

Redes neuronales
+
Lógica Fuzzy
+
Velocidad de
corrosión

MODELO BASADO EN REDES NEURONALES ARTIFICIALES, PARA LA DETERMINACIÓN DE VELOCIDADES DE CORROSIÓN POR CO₂ Y H₂S EN CAMPO DE PRODUCCIÓN DE HIDROCARBUROS

En la industria de hidrocarburos la estructura interna de tuberías y depósitos que albergan crudo se ven afectadas por la corrosión a causa de diferentes factores, entre otros las características del fluido, entre las cuales el contenido de CO₂ y H₂S son las más influyentes [1].

Ante la urgente necesidad de estudiar el proceso de corrosión [2], se han propuesto diversidad de procesos y tecnologías lo que ha generado diversidad de herramientas de uso general que ayudan en el cálculo de velocidades de corrosión por CO₂ y H₂S.

Aquí se presenta un modelo basado en la técnica de redes neuronales para estimar velocidades de corrosión en campos de hidrocarburos y la técnica de curvas y superficies fuzzy para el pre-procesamiento de las variables de entrada en la red neuronal.

INTRODUCCIÓN

El modelado de procesos con inteligencia artificial, se ha consolidado como un procedimiento apropiado para la solución de problemas cada vez más complejos e importantes. Modelos como las redes neuronales artificiales, y la lógica difusa (fuzzy logic) ampliamente probadas en diversidad de áreas de desarrollo tecnológico, se han implementado también en diferentes aspectos de la investigación en corrosión con resultados óptimos.

La Red Neuronal Artificial (RNA) es un mecanismo de procesamiento con una estructura que imita el comportamiento de las neuronas biológicas para la solución de problemas.

La Estructura de la RNA consta de: capa de entrada, capas ocultas y capa de salida; a esta estructura se le denomina perceptrón multicapa (Figura 1).

El número de neuronas de la capa de entrada es igual al número de parámetros independientes de entrada. La capa de salida consta de tantas neuronas como variables de salida. Para las capas ocultas, es difícil precisar el número de neuronas; se hacen pruebas con número variable de neuronas y el número apropiado se selecciona con base en el análisis de los resultados del proceso de entrenamiento [5].

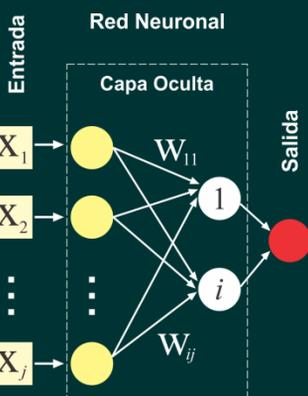


Figura 1. Perceptrón Multicapa

1.1. Modo de Operación de la Red: La información de entrada se define como un vector $X = [X_1, X_2, \dots, X_n,]$ [4].

Cada neurona i de la capa de entrada recibe un dato de entrada X_i , y lo envía como entrada a la neurona j de la siguiente capa (capa oculta).

Cada neurona j de la primera capa oculta recibe un dato X_i de cada una de las neuronas de la capa de entrada, lo multiplica por el correspondiente peso sináptico W_{ij} , generando una señal de salida como suma ponderada de las señales recibidas [5]:

$$u_j = \sum_i W_{ij} X_i \quad (1)$$

A continuación aplica una función de activación a la suma ponderada para generar un dato de salida $f(u_j)$, que va a una neurona de la capa siguiente (oculta o capa de salida) [4], [5].

$$f(u_j) = f(\sum_i W_{ij} X_i) \quad (2)$$

1.2. Pre-procesamiento FUZZY: Para el procesamiento de datos con redes neuronales, es conveniente preseleccionar las variables de entrada según su grado de importancia. Esto simplifica considerablemente el manejo y optimiza el rendimiento de las redes neuronales.

Recientemente se ha desarrollado un procedimiento basado en la aplicación de curvas y superficies fuzzy para éste tipo de pre-procesamiento [6], [7].

1.3. Entrenamiento de la Red: Se tienen m casos experimentales con valores de las variables de entrada y de la variable salida para cada caso. Estos m casos se utilizan en el entrenamiento de la red neuronal para la realización de la tarea de interés.

El proceso de entrenamiento genera la estructura apropiada de la Red. En el caso de relaciones de regresión, la red neuronal establece una correlación matemática entre las variables de entrada de la red y las salidas deseadas durante el proceso de entrenamiento; esta correlación está dada por los pesos sinápticos y las funciones de activación que unen las neuronas.

Durante el entrenamiento la red ajusta gradualmente los pesos sinápticos hasta que la diferencia entre los valores de salida experimentales (y) y los simulados por la red (t) alcanzan un mínimo.

