2015). En el caso del gas natural, la corrosión se produce por la presencia de elementos corrosivos como el CO<sub>2</sub> y el H<sub>2</sub>S con conjunción con la presencia de agua en estado líquido que sirve como medio para que ocurran reacciones electrolíticas que deterioran el acero de las tuberías de producción, transporte y procesamiento del gas natural. Particularmente, la corrosión debido al CO<sub>2</sub> bajo condiciones estáticas ha sido estudiada ampliamente y el mecanismo de reacción catódica es generalmente aceptado, ocurre cuando la hidratación del CO<sub>2</sub> en presencia de agua líquida forma H<sub>2</sub>CO<sub>3</sub> y proporcionar H<sup>+</sup> adicional, que conduce a la formación de FeCO<sub>3</sub> lo que provoca la degradación o destrucción de las tuberías (Li, Wang y Xie, 2022).

El estudio de la corrosión en la industria del gas natural se ha desarrollado a través de los años y se han publicado diversas investigaciones, como la de Pérez (2013) en su estudio sobre la corrosión en la industria del gas natural y los materiales que se utilizan para buscar tubería más resistentes a la misma; Groysman (2017) quien analizó la corrosión debida a la presencia de CO<sub>2</sub> y H<sub>2</sub>S en el gas natural y las posibles soluciones al problema; Feng *et al.* (2018) quienes también enfocaron su estudio en el efecto combinado del CO<sub>2</sub> y el H<sub>2</sub>S en la corrosión del acero al carbono; Nayak, Anarghya y Al Adhoubi (2020) quienes estudiaron la corrosión por efecto del CO<sub>2</sub> en tuberías de transporte de gas natural bajo un enfoque computacional; Li *et al.* (2022) con su estudio de la corrosión en tuberías de gas natural, bajo condiciones de flujo; entre otros trabajos realizados en esta temática.

Aun cuando se ha demostrado que la corrosión en la industria del gas natural ha sido estudiada, la predicción de la tendencia corrosiva como metodología para detectar posibles problemas y dar solución a los mismos antes de que ocurra la ruptura de la tubería por desgaste del material, aún sigue estando basada en procedimientos, que aunque estandarizados presentan fallas y se siguen suscitando fugas de gas natural y contaminación en los campos productores, en el transporte, almacenamiento y procesamiento. La búsqueda de una metodología estadística efectiva, basada en métodos multivariantes que involucren las relaciones entre todos los componentes del gas natural, se visualiza como fundamental en la predicción de la tendencia corrosiva, la cual tradicionalmente se ha centrado solo en la presencia de los gases ácidos (CO<sub>2</sub> y H<sub>2</sub>S), de allí que el uso de modelos de Redes Neuronales Artificiales (RNA) sean una alternativa viable para predecir con mayor precisión la tendencia a la corrosión, tomando en cuenta a todos los componentes del gas natural y no solo a los gases ácidos y de esta forma atacar el posible proceso corrosivo a tiempo evitando así rupturas de tuberías, fugas e impacto ambiental negativo.

Las RNA han sido utilizadas en diversos estudios donde se ha demostrado su efectividad en la predicción de condiciones específicas (Jiang *et al.*, 2016; Alqahtani *et al.*, 2020; Chin *et al.*, 2020; Wang *et al.*, 2020; Marín y Arriojas, 2021; Wang, Wang y Peng, 2021; Wu, Zhu y Wang, 2023). Por lo anterior, el objetivo de este estudio fue desarrollar una Red Neuronal Artificial (RNA) entrenada con datos de composición de muestras de gas natural para predecir la tendencia corrosiva. Este enfoque se plantea como un método alternativo que podría ser utilizado como una herramienta predictiva eficiente. El propósito es mitigar de manera efectiva el problema que representa la corrosión, con el fin de prevenir accidentes que puedan ocasionar daños a tuberías, instalaciones, equipos de procesos, el ambiente y a las personas.

## MATERIALES Y MÉTODOS

Para el desarrollo de la investigación se obtuvo una muestra de 46 cromatografías de gas natural de bases de datos de Petróleos de Venezuela (PDVSA) de la región oriental de Venezuela, específicamente de los campos productores de gas del Distrito Anaco, los cuales presentaron valores de CO<sub>2</sub> en porcentaje molar, así como cantidades de H<sub>2</sub>S en partes por millón (ppm), valores con los que se verificó que el mecanismo de corrosión predominante fuera por CO<sub>2</sub>, de acuerdo a la relación entre las presiones parciales de ambos gases en la mezcla, de acuerdo a lo indicado por Feng *et al.* (2018) según los siguientes criterios:

$$\begin{aligned} \frac{PpCO_2}{PpH_2S} < 20 &\Rightarrow \text{Corrosión Ácida (por H}_2\text{S)} \\ 20 < \frac{PpCO_2}{PpH_2S} < 500 &\Rightarrow \text{Corrosión Mixta (por CO}_2\text{+H}_2\text{S)} \\ \frac{PpCO_2}{PpH_2S} > 500 &\Rightarrow \text{Corrosión Dulce (por CO}_2\text{)} \end{aligned}$$

De allí que se tomaron en consideración los gases cuya cromatografía indicara valores de presiones parciales cuyas relaciones fueran mayores a 500, indicativo de una corrosión predominantemente por la presencia de CO<sub>2</sub> en la mezcla gaseosa.

Para el cálculo de las presiones parciales del CO<sub>2</sub> y el H<sub>2</sub>S se tomó en consideración el porcentaje molar del CO<sub>2</sub> y las ppm de H<sub>2</sub>S, así como la presión del sistema en el que tomó cada muestra de gas natural para su caracterización composicional. Esto con las ecuaciones 1 y 2:

$$PpCO_2 = Y_{CO_2} * Pt \quad \text{Ec. 1}$$

$$PpH_2S = Y_{H_2S} * Pt \quad \text{Ec. 2}$$

Donde:

PpCO<sub>2</sub> = Presión parcial de CO<sub>2</sub>

PpH<sub>2</sub>S = Presión parcial de H<sub>2</sub>S

Y<sub>CO<sub>2</sub></sub> = Fracción de CO<sub>2</sub> en la mezcla (%CO<sub>2</sub>/100)

Y<sub>H<sub>2</sub>S</sub> = Fracción de H<sub>2</sub>S en la mezcla (ppmH<sub>2</sub>S/1000000)

Pt = Presión del sistema

Luego de corroborar el mecanismo de corrosión por CO<sub>2</sub> se procedió a aplicar la regla de tendencia corrosiva establecida en el Apéndice C de la norma internacional NACE SP106 (2018) donde se especifica que una presión parcial de CO<sub>2</sub> superior a 207 kPa (30 psi) indica que es corrosiva, una presión parcial de CO<sub>2</sub> entre 21 kPa (3 psi) y 207 kPa (30 psi) es indicativo de posible corrosividad y una presión parcial de CO<sub>2</sub> inferior a 21 kPa (3 psi) se considera generalmente no corrosiva.

