

IMPLEMENTACIÓN DE REDES NEURONALES PARA PREDECIR PRESIÓN DE MISCIBILIDAD EN LA INYECCIÓN DE DIÓXIDO DE CARBONO

JOHANNA BARREIRO, ALEXIS GAMMIERO

Universidad Central de Venezuela. Escuela de Ingeniería de Petróleo.

e-mails: johannabarreiro@gmail.com / gammieroale@hotmail.com

Recibido: enero 2015

Aprobado para publicación: marzo 2016

RESUMEN

La inyección de Dióxido de Carbono (CO_2), ha demostrado ser un método efectivo en la recuperación mejorada de crudos livianos y medianos, debido a la disminución de la saturación residual del crudo al obtener condiciones miscibles. En la presente investigación, se desarrolló una correlación por medio de Redes Neuronales Artificiales (RNA), para predecir Presión Mínima de Miscibilidad (PMM) en la inyección de CO_2 , ya que los métodos experimentales para predecir PMM requieren grandes costos y tiempo. La PMM está correlacionada con la temperatura del yacimiento, fracción de componentes volátiles (X_{vol}) e intermedios (X_{int}) presentes en el crudo, masa molecular de la fracción de C_{5+} (MMC_{5+}), concentración de CO_2 y de componentes presentes en el mismo tales como N_2 , CH_4 , $\text{C}_2\text{-C}_4$ y H_2S . Se evaluaron diferentes arquitecturas y posteriormente se seleccionó la función entrenamiento y transferencia, número de capas ocultas y tolerancia del error cuadrático medio. Luego se realizó un análisis de sensibilidad respecto a distintos conjuntos de datos y número de neuronas para definir la arquitectura final. Se evaluó la consistencia en la física de los sistemas propuestos, donde el aumento de la temperatura, X_{vol} , MMC_{5+} , al igual que la concentración de N_2 y CH_4 en el gas, influyen en el incremento de la PMM. Un efecto inverso se espera al incrementar X_{int} , la concentración de H_2S y fracción de $\text{C}_2\text{-C}_4$ presentes en el gas de inyección. Finalmente, se estableció una comparación entre el error promedio obtenido por la RNA propuesta y las correlaciones de la literatura, donde se encontró que la RNA resultó ser más exacta en sus predicciones.

Palabras clave: correlación, miscibilidad, presión mínima de miscibilidad, dióxido de carbono, redes neuronales artificiales

IMPLEMENTATION OF NEURAL NETWORK FOR PREDICTING MINIMUM MISCIBILITY PRESSURE IN CARBON DIOXIDE FLOODING

ABSTRACT

Carbon Dioxide Injection has been an effective method for enhanced recovery of light and medium oils achieving the reduction of residual oil saturation to obtain miscible conditions. In the present study, a correlation was performed using Artificial Neural Networks (ANN) to predict Minimum Miscibility Pressure (MMP) in CO_2 flooding, because the experimental methods used to predict MMP require large cost and time. The MMP is correlated with reservoir temperature, volatile (X_{vol}) an intermediate (X_{int}) fractions in the oil, molecular weight of C_{5+} fraction (MWC_{5+}), CO_2 concentration and the impurities present in CO_2 stream such as N_2 , CH_4 , $\text{C}_2\text{-C}_4$ and H_2S . The network was trained and then was selected the training and transfer function, number of hidden layers and the mean square error tolerance for the basic architecture. Then, an analysis of sensitivity to different data sets and the number of neurons to define the final architecture of the network was performed. In this study was evaluated the physical consistency of the proposed systems, where the reservoir temperature increase, X_{vol} , MWC_{5+} and the concentration of components such as N_2 and CH_4 in gas, influence on the increase of MMP. A reverse effect is expected to increase X_{int} , the concentration of H_2S and $\text{C}_2\text{-C}_4$ fraction present in the gas injection. Finally, a comparison was made between the average error obtained by RNA and correlations proposed in the literature, which found that the RNA was more accurate in their predictions.

Keywords: correlation, miscibility, minimum miscibility pressure, carbon dioxide, artificial neural network

INTRODUCCIÓN

Durante las dos últimas décadas la inyección de Dióxido de Carbono (CO_2), ha demostrado ser un método efectivo en la recuperación mejorada de crudos livianos y medianos. Por otra parte, el cambio climático es un problema de proporciones globales y una de sus causas está relacionada a la emisión de gases del efecto invernadero tales como el CO_2 . Los puntos mencionados previamente hacen que para crudos livianos y medianos, la inyección de CO_2 sea uno de los principales métodos de recuperación mejorada lo cual se refleja en una diversidad de aplicaciones a nivel mundial. Sin embargo, la disponibilidad del CO_2 para este método de recuperación puede depender de utilizar esquemas selectivos para la remoción del mismo en el gas natural mediante aminas reformuladas.

El comportamiento de fases de los sistemas CO_2 /crudo, ha sido investigado ampliamente desde los años 60. Aunque su mayor auge ocurrió a finales de los años 70 y principio de los 80 con el aumento de los precios del petróleo y el inicio de muchos proyectos de inyección de CO_2 . Estudios para entender el desarrollo y la predicción de la presión de miscibilidad en la inyección de CO_2 puro e impuro, se han venido desarrollando en los últimos 30 años, debido a que en estos procesos se logra disminuir la saturación de petróleo residual y por ende un incremento en el factor de recobro.

Un concepto importante asociado con la inyección de CO_2 es la Presión Mínima de Miscibilidad (PMM). A esta presión, se puede alcanzar las condiciones miscibles por disminución de la tensión interfacial y la eficiencia microscópica de desplazamiento se incrementa. Existen dos tipos de desplazamientos miscibles: la miscibilidad al primer contacto, cuando un hidrocarburo de masa molecular intermedia como propano, butano o cualquier Gas Licuado del Petróleo (GLP), se pone en contacto con el crudo y se mezclan en todas sus proporciones formando una sola fase entre ellos, o la miscibilidad por múltiples contactos cuando el petróleo y el gas inyectado como nitrógeno, dióxido de carbono y gas natural no entran en equilibrio inmediatamente, requieren de una transferencia de componentes hidrocarburos entre ambos fluidos. Esta transferencia de masa puede ocurrir mediante el enriquecimiento del gas a través de la vaporización de las fracciones intermedias del crudo (miscibilidad por vaporización) o mediante el enriquecimiento del crudo a través de la condensación de las fracciones intermedias del gas rico (miscibilidad por condensación).