Como criterio de error se utiliza el error cuadrático medio (MSE).

$$mse = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 \quad (3)$$

El proceso avanza hasta que se alcanza el mínimo error o el número de iteraciones supera un número estipulado por el programador de la red. A este procedimiento se le denomina aprendizaje supervisado.

Tipo de característica	Variable	Unidad
Condiciones operacionales	Presión	PSI
	Temp.	°F
	Flujo de Crudo	BPD
	Flujo de Gas	mmscf /d
	Flujo de Agua	BPD
	API	
Físico químicas	Ph	
Gases Corrosivos	CO2	%v/v
	H2S	Ppm
Corrosión	Velocidad Corrosión	Mpy

Tabla 1: Variables de entrada y variable de salida

	Well Head	Manifold	Línea	Total
Cupones	107	82	18	207

Tabla 2: Información de trabajo recopilada para cupones

Variables más importantes
1. Flujo Crudo
2. PH
3. CO2
4. H2S

Tabla 3: Clasificación de las variables según la metodología fuzzy

2. CASO DE ESTUDIO

2.1. Variables para determinar velocidades de corrosión: La experiencia determina que las variables asociadas al proceso de corrosión por CO₂ y H₂S son: presión, temperatura, flujo de crudo, flujo de gas, flujo de agua, pH y API, presentadas en la tabla 1.

En este caso se tomó información de 207 cupones (fabricados en acero al carbón), ubicados en diferentes puntos de un sistema específico (Tabla 2).

2.2. Pre-procesamiento de la información: El pre-procesamiento fuzzy de los datos de entrada generó la clasificación mostrada en la tabla 3.

2.3. Generación de la red neuronal: En la figura 2 y la tabla 4 se registran los resultados de los entrenamientos con diferente número de variables de entrada según los resultados de la metodología fuzzy: Error cuadrático medio (MSE) y número de neuronas en la capa oculta (NCO).

Se observan que 5 repeticiones (entrenamientos o prototipos) bajo las condiciones mencionadas generan valores de MSE similares.

La estructura con 8 neuronas en la capa de entrada y 30 neuronas en la capa oculta que genera el mínimo valor de MSE se selecciona como la más apropiada. (Figura 2).

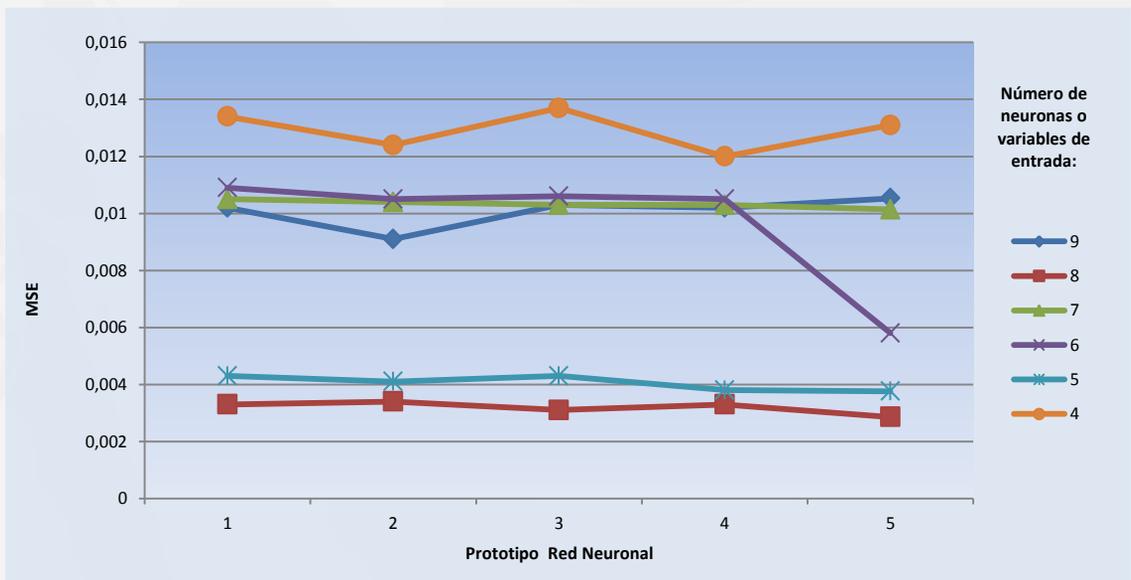


Figura 2: Rendimiento de Redes Neuronales

Neuronas capa entrada	9		8		7		6		5		4	
	NCO	MSE	NCO	MSE	NCO	MSE	NCO	MSE	NCO	MSE	NCO	MSE
1	23	0,0102	22	0,0033	24	0,0105	37	0,0109	37	0,0043	29	0,0134
2	24	0,0091	39	0,0034	27	0,0104	38	0,0105	36	0,0041	36	0,0124
3	25	0,0103	37	0,0031	37	0,0103	30	0,0106	40	0,0043	35	0,0137
4	26	0,0102	33	0,0033	36	0,0103	39	0,0105	33	0,0038	29	0,0120
5	25	0,01053	30	0,0028	30	0,0101	27	0,0058	35	0,0037	32	0,0131