El procesamiento de los datos se realizó mediante clasificador Bayesiano de Redes Neuronales Artificiales (RNA). La RNA es una técnica de aprendizaje automático utilizada para clarificar casos particulares a partir de una serie de datos de entrada y la forma más común de arquitectura de RNA es el Perceptrón Multicapa que consta de una capa de entrada conformada por la información de los predictores o variables de entrada, una o más capas ocultas que por lo general utilizan funciones de activación sigmoide y una capa de salida o capa de predicción, siendo este un enfoque que utiliza la retropropagación para construir la red (Alqahtani *et al.*, 2020). La estructura de una RNA se puede observar en la figura 1.

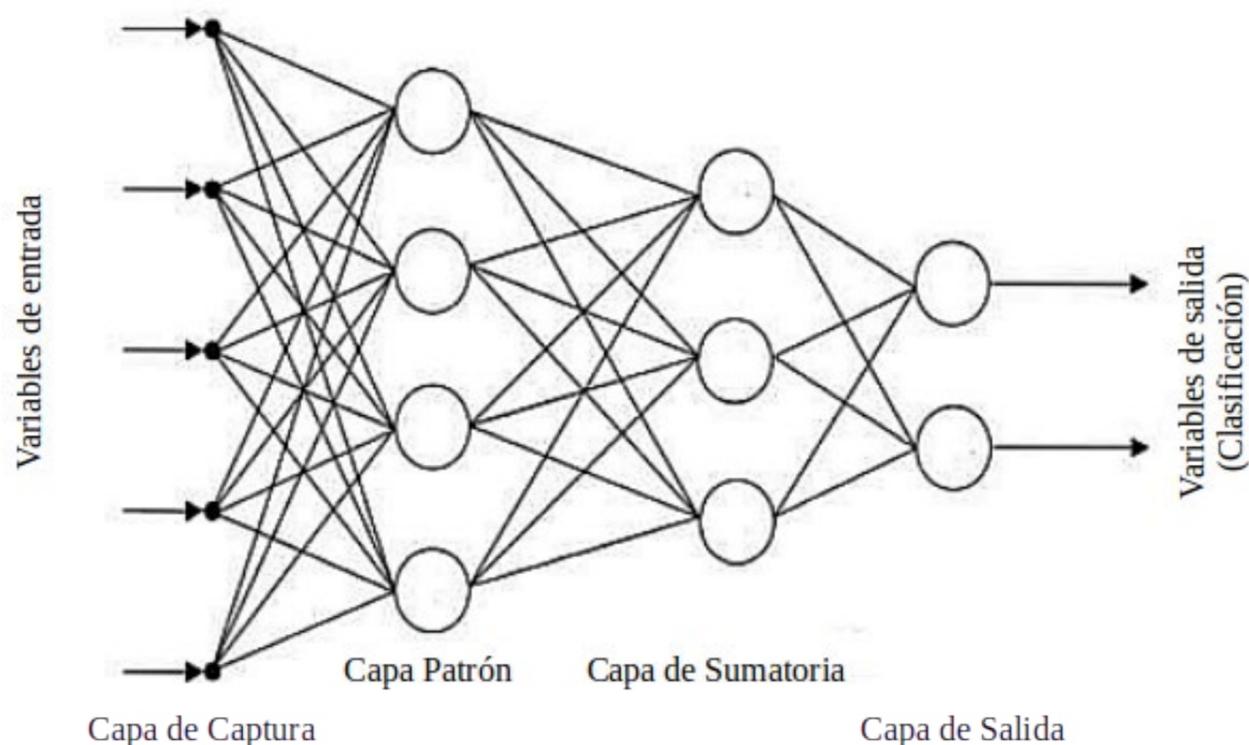


FIGURA 1  
Representación de una Red Neuronal Artificial

Fuente: Ajustado de Marín y Arriojas (2021)

Para la investigación las variables de entrada fueron los componentes del gas natural, en este caso 11 componentes: CO<sub>2</sub>, N<sub>2</sub>, Metano (C1), Etano (C2), Propano (C3), Iso-Butano (I-C4), N-Butano (N-C4), Iso-Pentano (I-C5), N-Pentano (N-C5), Hexano y más pesados (C6+) y H<sub>2</sub>S, además se incluyeron la Presión del sistema (P) y la Temperatura del sistema (T), para un total de 13 variables de entrada. Los componentes del gas se expresaron en porcentaje molar con excepción del H<sub>2</sub>S expresado en partes por millón (ppm), la presión del sistema en libras por pulgada cuadrada absolutas (Lpca) y la temperatura en °F. Se introdujeron 46 muestras de gas natural lo que representó un conjunto de entrenamiento con el mismo número de componentes y un total de datos procesados de 598, con probabilidades de ocurrencia proporcionales a los datos introducidos. El parámetro de espaciado usado fue obtenido por el método Jackknifing aplicado al entrenamiento de la red, este método estima el espaciado por un re-cálculo sistemático del valor estadístico por omisión de una observación por vez del conjunto de datos introducido y crea un conjunto nuevo de observaciones estadísticas con las que se estima el sesgo y la varianza, siendo especialmente aplicable a datos con diferentes pesos de muestreo (Wu *et al.*, 2023).

Se utilizó una función de activación de tipo sigmoidea. La función de activación representa el núcleo de una estructura de RNA y se utiliza para aumentar la capacidad de expresión del modelo de red neuronal, con base en el trazado por una función no lineal (Wang *et al.*, 2020). La expresión de la función sigmoidea se muestra en la ecuación 3 y su forma en la figura 2.