Cuando se inicia un proyecto de recuperación mejorada

por inyección de CO_2 , deben tomarse en cuenta ciertos factores como los cambios en la solubilidad de asfaltenos que pueden reducir la permeabilidad y disminuir la productividad al precipitar en la formación y aquellos factores que afectan la miscibilidad como la presión, la temperatura del yacimiento, la composición del crudo y el gas de inyección. Este último factor depende de la fuente del CO_2 (natural o industrial) ya que determina la cantidad de contaminantes como N_2 , CH_4 , H_2S y de las fracciones de $\text{C}_2 - \text{C}_3$ presentes. También la composición del crudo es un parámetro de gran importancia, ya que en la inyección de CO_2 ocurre miscibilidad por vaporización y la cantidad de componentes intermedios presentes en el petróleo, controlan el proceso de transferencia de masa hacia el gas. La PMM se puede estimar por medio de pruebas experimentales como el método de Tubo Delgado (*Slim Tube*) o Burbuja Ascendente (*Rising Bubble*), así como también por medio de modelos analíticos tales como correlaciones matemáticas y gráficas. El método de tubo delgado es una de las técnicas más utilizadas y aceptadas en la industria petrolera. Sin embargo, para la misma se requiere de largos tiempos de ensayos y costos elevados. Debido a esto, un gran número de correlaciones se han desarrollado utilizando como base los datos obtenidos por pruebas de tubo delgado. Un enfoque alternativo para generar correlaciones en la predicción de la PMM es la aplicación de Redes Neuronales Artificiales (RNA). Las RNA son herramientas para el modelado de sistemas complejos, que han sido utilizadas ampliamente en la solución de problemas en la industria petrolera asociados a programas de perforación, completación, evaluación de formaciones, producción, geología, geofísica, ingeniería de yacimientos y en el análisis económico del mercado petrolero. Sin embargo, existen pocas aplicaciones de esta herramienta y con escasa información en la predicción de la PMM.

REDES NEURONALES ARTIFICIALES (RNA)

Kohonen (1988) (citado en Flórez y Fernández, 2008) definió que las RNA son redes interconectadas masivamente en paralelo de elementos simples y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico. Por lo tanto, se pueden considerar como modelos que tratan de simular el comportamiento del cerebro humano y se caracterizan por el aprendizaje a través de la experiencia y la extracción de conocimiento genérico a partir de un conjunto de datos. Una RNA está formada por parámetros de entrada ($x_0, x_1 \dots x_n$), que provienen de un fuente externa y una salida que transmite la información al exterior de la red o a otras neuronas.

La señal de salida se calculará en función de las entradas, donde cada una de ellas es afectada por una ganancia o peso que determina la fuerza de la conexión, conocido como peso sináptico ($w_0, w_1 \dots w_n$). En cada nodo se realiza la suma de todas las señales de entrada multiplicadas por los pesos y luego el resultado es evaluado por la función transferencia (lineal, sigmooidal o tangente hiperbólica), para generar la salida de la red tal como se muestra en la ecuación 1:

$$X_{neta} = \sum_{i=1}^n (w_i \times x_i) + b_i \quad (1)$$

Donde:

- w_i : pesos asociados a cada neurona
- x_i : parámetros de entrada
- b_i : vector de tendencias o *bias* de las neuronas
- X_{neta} : salida de la red neuronal

Para este estudio es utilizado el algoritmo *Backpropagation*, que constituye el modelo de aprendizaje más utilizado y funciona de la siguiente forma: los patrones de entrada son presentados a la primera capa de la red y se propaga dicho estímulo a través de todas las capas posteriores, hasta generar una salida en el sistema. Si el error entre la salida generada y la deseada es aceptable, se paraliza el entrenamiento de la red. De lo contrario, estos errores se transmiten desde la capa de salida hacia las neuronas de la capa precedente y este proceso se repite capa por capa, hasta que todas las neuronas de la red hayan recibido un error, que describa su aporte relativo a la salida final. A partir de este valor de error se reajustan los pesos de cada neurona para minimizarlo. Si el aprendizaje ha sido eficaz, la red debe generar una salida próxima a la deseada ante la presencia de un dato de entrada desconocido.

CORRELACIONES PARA PREDECIR PMM EN LA INYECCIÓN DE CO₂ PURO E IMPURO

En la década de los 80 se produjo un gran interés hacia los métodos de recuperación mejorada, debido al aumento en los precios del petróleo. Para la inyección de CO₂ el número de proyectos ha permanecido desde los años 80 prácticamente constante, sin embargo en los últimos años ha crecido el interés hacia el mismo (ver figura 1), con el fin de aumentar el factor de recobro, disminuir la contaminación ambiental debido a la emisión de gases y a las presiones de miscibilidad con CO₂, que suelen ser relativamente bajas respecto a otros gases.

Un parámetro de vital importancia en la inyección de CO₂ es la determinación de la PMM a través de correlaciones matemáticas para CO₂ puro como impuro. Las correlaciones




Figura 1. Precios del petróleo en función del número de proyectos de CO₂ (Manrique et al, 2010)

analizadas en esta investigación comprenden las publicadas por Holm y Josendal (1974), National Petroleum Council (1976), Cronquist (1978), Dunyushkin y Namiot (1978), Petroleum Recovery Institute (1979), Lee (1979), Yellig y Metcalfe (1980), Mungan (1981), Johnson y Pollin (1981), Orr y Jensen (1984), Glaso (1985), Sebastian et al. (1985), Alston et al. (1985), Kovarik (1985), Orr y Silva (1987), Enick (1988), Eakin y Mitch (1988), Zuo et al. (1993), Dong et al. (1999), Huang et al. (2003), Yuan et al. (2004), Emera y Sarma (2005), Mousavi et al. (2006), Shokir (2007), Ghomian et al. (2008), Akbari et al. (2011) y Nezhad et al. (2011). En total, se cuenta con 27 correlaciones para calcular o predecir PMM con CO₂ puro e impuro.