Tabla 4: Resultados redes neuronales

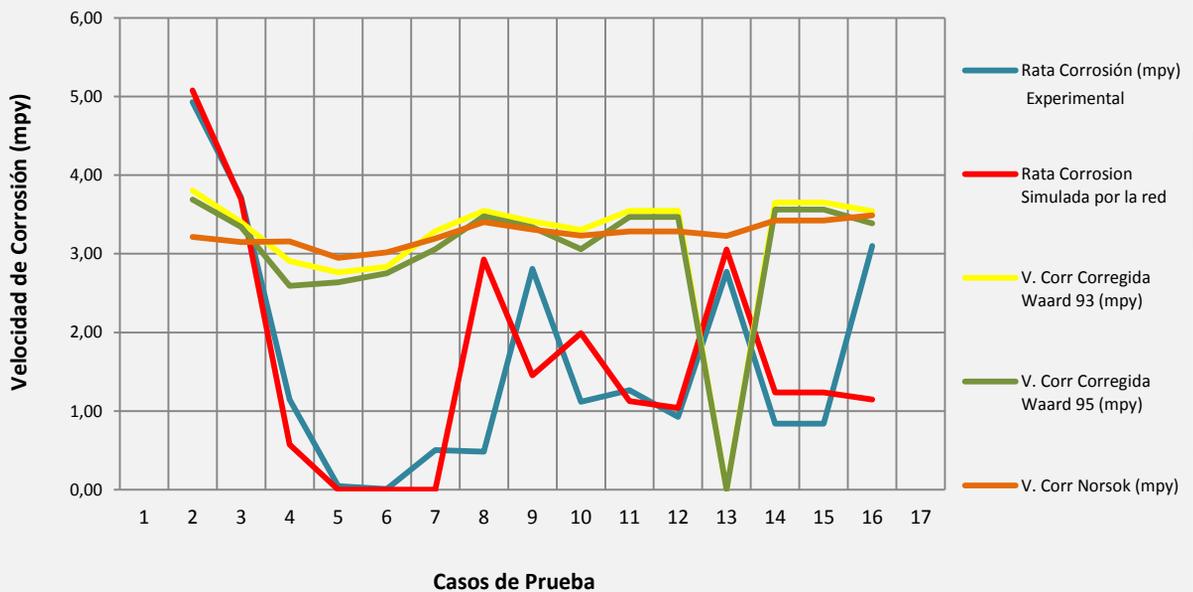


Figura 3: Cálculos de velocidad de corrosión: RNA vs Modelos convencionales

La figura 3 presenta la comparación de la estimación de velocidades de corrosión utilizando RNA y los modelos de uso convencional. Se observa que las predicciones de la RNA son las que mejor coinciden con los datos experimentales

CONCLUSIONES:

Las redes neuronales artificiales presentan buenos resultados para la estimación de velocidades de corrosión en sistemas de hidrocarburos.

La calidad de los resultados depende estrechamente de la cantidad y calidad de la información.

REFERENCIAS

- [1] M.B.Kernany and D. Harrop, BP International, SPE 29784, 1995.
- [2] Corrosion Cost and Preventative Strategies in the United States, September 2001, Report FHWA-RD-01-156.
- [3] Fuentes Carmelo, Peña D. (2007). "Predicción de la Corrosión por CO₂ + H₂S en Tuberías de Acero al Carbono", Scientia et Technica Año XIII, No 36, p. 881.
- [4] Caicedo, Eduardo y Jesús López. 2009. Una aproximación practica a las Redes Neuronales Artificiales. Cali: Editorial Universidad del Valle.
- [5] Molina, Alfredo y Bonifacio del Brio. 2007. Redes Neuronales y sistemas Borrosos. México: Alfaomega Grupo Editor S.A.
- [6] Y. Lin, G. Cunningham and S. Coggeshall. 1996. Input Variable Identification – Fuzzy Curves and fuzzy Interfaces. Fuzzy Sets and Systems.82:65.
- [7] Y. Lin, G. Cunningham, S. Coggeshall and R. Jones. September 1998. Nonlinear System Input Structure Identification: Two Stage Fuzzy Curves and Surfaces. IEEE. Vol. 28, No 5, Page 638.

CIC - SOLUCIONES TECNOLÓGICAS

SISTEMA DE **MONITOREO REMOTO** DE POTENCIALES DE PROTECCIÓN CATÓDICA

ESTACIÓN DE **CONEXIÓN Y MEDICIÓN** DE SISTEMAS DE PROTECCIÓN CATÓDICA