$$f(x) = \frac{1}{1+e^{-x}} \quad \text{Ec. 3}$$

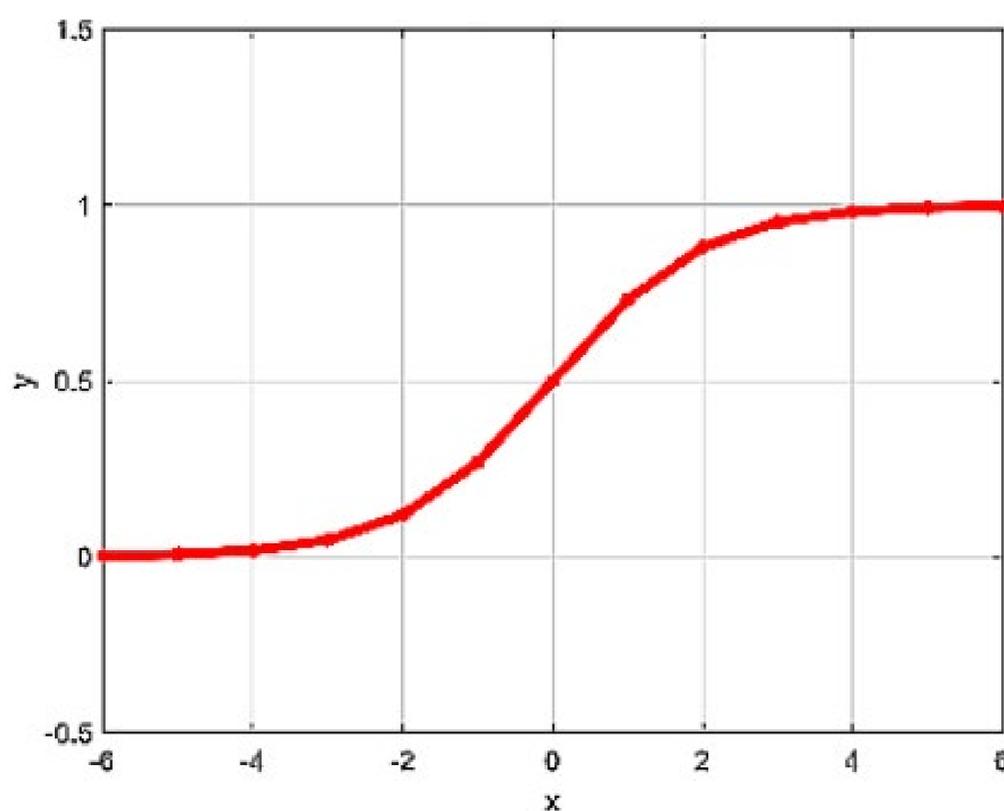


FIGURA 2  
Curva sigmoidea

Fuente: Wang *et al.* (2020)

Esta función de activación se optimizó mediante el método Bayesiano, funciona construyendo una distribución posterior de funciones mediante un proceso gaussiano que logra una mejor descripción y ajuste de la función de activación (Wang *et al.*, 2021). Como variables de salida o de clasificación se establecieron los tres niveles de tendencia corrosiva (No corrosivo, Posible corrosión y Corrosivo).

Una vez que se han establecido todos los parámetros de entrada y salida, así como la función de activación optimizada, la estructura de una red neuronal puede ser esquematizada de manera general, como se muestra en la figura 3.

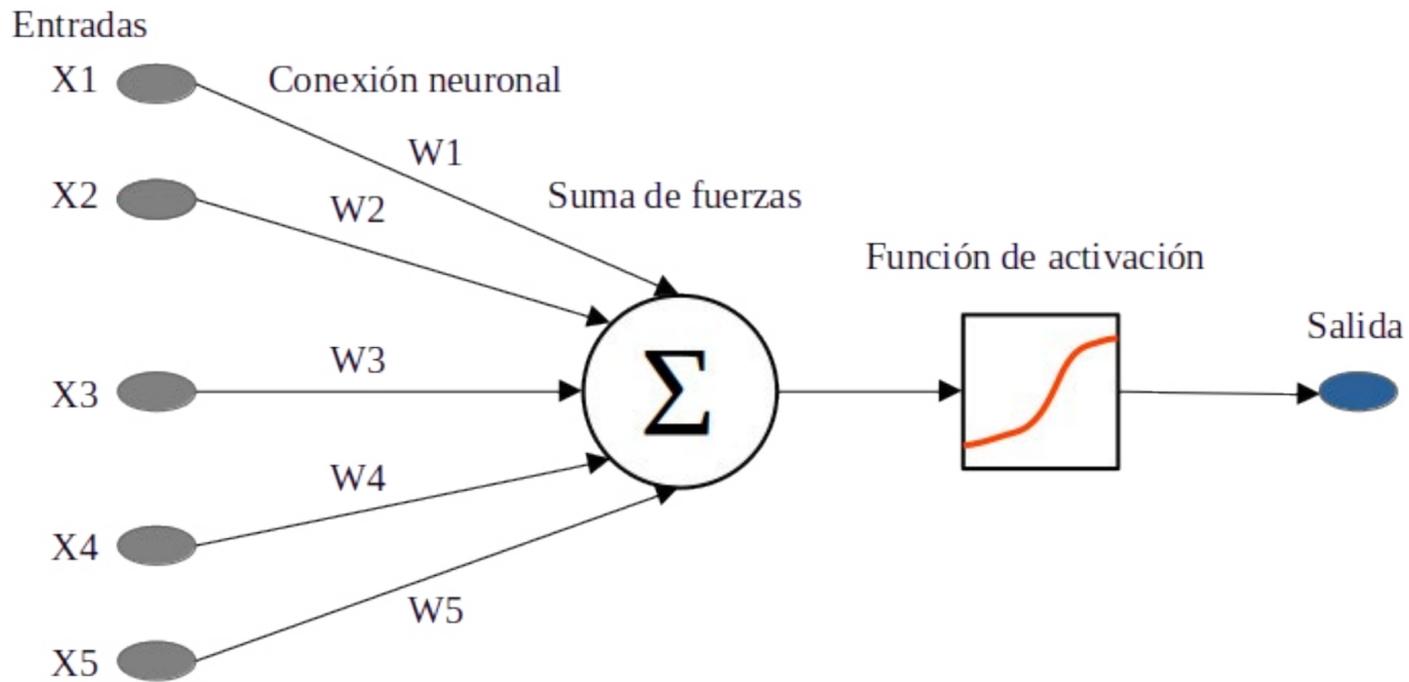


FIGURA 3  
Modelo general de neurona artificial

La RNA fue desarrollada con el paquete estadístico Statgraphics Centurion XVII, que es un software especializado para el manejo de cantidades grandes de datos y permite de forma sencilla análisis estadísticos complejos. Con el software se obtuvieron parámetros como las características generales de las muestras de gas natural con base en la descripción de cada componente; espaciamiento óptimo entre neuronas; el porcentaje de casos correctamente clasificados por la RNA; las predicciones para cada uno de las tendencias corrosivas y los casos incorrectamente clasificados. Además del aporte de gráficos como la estructura de la RNA desarrollada y de las relaciones entre el contenido de CO<sub>2</sub> en la mezcla y cada uno de los demás componentes en función de las tendencias clasificadas. También se utilizaron datos de 8 muestras adicionales de gas natural recuperadas de documentos científicos publicados en la web, de diferentes partes del mundo, con la finalidad de validar la RNA y probar su aplicabilidad en la predicción de la tendencia corrosiva.

## RESULTADOS Y DISCUSIÓN

Se realizó un análisis descriptivo de las muestras utilizadas para el estudio, con base en los 11 componentes y las 2 condiciones operacionales tomadas en consideración, de acuerdo a lo mostrado en la tabla 1.