Con respecto al año en que fueron desarrolladas cada una de las correlaciones, se muestra en la figura 2 una gráfica del porcentaje de correlaciones llevadas a cabo en cada una de las décadas. Un 41 por ciento fueron generadas en la década de los 80 cuando los precios del petróleo y el número de proyectos de recuperación mejorada aumentaron. Sin embargo, en los últimos años la inyección de CO₂, ha demostrado ser uno de los métodos que ha tenido mayor auge, por lo tanto un 30 por ciento de las correlaciones existentes fueron desarrolladas en esta época.

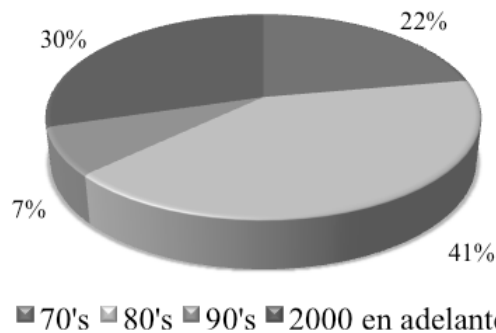


Figura 2. Representación gráfica del año de las correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO₂

Otro análisis se puede realizar en cuanto al origen de los datos utilizados para generar la correlación. En la figura 3 se muestra una gráfica del porcentaje de correlaciones que fueron desarrolladas en base a datos obtenidos por el método de burbuja ascendente y tubo delgado, donde fueron llevadas a cabo un 74 por ciento y un 9 por ciento respectivamente. El 17 por ciento restante se refiere al caso en donde se utilizaron datos de ambas fuentes. Cabe destacar que para este análisis se tomaron en cuenta únicamente 22 correlaciones, ya que no se dispuso de información referida al origen del resto de las mismas.

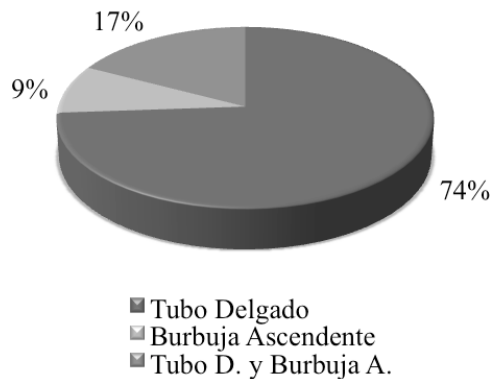


Figura 3. Representación gráfica del origen de la correlación para predecir la presión mínima de miscibilidad en la inyección de CO_2

Con respecto al tipo de correlación desarrollada, se muestra en la figura 4, la clasificación y el porcentaje correspondiente a cada uno de estas. Los tres grupos que se definen son: ecuaciones, gráficas y RNA. En esta gráfica (figura 4), se puede observar que la mayor parte de las correlaciones comprenden ecuaciones matemáticas derivadas de regresiones (lineales y no lineales), ya que son fáciles de generar y más precisas que las correlaciones gráficas.




Figura 4. Representación gráfica del tipo de correlación para predecir la presión mínima de miscibilidad en la inyección de CO_2

Las primeras correlaciones fueron de tipo gráficas y entre las cuales se encuentra las desarrolladas por Holm y Josendal en el año 1974, Yellig y Metcalfe (1980), Mungan (1981), Dunyushkin y Namiot (1978) y Enick (1988). En la figura 5 se muestra que estas últimas fueron generadas únicamente en la década de los 70 y 80. Posterior a estos tiempos, se fue perdiendo el interés hacia este tipo de correlaciones, ya que son menos precisas en el cálculo de la PMM y surgió un mayor interés en correlaciones en forma de ecuación, la cual ha predominado desde los años 70 hasta los 90. En los últimos años, se ha venido desarrollando una alternativa basada en la teoría de la inteligencia artificial conocida como Redes Neuronales Artificiales (RNA), que permite construir un modelo más preciso y fiable. Es por esto, que un 50 por ciento de las correlaciones realizadas en la última década pertenecen a este grupo. Las correlaciones que implementan RNA fueron desarrolladas por Huang et al. (2003), Mousavi et al. (2006), Akbari y Kasiri (2010) y Nezhad et al. (2011).




Figura 5. Representación gráfica del tipo de correlación evaluada en función del tiempo

En relación al tipo de gas usado para generar cada correlación, se observa en la figura 6 el porcentaje de aquellas que permiten calcular PMM ya sea para CO_2 puro, impuro o ambas. Para el caso del CO_2 puro, existen correlaciones desarrolladas por Holm y Josendal (1974), National Petroleum Council (1976), Petroleum Recovery Institute (1979), Cronquist (1978), Lee (1979), Yellig y Metcalfe (1980), Orr y Jensen (1984), Mungan (1981), Glaso (1985), Orr y Silva (1987), Zuo et al. (1993), Emera y Sarma (2005) y Ghomian et al. (2008). Por otra parte, Dunyushkin y Namiot (1978), Kovarik (1985), Sebastian et al. (1985) y Dong et al. (1999) desarrollaron correlaciones solo para el caso de CO_2 impuro. De la misma manera, existen otras correlaciones que pueden ser usadas tanto para CO_2 puro e impuro llevadas a cabo por Huang et al. (2003), Alston et al. (1985), Enick (1988), Eakin y Mitch (1988), Yuan et al. (2004), Johnson y Pollin (1981), Nezhad et al. (2011), Mousavi et al. (2006), Shokir (2007) y Akbari y Kasiri (2010).




Figura 6. Representación gráfica del tipo de gas usado en las correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO₂

Para entender el porcentaje de correlaciones llevadas a cabo según el tipo de gas usado y la década en que estas fueron desarrolladas, se muestra en la figura 7 el porcentaje de las mismas desde los años 70 hasta la actualidad. Se observa que el desarrollo de correlaciones para CO₂ puro ha venido disminuyendo en la década de los 80 y 90, incluso en los últimos años se desarrollaron pocas correlaciones de este tipo. A diferencia del CO₂ puro, el CO₂ impuro está disponible desde varias fuentes incluyendo reservas naturales, plantas de proceso o también procedente de pozos que se encuentren en campos bajo un esquema de explotación por inyección de CO₂. Es por esto, que al pasar los años se fueron desarrollando correlaciones que incluyeran componentes tales como CH₄, N₂, H₂S, C₂-C₄ en la corriente de gas.

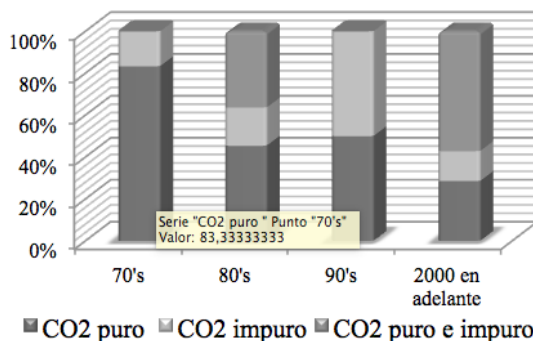


Figura 7. Representación gráfica del porcentaje de correlaciones según el tipo de gas en función del tiempo

ANÁLISIS ESTADÍSTICO

El análisis estadístico fue aplicado para 181 datos en total, de los cuales se obtuvo una matriz con 65 datos para CO₂ puro y 116 datos para CO₂ impuro. Los datos utilizados para la construcción del modelo provienen de las publicaciones de Holm y Josendal (1974), Graue y Zana (1981), Sebastian et al. (1984), Alston et al. (1985), Eakin y Mitch (1988), Harmon y Grigg (1988), Jaubert et al. (2001), Zuo et al. (1993), Wu (1995), Mousavi et al. (2006), Yuang et al. (2004), Bon et al. (2005), Shokir (2007), Adyani et al.

(2007) y Al_Ajmi et al. (2009).

Para la construcción de la RNA fueron utilizados parámetros de entrada como la temperatura, la masa molecular de la fracción de C₅₊, la fracción de los componentes volátiles e intermedios, la concentración de CO₂ y de componentes presentes en el mismo tales como el N₂, CH₄, C₂-C₄ y H₂S. Para llevar a cabo dicho análisis, se utilizaron medidas estadísticas tales como la media, mediana, máximo y mínimo, desviación estándar, varianza, covarianza, coeficiente de correlación, curtosis, asimetría y gráficas estadísticas como histogramas y diagramas de dispersión. En la tabla 1 se observa el valor máximo y mínimo correspondiente a cada parámetro analizado, indicando que existe un amplio intervalo de condiciones en la que se puede implementar la RNA desarrollada.

Tabla 1. Máximo y mínimo de cada variable estudiada

| | Mínimo | Máximo |
|--|--------|--------|
| Temperatura (°F) | 69,80 | 279,00 |
| PMC ₅₊ | 136,18 | 302,50 |
| Xvol (N ₂ ,CH ₄) | 0,00 | 54,00 |
| Xint (CO ₂ , C ₂ -C ₆) | 1,20 | 52,76 |
| CO ₂ | 40,00 | 100,00 |
| N ₂ | 0,00 | 19,00 |
| CH ₄ | 0,00 | 28,00 |
| C ₂ -C ₄ | 0,00 | 28,00 |
| H ₂ S | 0,00 | 50,00 |

DESARROLLO DEL MODELO

Selección de la arquitectura base

En esta etapa se analizó el comportamiento de las distintas arquitecturas de RNA evaluadas, donde se utilizó un 70 por ciento de la base de datos para la fase de entrenamiento (127 valores del total) y para la prueba de la misma, se utilizó el 30 por ciento (54 valores del total). Las arquitecturas evaluadas fueron hechas únicamente para un conjunto (*set*) de la base de datos. Esto quiere decir que con el mismo conjunto de datos de entrenamiento y prueba se corrieron distintos escenarios sensibilizando el error cuadrático medio, función entrenamiento y transferencia, número de capas ocultas y neuronas de la red.

Por otra parte, se realizó un preprocesamiento de los datos con el fin de tener las variables de entrada y la salida de la red en un mismo rango de magnitud mediante la ecuación 2. El punto previo es ejecutado ya que las variables utilizadas

para la construcción de la red, se encuentran en escalas totalmente diferentes. Se evaluaron dos escenarios, la cual incluye normalización en los intervalos [0,1] y [-1,1].

$$X'_i = \left(\frac{x_i - \min(x)}{\max(x) - \min(x)} \times (new_max - new_min) + new_min \right)_p \quad (2)$$

Donde:

X'_i : valor normalizado de la propiedad

$\min(x)$: valor mínimo de la propiedad x

$\max(x)$: valor máximo de la propiedad x

x_i : valor actual de la propiedad.

Para normalizar en el intervalo [0,1]:

$new_min = 0, new_max = 1$

Para normalizar en el intervalo [-1,1]:

$new_min = -1, new_max = 1$

Una vez seleccionados y preprocesados los datos, se procede al entrenamiento de la RNA. El objetivo de esta etapa es determinar el número de capas ocultas y neuronas, que tendrán cada una de ellas, con el fin de conseguir la red neuronal más sencilla que mejor se aproxime al valor de PMM experimental. Para esto se hizo un análisis de sensibilidad con cada uno de los parámetros que conforma la red tales como la función de entrenamiento y transferencia, número de capas ocultas, número de neuronas y el Goal o error cuadrático medio, que se tiene como objetivo.