TABLA 1  
Características generales de las muestras de gas natural (% molar)

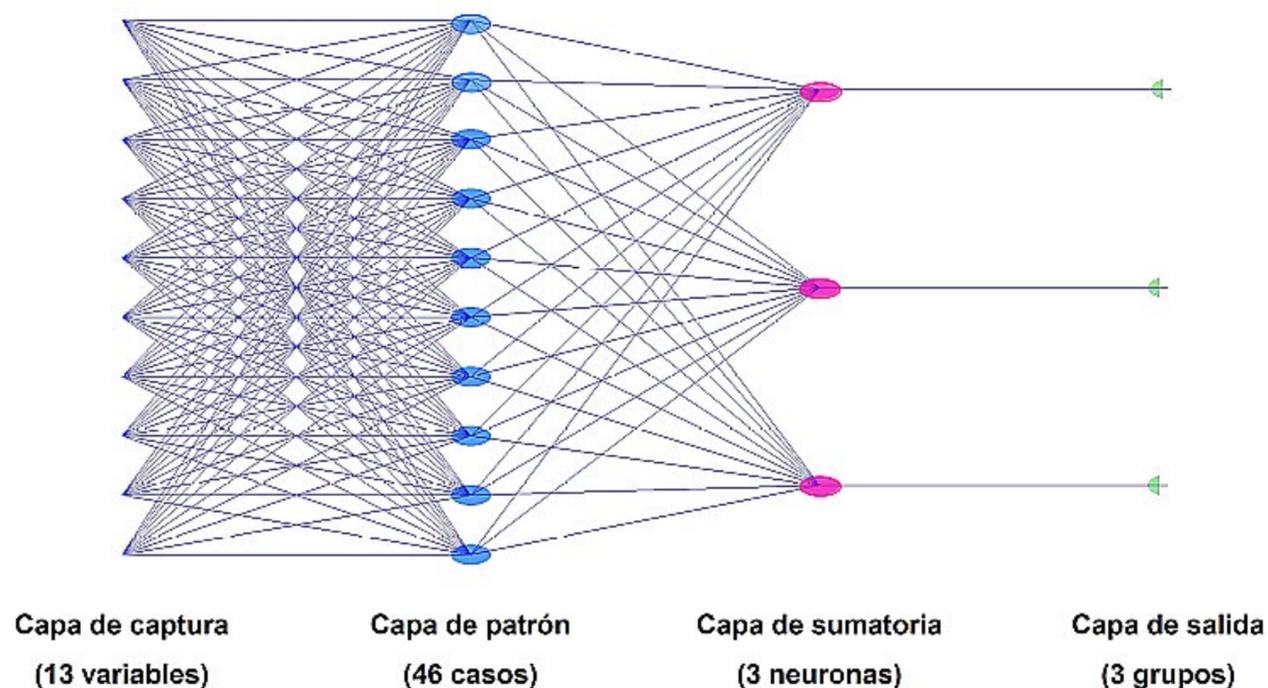
	CO <sub>2</sub>	N <sub>2</sub>	C1	C2	C3	I-C4	N-C4	I-C5	N-C5	C6+	H <sub>2</sub> S (ppm)
Nº de valores	46	46	46	46	46	46	46	46	46	46	46
Media	6,27	0,16	70,43	9,58	6,51	1,74	2,76	0,96	0,78	0,83	22,07
Desviación Estándar	2,14	0,11	14,44	3,91	5,12	1,72	2,99	1,17	1,02	0,87	17,02
Coefficiente de variación	34,21	66,96	20,51	40,81	78,65	98,58	108,60	122,00	131,50	104,80	77,16
Rango	9,36	0,50	75,00	13,15	27,86	8,21	17,49	6,27	5,35	3,86	55,00
Mínimo	2,26	0,04	8,46	3,84	1,93	0,55	0,71	0,23	0,14	0,21	5,00
Máximo	11,62	0,54	83,46	16,99	29,79	8,76	18,20	6,50	5,50	4,07	60,00

Se observa en la tabla 1, como era de esperarse, que el componente mayoritario de las muestras de gas natural utilizadas fuera el metano (C1) con un valor promedio de 70,43% molar y que los demás componentes hidrocarburos disminuyeran su porcentaje al ir aumentando el número de carbonos en la cadena. Los componentes no hidrocarburos están dominados por el Dióxido de carbono (CO<sub>2</sub>) con una cantidad promedio

de 6,27% molar, superando incluso a los hidrocarburos de más de tres átomos de carbono (butano y superiores) en cuanto a su participación en la mezcla. El nitrógeno (N<sub>2</sub>) aparece como el componente no hidrocarburo segundo en importancia con 0,16% molar en promedio y en menor cantidad se visualiza al sulfuro de hidrógeno (H<sub>2</sub>S) con una media de 22,07 ppm. A pesar de que el C1 presenta el mayor rango de valores con mínimo de 8,46% molar y máximo de 83,46% molar, su coeficiente de variación (CV) fue el mínimo (20,51%) lo que indica que es el componente con composición más estable al analizar las 46 muestras en conjunto, siendo por el contrario el N-pentano el de mayor variabilidad dentro de las muestras con un CV de 131,50% lo que demuestra que la presencia de los hidrocarburos más pesados en el gas natural varía considerablemente entre muestras, si se toma en cuenta que del N-butano al hexano y más pesados, todos presentaron porcentajes de CV superiores al 100%.

Aun cuando la composición del gas natural depende en gran medida de las condiciones bajo las cuales se formó y depositó en los estratos del subsuelo, lo que limita la comparación con otras muestras por la gran variabilidad, en estudios científicos se han mencionado composiciones promedio de sus componentes, así Faramawy, Zaki y Sakr (2016) presentan una composición donde se observa una tendencia similar a la observada en la composición promedio de las muestras utilizadas, con todos los valores de los componentes hidrocarburos dentro de los rangos observados en las muestras de estudio, sin embargo, dentro de los gases no hidrocarburos solo el CO<sub>2</sub> superó los valores propuestos por los autores citados, lo que es debido a que las muestras fueron tomadas de gases naturales con contenido de CO<sub>2</sub> superiores y que presentan una fuente potencial de corrosión para las tuberías de acero al carbono por donde circulan, por tal razón se considera que la composición de promedio de las muestras está acorde con lo que se espera de acuerdo a la literatura científica especializada en el área de estudio.

Con los datos procesados se obtuvo el diagrama de red que se muestra en la figura 4, donde se detallan los datos cargados en la capa de captura (13 variables) y los parámetros generados por la RNA en la capa patrón constituida por los 46 casos de estudio (muestras), en la capa sumatoria donde se generaron 3 neuronas que corresponden a cada uno de las categorías de clasificación (No corrosivo, Posible corrosión y Corrosivo) y la capa de salida donde se generaron igualmente 3 grupos correspondientes a cada una de las categorías de clasificación.



**FIGURA 4**  
Estructura de la red neuronal artificial desarrollada para la clasificación de la tendencia corrosiva

Esta RNA se desarrolló de forma automática por el software entrenada utilizado un parámetro de espaciamento de 0,1813 el cual fue optimizado por el método Jackknifing. A partir de la RNA desarrollada, se obtuvo el resultado de clasificación que se detalla en la tabla 2, para cada nivel de clasificación de la tendencia corrosiva.