Selección de la arquitectura final

En esta sección se selecciona en forma definitiva la arquitectura de la RNA. Para esto, se llevó a cabo un análisis de sensibilidad respecto a distintos conjuntos de datos y al número de neuronas correspondientes en cada capa oculta, dejando fija la función de entrenamiento y transferencia, número de capas ocultas y la tolerancia del error cuadrático medio definida en la fase anterior.

Para evaluar el comportamiento de las distintas arquitecturas de la red, se utilizó un 80 por ciento de la base de datos para la fase de entrenamiento, lo que abarca 145 valores del total y para la prueba de la misma, se utilizó el 20 por ciento de la base de datos restante, comprendiendo 36 valores.

La estructura de la red neuronal más exitosa es aquella donde se tiene la arquitectura más sencilla con el error de predicción más bajo para un determinado conjunto de datos, es decir, cuando la diferencia entre el valor predicho y el valor real es lo más pequeño posible. En la tabla 2 se muestra el error relativo promedio y el coeficiente de correlación de la RNA desarrollada en esta investigación para el conjunto de datos seleccionado, donde se obtuvo el

error de predicción más bajo con un 6,68 por ciento, al igual que sus valores en el coeficiente de correlación indican un buen ajuste de los datos utilizados. A su vez, es la RNA que posee la arquitectura más sencilla en cuanto al número de neuronas utilizadas, con ocho neuronas en la primera capa oculta y cuatro neuronas en la segunda capa.

Tabla 2. Error relativo promedio y coeficiente de correlación de la RNA desarrollada

| Correlación | Error relativo promedio (%) | | Coeficiente de correlación (R) | |
|-----------------------------------|-----------------------------|------|--------------------------------|------|
| | E | P | E | P |
| RNA | 4,13 | 6,68 | 0,99 | 0,97 |
| <i>E: Entrenamiento P: Prueba</i> | | | | |

En la figura 8 se muestra el error relativo porcentual de los datos de evaluación en función del número de neuronas para cada capa oculta, donde se puede corroborar que el error de prueba más bajo corresponde a la RNA con ocho neuronas en la primera capa oculta y cuatro neuronas en la segunda capa.

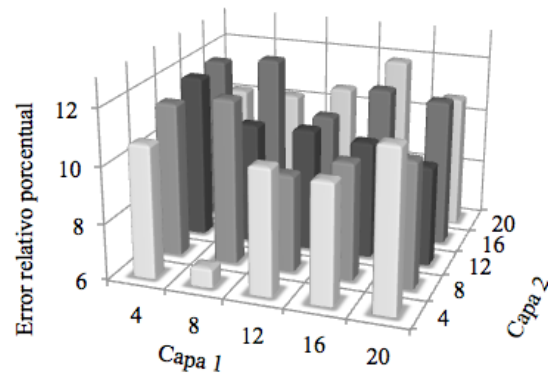


Figura 8. Error relativo porcentual de prueba en función del número de neuronas para dos capas ocultas de la red neuronal final

Por otra parte, en las figuras 9 y 10 se muestra la correlación entre los datos experimentales y los obtenidos por la RNA desarrollada, tanto para los datos de entrenamiento y evaluación. El valor del coeficiente de correlación en las gráficas, demuestra un alto ajuste de los datos implementados en el entrenamiento y prueba de la misma.

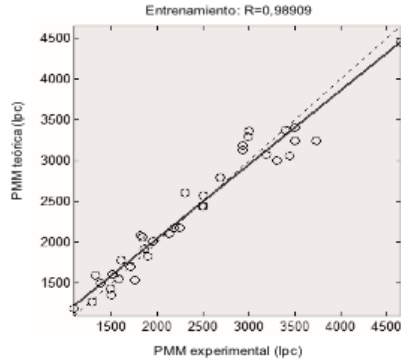


Figura 9. PMM estimada en función de la PMM experimental para la prueba de la red




Figura 10. PMM estimada en función de la PMM experimental para el entrenamiento de la red

A su vez, para tener una mejor representación del modelo desarrollado, se muestra en la figura 11 la arquitectura de la RNA final, donde se observan las variables de entrada utilizadas para entrenar la red, al igual que la arquitectura correspondiente.

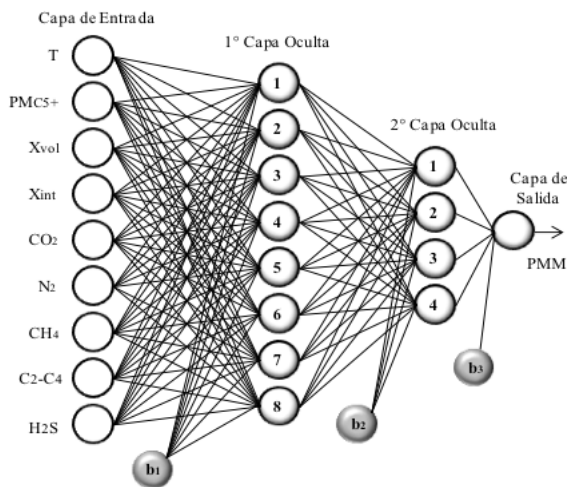


Figura 11. Arquitectura final de la RNA para predecir la PMM en la inyección de CO2

Igualmente, la RNA de la figura 11 puede ser representada matemáticamente por medio de la ecuación matricial:

$$PMM_p = \text{logsig}(LW_2 * \text{logsig}(LW_1 * \text{logsig}(IW * p + b_1) + b_2) + b_3) \quad (3)$$

Donde:

p : vector de entrada (9x1)

IW : matriz de pesos entre la capa de entrada y la primera capa oculta (8x9)

LW_1 : matriz de pesos entre la primera capa oculta y la segunda capa oculta (4x8)

LW_2 : matriz de pesos entre la segunda capa oculta y la capa de salida (1x4)

b_1 : vector de tendencias o *bias* de las neuronas en la primera capa oculta (8x1)

b_2 : vector de tendencias o *bias* de las neuronas en la segunda capa oculta (4x1)

b_3 : tendencia o *bias* de la neurona en la capa de salida

PMM_p : Valor estimado por la red neuronal

Los vectores de tendencia o *bias*, al igual que los pesos correspondientes de la correlación desarrollada en esta investigación, se muestran desde la tabla 5 a la tabla 10.

VALIDACIÓN FÍSICA DE LAS VARIABLES

En esta sección se verificó que la red cumple con el comportamiento físico apropiado que deben tener ciertas variables frente a la PMM y que han sido ampliamente reportadas en la literatura. Se logró verificar que el aumento de la temperatura del yacimiento, la fracción de componentes volátiles presentes en el crudo, la masa molecular de la fracción de C_{5+} , al igual que la concentración de componentes tales como el N_2 y CH_4 en el gas, influyen en el incremento de la PMM. En cambio, esta última disminuye al aumentar la fracción de componentes intermedios presentes en el crudo, la concentración de H_2S y componentes desde el C_2 hasta el C_4 presentes en el gas de inyección.

COMPARACIÓN DE LA CORRELACIÓN GENERADA POR RNA Y LAS CORRELACIONES DE LA LITERATURA

Se han desarrollado investigaciones previas acerca de la implementación de RNA en la predicción de la PMM para la inyección de CO_2 puro e impuro. En la tabla 4 se observan los resultados obtenidos en las investigaciones llevadas a cabo por Nezhad et al. (2011), Akbari y Kasiri (2010), Mousavi et al. (2006), Huang et al. (2003) y la obtenida en esta investigación. Para esta se reporta el número de datos implementados para la prueba y entrenamiento de la red, así como la arquitectura obtenida para ciertos casos.

Con respecto a la cantidad de datos que se tiene para la fase

de entrenamiento y prueba en la construcción de la RNA, se tiene que Mousavi et al. (2006) utilizaron la menor cantidad de ellos abarcando 55 datos en total, seguido de Akbari y Kasiri (2010) que contaron con 128 y por último Nezhad et al. (2011) con 179 datos. La correlación llevada a cabo en la presente investigación cuenta con una base similar a la de Nezhad et al. (2011) con la inclusión de 2 datos adicionales, llegando a 181 en total. Cabe destacar que para la red desarrollada por Huang et al. (2003), no se cuenta con la cantidad y el porcentaje de datos que utilizaron.

Otro parámetro importante es la arquitectura de la RNA. En el caso de Nezhad et al. (2011) desarrollaron un tipo de red de base radial para la predicción de la PMM, que requiere un mayor número de neuronas que las redes estándar de propagación hacia atrás o backpropagation. En las otras redes reportadas, tal como es el caso de Mousavi et al. (2006) y la red de Akbari y Kasiri (2010), obtuvieron arquitecturas relativamente sencillas. Sin embargo, una de las limitantes más fuertes es que no se reporta en sus publicaciones los parámetros y pesos necesarios, para la construcción de estos modelos y por lo tanto se ve limitada su implementación.

Tabla 3. Correlación obtenida por la RNA desarrollada y las correlaciones por RNA de la literatura

| Correlación | Número de datos | | | Arquitectura | |
|------------------------|-----------------|----|-------|--------------|--------|
| | E | P | Total | Capa 1 | Capa 2 |
| Nezhad et al. (2011) | 154 | 25 | 179 | 100 neuronas | |
| Akbari y Kasiri (2010) | 102 | 26 | 128 | 30 | - |
| Mousavi et al. (2006) | 44 | 11 | 55 | 7 | 5 |
| Huang et al. (2003) | - | - | - | - | - |
| RNA* | 145 | 36 | 181 | 8 | 4 |

E: Entrenamiento P: Prueba
* Red neuronal desarrollada en esta investigación

Además de los modelos desarrollados por RNA, existen otros modelos llevados a cabo por métodos estadísticos, que presentan la predicción de la PMM usando como gas de inyección CO₂ puro e impuro. En la tabla 4 se muestra el error mínimo (E_{Min}), máximo (E_{Max}) y promedio (EP), además del coeficiente de correlación (R), para el modelo desarrollado en esta investigación y las correlaciones reportadas en la literatura, donde se observa que la RNA puede ser usada con mayor exactitud que los métodos convencionales estadísticos. Cabe destacar que los errores

para cada correlación mostrados en la tabla 4, fueron obtenidos en base a los datos implementados en esta investigación.

Tabla 4. Correlación obtenida por la RNA desarrollada en esta investigación y las correlaciones de la literatura

| Correlación | E _{Min} (%) | E _{Max} (%) | EP (%) | R |
|-------------------------------------|----------------------|----------------------|--------|------|
| Shokir (2007) | 0,02 | 87,45 | 20,18 | 0,69 |
| Petroleum Recovery Institute (1979) | 0,05 | 109,94 | 19,49 | 0,71 |
| Cronquist (1978) | 0,57 | 58,21 | 13,70 | 0,90 |
| Lee (1979) | 0,02 | 107,51 | 19,30 | 0,71 |
| Emera y Sarma (2005) | 0,04 | 48,99 | 11,94 | 0,91 |
| Alston et al. (1985) | 0,05 | 64,52 | 16,16 | 0,86 |
| RNA* | 0,28 | 20,32 | 6,68 | 0,97 |

* Red neuronal desarrollada en esta investigación

CONCLUSIONES

La RNA desarrollada en esta investigación cumple con el comportamiento físico descrito en la literatura. El aumento de la temperatura del yacimiento, la fracción de componentes volátiles presentes en el crudo, la masa molecular de la fracción de C₃₊, al igual que la concentración de componentes tales como el N₂ y CH₄ en el gas, influyen en el incremento de la PMM. En cambio, esta última disminuye al aumentar la fracción de componentes intermedios presentes en el crudo, la concentración de H₂S y componentes desde el C₂ hasta el C₄ presentes en el gas de inyección.

Mediante la correlación generada en esta investigación, se puede predecir la PMM en la inyección de CO₂ con un error de 6,68 por ciento. Igualmente, se obtuvo un coeficiente de correlación de 0,97.

La RNA desarrollada en esta investigación, posee una arquitectura sencilla con dos capas ocultas, ocho neuronas en su primera capa y cuatro neuronas en la segunda.