**TABLA 2**  
Resultados de la clasificación a partir de la RNA desarrollada para cada nivel de tendencia corrosiva

<b>Tendencia Corrosiva</b>	<b>Tamaño de Grupo</b>	<b>Corrosivo</b>	<b>No corrosivo</b>	<b>Posible corrosión</b>
<b>Corrosivo</b>	10	10 (100,00%)	0 (0,00%)	0 (0,00%)
<b>No corrosivo</b>	4	0 (0,00%)	3 (75,00%)	1 (25,00%)
<b>Posible corrosión</b>	32	0 (0,00%)	1 (3,13%)	31 (96,88%)

Porcentaje de casos de entrenamiento correctamente clasificados: 95,65%

En la tabla 2 se puede observar que, de las 46 muestras analizadas, 10 presentaron una tendencia corrosiva. De estas, el 100,00% fue clasificado correctamente por la RNA. En cuanto a las 4 muestras con tendencia no corrosiva, el 75,00% (3) fue clasificado correctamente por la RNA, dejando un 25,00% de muestras incorrectamente clasificadas. Esto significa que 1 muestra, inicialmente considerada no corrosiva, fue ubicada erróneamente en el grupo correspondiente a las muestras con tendencia a posible corrosión. Por otro lado, de las 32 muestras con tendencia a posible corrosión, el 96,88% (31) fue correctamente clasificado por la RNA, con un 3,13% (1) de las muestras incorrectamente clasificadas y ubicadas como no corrosivas.

El total de muestras clasificadas correctamente fue de 95,65%. Lo anterior denota que el grupo más sensible a clasificar es el de las muestras no corrosivas, las cuales aun cuando tienen la presencia del CO<sub>2</sub> y el H<sub>2</sub>S la baja presión de parcial de CO<sub>2</sub> < 3 Lpca las clasifica como no corrosivas, sin embargo, la RNA arroja como resultado que la mayoría de ellas deben ser clasificadas en el grupo de las muestras con posible tendencia a la corrosión. El detalle de las muestras incorrectamente clasificadas se muestra en la tabla 3.

**TABLA 3**  
Muestras incorrectamente clasificadas por la RNA desarrollada

<b>Muestra</b>	<b>Tendencia inicial</b>	<b>Tendencia predicha</b>
16	Posible corrosión	No corrosiva
38	No corrosivo	Posible corrosión

En la tabla 3 se observan las 2 muestras cuya clasificación fue incorrecta según la RNA desarrollada, con la clasificación predicha respectiva para cada una de ellas. El componente de dichas muestras se observa en la tabla 4.

**TABLA 4**  
Composición de las muestras clasificadas incorrectamente por la RNA desarrollada

<b>Muestra</b>	<b>CO2</b>	<b>N2</b>	<b>C1</b>	<b>C2</b>	<b>C3</b>	<b>I-C4</b>	<b>N-C4</b>	<b>I-C5</b>	<b>N-C5</b>	<b>C6+</b>	<b>H2S (ppm)</b>
16	4,919	0,166	43,450	16,830	16,090	3,727	7,305	2,600	2,322	2,590	60
38	4,414	0,054	78,862	8,112	4,471	1,390	1,684	0,477	0,242	0,294	5

Es claro que la tendencia corrosiva está en función a la PpCO<sub>2</sub>, dado que es el mecanismo de corrosión predominante en todas las muestras y que a su vez ésta depende de la presión del sistema, a una mayor presión se tiene una mayor tendencia hacia la corrosión, sin embargo la RNA toma en cuenta la contribución de cada componente por lo que en el caso de la muestra 16, se observa por su composición que la misma se trata de un gas condensado, pues presenta baja cantidad de metano y altas concentraciones de los hidrocarburos más pesados, siendo los líquidos unos atenuadores del proceso corrosivo y en esta muestra los hidrocarburos líquidos representan un 18,544% del total, lo que supera a muestras de gas condensado reportadas por Alarouj, Alomair y Elsharkawy (2020) para Kuwait con un máximo de hidrocarburos líquidos de 17,10%.

La presencia de hidrocarburos líquidos en porcentaje importante disminuye la tendencia corrosiva de la mezcla por su naturaleza aceitosa lo que disminuye la posibilidad de corrosión electroquímica, disminuyendo la transferencia de electrones entre el metal y el medio corrosivo (Marín-Velásquez y Arriojas-Tocuyo, 2020), además el sistema donde se maneja esta muestra presenta una presión relativamente baja de 50 lpc (64,5 Lpca) que hace que la PpCO<sub>2</sub> sea de 3,17 Lpca que se encuentra en el límite entre la tendencia no corrosiva (PpCO<sub>2</sub> < 3 Lpca) y la posible tendencia corrosiva (PpCO<sub>2</sub> entre 3 Lpca y 500 Lpca). Así mismo una relación de presiones parciales de los gases ácidos similar a las de las muestras con tendencia no corrosiva (PpCO<sub>2</sub>/PpH<sub>2</sub>S < 900), la baja cantidad de metano y la tendencia no corrosiva de otra muestra similar de gas condensado (muestra 23), justifican que la muestra 16 sea clasificada por la RNA como no corrosiva demostrando su precisión en este aspecto.

La muestra 38 clasificada como no corrosiva, fue pronosticada como con posible corrosión por la RNA, esta muestra presenta composición y condiciones operacionales similares a otras muestras analizadas y que se clasificaron correctamente como tendencia a la posible corrosión, como las muestras 36, 37 y 39 todas procedentes del mismo yacimiento pero de pozos diferentes, estando todas en el límite bajo de la tendencia a la posible corrosión respecto a la PpCO<sub>2</sub> (36 = 3,35 Lpca, 37 = 3,07 Lpca y 39 = 3,04 Lpca) siendo la principal diferencia que la muestra 38 presentó un menor porcentaje de CO<sub>2</sub> lo que la ubicó con una PpCO<sub>2</sub> = 2,85 Lpca < 3 Lpca que la ubica en la zona no corrosiva, pero en el límite con la tendencia a la posible corrosión. Estas muestras pueden cambiar su tendencia corrosiva con cambios en las condiciones operacionales, principalmente en la presión, sin embargo, la similitud en sus composiciones hace que para la RNA las cuatro sean iguales respecto a su tendencia corrosiva, por lo que la clasificación dada por la misma se considera correcta.

El uso de RNA para la predicción de la tendencia corrosiva por CO<sub>2</sub> ha demostrado una alta eficiencia según los resultados obtenidos, lo que es consistente con resultados de otras investigaciones donde la corrosión ha sido modelada a partir de RNA, como el caso de Jiang *et al.* (2016) quienes demostraron que un modelo basado en RNA es eficiente para predecir la corrosión y la vida útil de alcantarillas de hormigón, en un estudio realizado en Australia, de igual manera Chin *et al.* (2020) demostraron que la RNA es capaz de predecir la presión de fallo de tuberías de acero al carbono por efecto de la corrosión con una precisión de 85% en un trabajo realizado en Malasia, un valor que fue superado en la presente investigación, sin embargo las diferencias pueden deberse a las condiciones y muestras utilizadas. Por su parte Nayak *et al.* (2020) al analizar la corrosión interna en tuberías de acero al carbono por efecto del CO<sub>2</sub>, también demostraron que con el uso de RNA, los valores predichos tienen una buena concordancia de 91,7% con valores de corrosión observados experimentalmente en las mismas condiciones de funcionamiento, lo que se corresponde con la observación hecha en este estudio donde las condiciones operacionales son claves en la predicción de la tendencia corrosiva.