Para la correlación desarrollada existe un amplio intervalo de condiciones en las que se puede implementar la red neuronal.

El algoritmo implementado fue el de *Levenberg-Marquardt*, junto con la función transferencia *tansig* (sigmoide) y una tolerancia del error cuadrático medio de 1×10^{-3} para el entrenamiento de la red, siendo este último el más adecuado para evitar el sobreentrenamiento de la misma.

La implementación de modelos desarrollados por RNA publicados en la literatura, se ven fuertemente limitados por la falta de información que se tiene para la construcción de los mismos.

En la década de los 70 fueron desarrolladas las primeras correlaciones gráficas. Posteriormente, desde los años 70 hasta los 90, hubo una evolución de las mismas donde ha predominado su representación en forma de ecuación, siendo estas últimas las que abarcan la mayor parte de las correlaciones publicadas en la literatura.

La mayor parte de las correlaciones publicadas en la literatura, han sido desarrolladas en la década de los 80 y en base a datos obtenidos por medio de pruebas de tubo delgado.

En la actualidad, se han venido desarrollando correlaciones en base a RNA por ser modelos eficientes en la predicción de la PMM.

REFERENCIAS

- ADYANI, W.N., RAZAK, K. & KECHUT, N.I. (2007). Advanced technology for rapid minimum miscibility pressure determination (Part 1). SPE 110265. Presented at the 2007 SPE Asia Pacific Oil & Gas Conference and Exhibition held in Jakarta, Indonesia.
- AKBARI, M.R. & KASIRI, N. (2011). A determination of minimum miscibility pressure in gas injection process by mixing rules. Presented at 14th Intl. Oil, Gas & Petrochemical Congress.
- AL-AJMI, M., ALOMAIR, O. & ELSHARKAWY, A. (2009, Diciembre). Planning miscibility test and gas injection projects for four major Kuwaiti reservoirs. SPE 127537. Presented at the Kuwait International Petroleum Conference. Kuwait.
- ALSTON, R.B., KOKOLIS, G.P. & JAMES, C.F. (1985, Abril). CO₂ minimum miscibility pressures: a correlation for impure CO₂ streams and live oil systems. SPE 11959, 268–274.
- BON J. & SARMA H.K.. (2005). An investigation of minimum miscibility pressure for CO₂ – rich injection gases with pentanes-plus fraction. SPE 97536.
- DONG, M., HUANG, S., SRIVASTAVA, R. (1999, Junio). Effect of solution gas in oil on co2 minimum miscibility pressure. Paper 99-47. The Petroleum Society. Presented at 1999 CSPG and Petroleum Society Joint Convention, in Calgary, Alberta, Canada.
- EAKIN, B.E. & MITCH, F.J. (1988). Measurement and correlation of miscibility pressures of reservoir oils. SPE Paper 18065 presented at 63rd Annual Technical Conference and Exhibition, Houston, TX, pp. 75–81.
- EMERA, M.K. & SARMA, H.K. (2005). Use of genetic algorithm to estimate co2–oil minimum miscibility pressure—a key parameter in design of CO₂ miscible flood. J. Pet. Sci. Eng. 46, 37–52.
- ENICK, R.M., HOLDER, G.D., MORSI, B.I (1988). A thermodynamic correlation for the minimum miscibility pressure in CO₂ flooding of petroleum reservoirs. SPE Reserv. Eng. J. 2, 81–92.
- GLASO O. (1985). Generalized minimum miscibility pressure correlation. SPE 12893.
- GRAUE, D.J. & ZANA, E.T. (1981, Julio). Study of a possible CO₂ flood in Rangeley field. SPE 7060. J. Pet. Technol., 1312–1318.
- HARMON, R.A. & GRIGG, R.B. (1988). Vapor-density measurement for estimating minimum miscibility pressure. SPE Reserv Eng J., 1215-1220.
- HOLM, L.W. & JOSENDAL, V.A. (1974). Mechanisms of oil displacement by carbon dioxide. J Pet Technol, 1427-1436.
- HUANG, Y.F., HUANG, G.H., DONG, M.Z. & FENG, G.M. (2003). Development of an artificial neural network model for predicting minimum miscibility pressure in CO₂ flooding. Journal of Petroleum Science and Engineering, 37, 83-95.
- JAUBERT, J.N., AVAULLE, L. & SOUVAY, J.F. (2002). A crude oil data bank containing more than 5000 PVT and gas injection data. Journal of Petroleum Science and Engineering. 65-107.

- JOHNSON, J.P. & POLLIN, J.S. (1981). Measurement and correlation of CO₂ miscibility pressures. SPE Paper 9790 presented at the SPE/DOE Second Joint Symposium on Enhanced Oil Recovery, Tulsa, USA, pp. 269–281.
- KOVARIK, F.S. (1985, Noviembre). A Minimum miscibility pressure study using impure CO₂ and West Texas oil systems: data base, correlations, and compositional simulation. SPE 14689. Production Technology Symposium held in Lubbock, Texas.
- MANRIQUE, E., THOMAS, C., RAVIKIRAN, R., IZADI, M., LANTZ, M., ROMERO, J., ALVARADO, V. (2010, Abril). EOR: Current status and opportunities. SPE 130113. Presented at the 2010 SPE Improved Oil Recovery Symposium held in Tulsa, Oklahoma, USA.
- MOUSAVI, S.A., VAFAR SEFTI, M., AMERI, A. & SHOJAI KAVEH, N. (2008). Minimum miscibility pressure prediction based on a hybrid neural genetic algorithm. Chemical Engineering Research and Design, 86, 173-185.
- MUNGAN, N. (1981, Enero). Carbon dioxide flooding - fundamentals. J. Cdn. Pet. Tech. Calgary, Alberta. 87 – 92.
- NEZHAD, A.B., MOUSAVI, S.M. & AGHAHOSEINI, S. (2011). Development of an artificial neural network model to predict CO₂ minimum miscibility pressure. NAFTA 62 (3-4) 105-108.
- ORR, F.M. & SILVA, M.K. (1987). Effect of oil composition on minimum miscibility pressure—Part 2: Correlation. SPE Reserv. Eng. J. 11, 479–491.
- SEBASTIAN, H.M., WENGER, R.S. & RENNER, T.A. (1985, Abril). Correlation of minimum miscibility pressure for impure CO₂ streams. Paper SPE 12648 Presented at the 1984 SPE/DOE Enhanced Oil Recovery Symposium, Tulsa, JPT, 37 (2), 268– 274.
- SHOKIR, EISSA M. EL-M. (2007). CO₂ oil minimum miscibility pressure model for impure and pure CO₂ streams. Journal of Petroleum Science and Engineering.
- YELLIG, W.F. & METCALFE, R.S. (1980). Determination and prediction of CO₂ minimum miscibility pressure. J. Pet. Technol. 1, 160–168.
- YOUSEF GHOMIAN, GARY A. POPE & KAMY SEPEHRNOORI (2008, Septiembre). Development of a response surface based model for minimum miscibility pressure (MMP) Correlation of CO₂ flooding. SPE 116719. Presented at the Annual Technical Conference and Exhibition held in Denver, Colorado, USA.
- YUAN, H., JOHNS, R.T., EGWUENU, A.M. & DINDORUK, B. (2004). Improved MMP correlations for CO₂ floods using analytical gas flooding theory. SPE Paper 89359 presented at the SPE/DOE Fourteenth Symposium on Improved Oil Recovery, Tulsa, USA, pp. 1- 16.
- WU, R.S. & BATYCKY, J.P. (2006). Evaluation of miscibility from slim tube test. Journal of Canadian Petroleum Technology. JCPT 90-06-06. Esso Resources Canada Ltd. Calgary, Alberta.
- ZUO, Y.X., CHU, J.Z., KE, S.L. & GUO, T.M. (1993). A study of the minimum miscibility pressure for miscible flooding systems. J. Pet. Sci. Eng. 8, 315– 328.

Tabla 5. Vector de tendencias o *bias* de las neuronas en la primera capa oculta (b_i)

| Neuronas de la primera capa oculta | b_i |
|------------------------------------|-----------|
| 1 | 10,041925 |
| 2 | 5,629649 |
| 3 | -3,717359 |
| 4 | 4,204047 |
| 5 | -0,322576 |
| 6 | 0,346214 |
| 7 | -0,531967 |
| 8 | 7,939969 |

Tabla 6. Matriz de pesos entre la capa de entrada y la primera capa oculta (IW)

| Neuronas ocultas | Neuronas de entrada | | | | | | | | |
|------------------|---------------------|------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
| IW | T | PM_{C5+} | X_{vol} | X_{int} | CO_2 | N_2 | CH_4 | C_2-C_4 | H_2S |
| 1 | -3,151663 | 2,340150 | -2,413846 | -1,330103 | 1,453491 | -2,982238 | 0,418139 | -2,660173 | 0,347380 |
| 2 | -0,075603 | -3,830991 | 1,186965 | -6,152602 | -3,579369 | -0,646663 | 1,389724 | 4,726675 | 0,565622 |
| 3 | 7,836813 | -5,408437 | -5,207229 | 1,409493 | 2,664934 | -9,072103 | 0,879333 | 2,962439 | 1,029494 |
| 4 | -2,033105 | -5,831264 | 0,544315 | -4,149068 | -2,628977 | -4,984066 | -0,619863 | 2,586069 | 2,277243 |
| 5 | -6,563488 | 4,013093 | 2,773580 | -0,258297 | 0,739621 | 2,478587 | 0,550829 | -0,159658 | 0,833391 |
| 6 | 0,224607 | -5,474297 | 0,733483 | 4,533254 | -5,162978 | -1,028483 | 4,978808 | -2,153426 | -1,444217 |
| 7 | 3,972163 | 6,544274 | 5,723162 | -9,481119 | 1,654273 | -1,305394 | -5,751788 | -1,602377 | 1,976835 |
| 8 | 2,596621 | -7,375412 | -4,214783 | 4,151638 | -2,219228 | -2,452431 | -2,221673 | 6,923406 | -1,603694 |

Tabla 7. Vector de tendencias o *bias* de las neuronas en la segunda capa oculta (b_2)

| Neuronas de la segunda capa oculta | b_2 |
|------------------------------------|-----------|
| 1 | 6,344748 |
| 2 | 0,336473 |
| 3 | -0,617135 |
| 4 | -8,965176 |

Tabla 8. Matriz de pesos entre la primera capa oculta y la segunda capa oculta (LW_1)

| Neuronas de la segunda capa oculta LW_1 | Neuronas de la primera capa oculta | | | | | | | |
|---|------------------------------------|-----------|----------|-----------|-----------|-----------|-----------|-----------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 |
| 1 | -0,514311 | -6,246890 | 0,112318 | 0,349417 | 3,514496 | 1,437986 | -0,409218 | -2,407805 |
| 2 | -3,367314 | -1,262253 | 3,025563 | 3,110286 | 2,761666 | -5,117867 | 1,891641 | 1,917762 |
| 3 | 0,640052 | -3,780076 | 1,460000 | -1,345100 | -1,160247 | 0,566745 | 1,815082 | -0,497227 |
| 4 | -1,696286 | -3,465904 | 6,226385 | 4,193977 | 4,448605 | -1,646341 | 1,279778 | 7,022495 |

Tabla 9. Vector de tendencias o *bias* de la neurona en la capa de salida (b_3)

| Neurona de salida | b_3 |
|-------------------|----------|
| 1 | 2,079050 |

Tabla 10. Matriz de pesos entre la segunda capa oculta y la capa de salida (LW_2)

| Neurona de salida LW_2 | Neuronas de la segunda capa oculta | | | |
|--------------------------|------------------------------------|----------|----------|-----------|
| | 1 | 2 | 3 | 4 |
| 1 | -3,083196 | 0,837796 | 6,583819 | -5,728622 |