Con las predicciones de la RNA se elaboraron gráficas para establecer el comportamiento de la tendencia corrosiva tomando en consideración el CO<sub>2</sub> (% molar) con relación a cada uno de los componentes de las muestras, en la figura 5 se observa la relación con los hidrocarburos gaseosos (C1, C2 y C3).

En la figura 5 se evidencia que el comportamiento de la tendencia corrosiva respecto a los hidrocarburos gaseosos no presenta valores de no corrosiva, lo que indica que la presencia de estos gases en conjunto con el CO<sub>2</sub> tiende a volver la mezcla corrosiva. En los casos del C2 y el C3 (Figuras 5-B y 5-C) el aumento de la concentración de ambos gases provoca una disminución en la probabilidad de que se tenga una tendencia corrosiva, siendo el punto máximo cuando no están presentes los mismos en la muestra, con una contribución más marcada del C2, dado su mayor % molar en la muestra. Por el contrario, el C1 contribuye a aumentar la tendencia corrosiva en presencia de CO<sub>2</sub>, por lo que se observa en la figura 5-A, como la tendencia corrosiva aparece a una mayor cantidad de C1 y una menor cantidad de CO<sub>2</sub>.

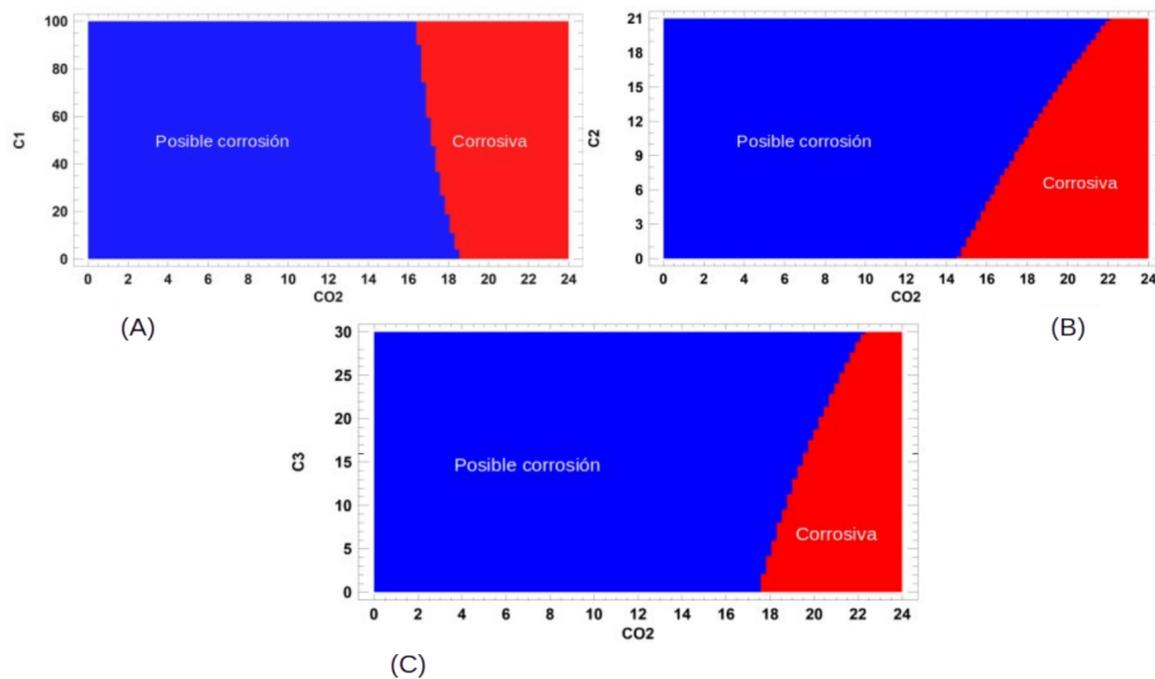


FIGURA 5

Comportamiento de la tendencia corrosiva basada en la relación  $\text{CO}_2$  – Hidrocarburos gaseosos

El efecto de metano y otros hidrocarburos componentes del gas natural en el proceso corrosivo no ha sido estudiado a profundidad, pues se considera que la corrosión en las tuberías de acero al carbono por donde se transporta el gas natural se debe principalmente a la presencia de gases ácidos ( $\text{CO}_2$  y  $\text{H}_2\text{S}$ ) así como también al contenido de agua y las condiciones operacionales (P y T), por lo que el efecto del metano en la corrosión se ha centrado en su capacidad para formar hidratos con el agua y estos hidratos se han catalogado como agentes corrosivos (Farhadian *et al.*, 2020), sin embargo el estudio de inhibidores de corrosión ha demostrado que la eficiencia atenuadora del proceso corrosivo de los compuestos orgánicos aumenta al aumentar la longitud de la cadena alquílica de C1 a C12 (Verma, Quraishi y Rhee, 2022) lo que puede dar sustento a lo que se observó a través de la predicción hecha por parte de la RNA en el caso de los hidrocarburos gaseosos y porque el C1 por ser el hidrocarburo más liviano no tiene un efecto atenuador, sino que por el contrario su mayor cantidad y por ende mayor presión de vapor actúa de forma positiva respecto a la tendencia corrosiva del  $\text{CO}_2$  aumentando la misma. Lo anterior además es un buen punto para investigar más sobre el efecto de C1 en la tendencia corrosiva del gas natural.

En la figura 6 se muestra gráficamente la tendencia corrosiva con base en la relación entre el contenido molar de  $\text{CO}_2$  y el contenido molar de los hidrocarburos líquidos (C4 al C6+) para analizar el comportamiento de la corrosión según la relación entre estos componentes.

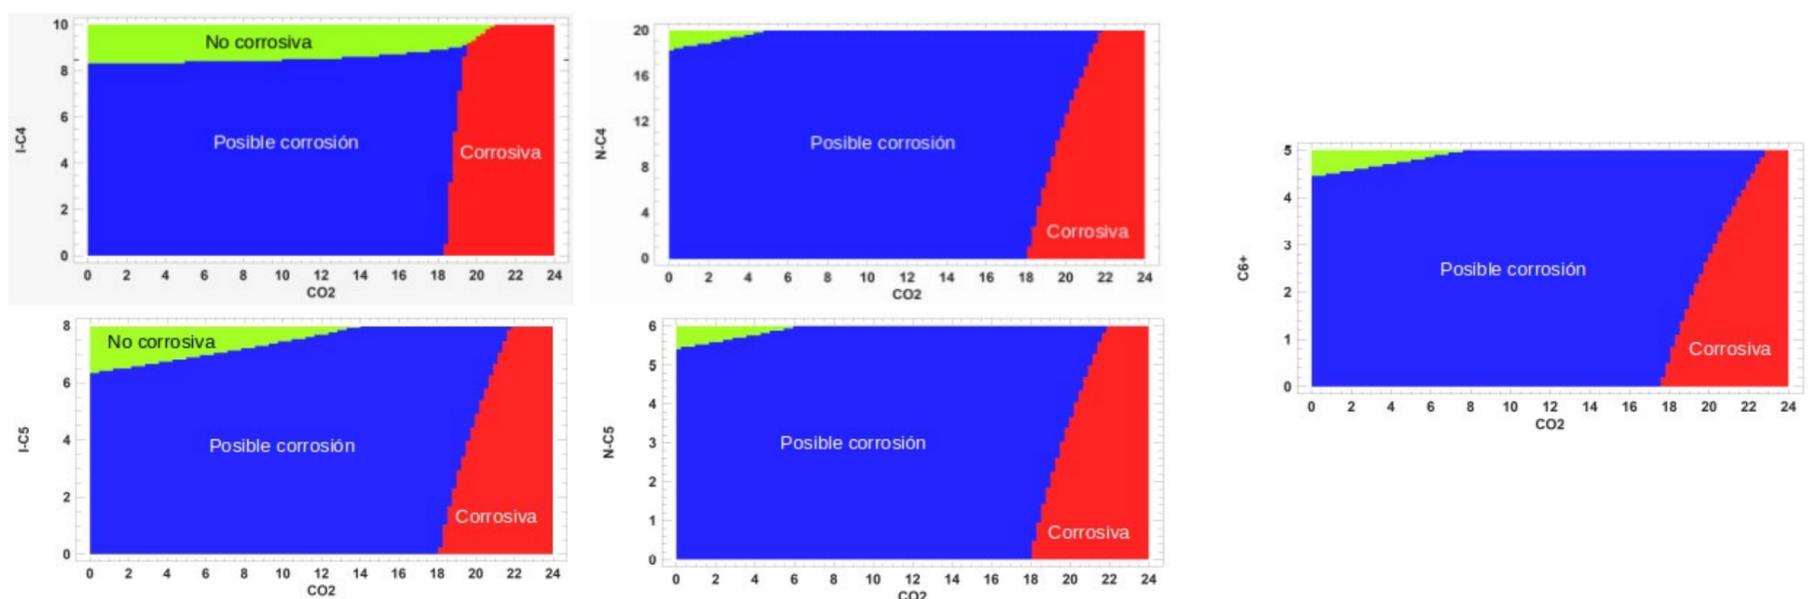


FIGURA 6

Comportamiento de la tendencia corrosiva basada en la relación  $\text{CO}_2$  – Hidrocarburos líquidos

Como se puede observar en la figura 6, a diferencia de lo que se obtuvo con los hidrocarburos gaseosos, la tendencia no corrosiva se ve asociada a la presencia de los hidrocarburos líquidos y en todos los casos, al aumentar el porcentaje de los hidrocarburos líquidos la tendencia es a que la mezcla gaseosa se vuelva no corrosiva, a bajas concentraciones de CO<sub>2</sub>, lo que se ve más evidente en la relación CO<sub>2</sub> – I-C4, donde la tendencia no corrosiva se observa hasta valores de 18% CO<sub>2</sub> con I-C4 > 8% por lo que este hidrocarburo parece tener el mayor grado de atenuación de la corrosión en la mezcla. En segundo lugar, se observa el I-C5 que presenta tendencia no corrosiva cuando está en porcentaje molar mayor a 6% y con CO<sub>2</sub> < 14%. Los hidrocarburos de mayor número de carbonos (C6+) presentan atenuación a menores porcentajes (C6+ > 4%) pero con porcentajes de CO<sub>2</sub> < 8%.

El comportamiento corrosivo dado por el análisis de RNA demuestra la capacidad atenuante de los hidrocarburos líquidos respecto a la corrosión del gas natural en las tuberías de acero al carbono y que los hidrocarburos más complejos presentan atenuación a porcentajes menores, siempre medidos por la presencia del CO<sub>2</sub> como agente corrosivo. Este efecto de los hidrocarburos líquidos como atenuadores o mitigadores de la corrosión ha sido poco documentado, sin embargo Ayello *et al.* (2013) investigaron sobre el efecto del petróleo como mitigador de corrosión en oleoductos y descubrieron, que aunque no es generalizado, algunos petróleos crudos exhiben mecanismos que mitigan la corrosión, como la inhibición a través de la fase acuosa por moléculas similares a inhibidores, la alteración de la mojabilidad de la superficie del acero a mojada por aceite, limitando así el acceso del agua a la superficie, o disminuyendo la tensión interfacial entre el aceite y el agua y facilitando la dispersión del agua en el aceite, lo que reduce la probabilidad de corrosión al impedir que el agua esté en contacto con la superficie del acero, esto da fe de la capacidad de ciertos hidrocarburos complejos para actuar como agentes atenuantes de la corrosión, tal como se describe en la presente investigación.

Para corroborar la capacidad predictiva de la RNA desarrollada, se utilizaron 8 muestras adicionales, y los resultados se detallan en la tabla 5.

**TABLA 5**  
Predicción de la tendencia corrosiva de muestras adicionales de acuerdo a la RNA desarrollada

<b>Muestra</b>	<b>Tendencia inicial</b>	<b>Tendencia predicha</b>
1	No corrosivo	Posible corrosión
2	Corrosivo	Posible corrosión
3	Corrosivo	Corrosivo
4	Posible corrosión	Posible corrosión
5	No corrosivo	Posible corrosión
6	No corrosivo	Posible corrosión
7	Posible corrosión	Posible corrosión
8	Corrosivo	Corrosivo

Se observa que, de las 8 muestras, 4 (50%) fueron clasificadas correctamente, mientras que las otras 4 no lo fueron de manera precisa por la RNA. Esta inexactitud se debió a la tendencia de las muestras no corrosivas, que, como se ha observado previamente, presentan el menor porcentaje de clasificación correcta por parte de la RNA desarrollada. Es notable que el 100% de estas muestras fueron ubicadas en el rango de las muestras con posible corrosión. Por otro lado, las muestras con tendencia corrosiva fueron clasificadas de manera correcta en un 66,7% (2 de 3), y las muestras con tendencia hacia una posible corrosión fueron clasificadas de forma correcta en un 100%. Este resultado se compagina con lo observado con las muestras utilizadas para el entrenamiento de la RNA y se asume que en este caso no existen muestras no corrosivas, debido a la presencia de CO<sub>2</sub> en cantidades que pueden generar corrosión, por ello se debe redefinir los rangos para que las muestras sean consideradas como no corrosivas. Por otro lado, estas 8 muestras presentaron poco o nada de H<sub>2</sub>S, lo que evidentemente fue un factor que afectó la predicción. En todo caso, se comprueba que para muestras con tendencia hacia la corrosión o corrosivas, la RNA desarrollada predice el 80,0% de la tendencia mostrada, ya que clasificó correctamente a 4 de las 5 muestras en estas tendencias.

## CONCLUSIONES

- El uso de RNA para la predicción de la tendencia corrosiva del gas natural, por efecto del CO<sub>2</sub> demostró ser eficiente, ya que es capaz de generar una predicción en más del 80,0% de las muestras, y dicha predicción aumenta si se utilizan muestras con todos los componentes necesarios, ya que se observó que al faltar algún componente la capacidad predictiva disminuye.
- Se observó, además, que la RNA desarrollada es capaz de mostrar la influencia de los hidrocarburos en la corrosión, al relacionarlos con el CO<sub>2</sub> presente, donde la mayoría de ellos se comporta de forma mitigadora, es decir que retardan la acción corrosiva del CO<sub>2</sub>, pero deben estar en concentraciones suficientes, siendo los más pesados (C6+) los que ejercen el efecto a menores concentraciones, pero con menores concentraciones de CO<sub>2</sub>.

## RECOMENDACIONES

Se recomienda que se continúe el estudio con mayor cantidad de muestra que validen los rangos de predicción observadas, además de que se debe estudiar más a fondo el efecto del metano en el proceso corrosivo, ya que se observó que el mismo parece favorecer a la corrosión y no se han desarrollado suficientes investigaciones que corroboren esta influencia. Así mismo, se deben utilizar otros métodos de clasificación multivariante como análisis discriminante, para observar si otros modelos predicen con mayor precisión la tendencia corrosiva del gas natural por efecto del CO<sub>2</sub>.

## REFERENCIAS

- Alarouj, M., Alomair, O. y Elsharkawy, A. (2020) "Gas condensate reservoirs: Characterization and calculation of dew-point pressure", *Petroleum Exploration and Development*, 47 (5), pp. 1091-1102. DOI: 10.1016/S1876-3804(20)60120-3
- Alqahtani, H., Sarker, I. H., Kalim, A., Minhaz Hossain, S. M., Ikhlaiq, S. y Hossain, S. (2020) "Cyber intrusion detection using machine learning classification techniques". *Computing Science, Communication and Security: First International Conference, COMS2 2020*. Singapur: Springer, pp. 121-131. DOI: 10.1007/978-981-15-6648-6\_10
- Ayello, F., Robbins, W., Richter, S. y Nešić, S. (2013) "Model compound study of the mitigative effect of crude oil on pipeline corrosion", *Corrosion*, 69 (3), pp. 286-296. DOI: 10.5006/0631
- Chin, K. T., Arumugam, T., Karuppanan, S. y Ovinis, M. (2020) "Failure pressure prediction of pipeline with single corrosion defect using artificial neural network", *Pipeline Sci. Technol.*, 4 (1), pp. 10-17. DOI: 10.28999/2514-541X-2020-4-1-10-17
- Faramawy, S., Zaki, T. y Sakr, A. A.-E. (2016) "Natural gas origin, composition, and processing: A review", *Journal of Natural Gas Science and Engineering*, 34, pp. 34-54. DOI: 10.1016/j.jngse.2016.06.030
- Farhadian, A., Varfolomeev, M. A., Kudbanov, A., Rezaeisadat, M. y Nurgaliev, D. K. (2020) "Waterborne polymers as kinetic/anti-agglomerant methane hydrate and corrosion inhibitors: A new and promising strategy for flow assurance", *Journal of Natural Gas Science and Engineering*, 77, p. 103235. DOI: 10.1016/j.jngse.2020.103235
- Feng, R., Beck, J. R., Hall, D. M., Buyuksagis, A., Ziomek Moroz, M. y Lvov, S. N. (2018) "Effects of CO<sub>2</sub> and H<sub>2</sub>S on corrosion of martensitic steels in brines at low temperature", *Corrosion*, 74 (3), pp. 276-287. DOI: 10.5006/2406
- Groysman, A. (2017) "Corrosion problems and solutions in oil, gas, refining and petrochemical industry", *KOM-Corrosion and Material Protection Journal*, 61 (3), pp. 100-117. DOI: 10.1515/kom-2017-0013
- Jiang, G., Keller, J., Bond, P. L. y Yuan, Z. (2016) "Predicting concrete corrosion of sewers using artificial neural network", *Water research*, 92, pp. 52-60. DOI: 10.1016/j.watres.2016.01.029
- Li, J., Wang, D. y Xie, F. (2022) "Failure analysis of CO<sub>2</sub> corrosion of natural gas pipeline under flowing conditions", *Engineering Failure Analysis*, 137, p. 106265. DOI: 10.1016/j.engfailanal.2022.106265

- Marín Velásquez, T. D. y Arriojas Tocuyo, D. D. J. (2020) "Efecto de la mezcla de aceites de Anacardium occidentale/ Cocos nucifera en gasoil sobre la velocidad de corrosión de acero al carbono en solución salina", *Revista Tecnología en Marcha*, 33 (4), pp. 37-46. DOI: 10.18845/tm.v33i4.4484
- Marín, T. D. y Arriojas, D. D. J. (2021) "Ubicación de revistas científicas en cuartiles según SJR: Predicción a partir de estadística multivariante", *Anales de Documentación*, 24 (1), pp. 1-11. DOI: 10.6018/analesdoc.455951.
- NACE SP106 (2018) *Control of Internal Corrosion in Steel Pipelines and Piping Systems*. Houston: National Association of Corrosion Engineers International.
- Nayak, N., Anarghya, A. y AlAdhoubi, M. (2020) "A study on the behavior of CO<sub>2</sub> corrosion on pipeline using computational fluid dynamics, experimental and artificial neural network approach", *Engineering Research Express*, 2 (2), p. 025012. DOI: 10.1088/2631-8695/ab69d6
- Perez, T. E. (2013) "Corrosion in the oil and gas industry: an increasing challenge for materials", *Jom*, 65 (8), pp. 1033-1042. DOI: 10.1007/s11837-013-0675-3
- Valdez, B., Schorr, M. y Bastidas, J. M. (2015) "The natural gas industry: equipment, materials, and corrosion", *Corrosion Reviews*, 33 (3-4), pp. 175-185. DOI: 10.1515/correv-2015-0012
- Verma, C., Quraishi, M. A. y Rhee, K. Y. (2022) "Hydrophilicity and hydrophobicity consideration of organic surfactant compounds: Effect of alkyl chain length on corrosion protection", *Advances in Colloid and Interface Science*, 306, p. 102723. DOI: 10.1016/j.cis.2022.102723
- Wang, Y., Li, Y., Song, Y. y Rong, X. (2020) "The influence of the activation function in a convolution neural network model of facial expression recognition", *Applied Sciences*, 10 (5), p. 1897. DOI: 10.3390/app10051897
- Wang, Y., Wang, H. y Peng, Z. (2021) "Rice diseases detection and classification using attention based neural network and bayesian optimization", *Expert Systems with Applications*, 178, p. 114770. DOI: 10.1016/j.eswa.2021.114770
- Wu, S., Zhu, X. y Wang, H. (2023) *Subsampling and jackknifing: a practically convenient solution for large data analysis with limited computational resources*. Ithaca, New York: Cornell University. Disponible en <https://arxiv.org/abs/2304.06231>. DOI: [10.48550/arXiv.2304.06231](https://doi.org/10.48550/arXiv.2304.06231)