

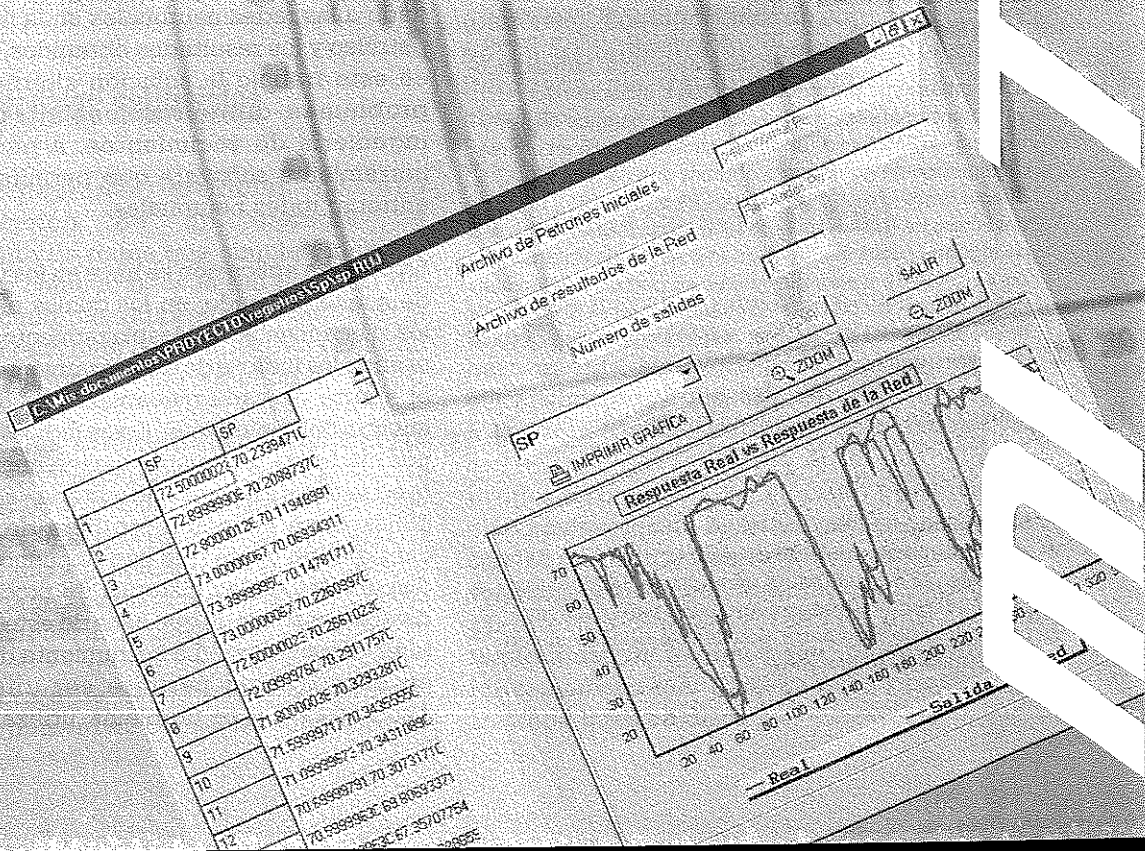
MIGUEL FERNANDO PÉREZ IZQUIERDO *
 MIKE ALBERTO ROZO ANAYA *
 ROBERT ULLOA JIMÉNEZ *
 FERNANDO ENRIQUE CALVETE **
 ZULY CALDERÓN CARRILLO ***


APLICACIÓN DE LAS REDES NEURONALES AL ESTUDIO DE YACIMIENTOS DE PETRÓLEO

*Ingeniero de Petróleos, Escuela de Ingeniería de Petróleos,
 Universidad Industrial de Santander

** Ingeniero de Petróleos, EGOPEIAD, Casabe.
 E-mail: fernando.calvete@ecopetrol.com.co

*** PhD, Escuela de Ingeniería de petróleo, Universidad Industrial de
 Santander, e-mail: calderon@uis.edu.co






Miguel Fernando Pérez Izquierdo

Resumen

En este trabajo se presenta el desarrollo de una herramienta *software* (GERENE), para generar y entrenar redes neuronales, con el fin de aplicarla a la solución de algunos problemas comunes encontrados en la industria del petróleo. Esta herramienta se desarrolló teniendo en cuenta que en ingeniería se presentan

problemas de gran complejidad, los cuales requieren de un manejo matemático dispendioso y que en muchos casos no se obtienen los mejores resultados usando los métodos tradicionales. Además se ha demostrado, algunas veces, que la aplicación de nuevas tecnologías permite optimizar los procesos industriales.



Mike Alberto Roza Anaya

La herramienta desarrollada GERENE fue utilizada en dos aplicaciones de la ingeniería de yacimientos. En la primera aplicación se utilizó la herramienta como una solución alternativa al cálculo del comportamiento de los índices de desplazamiento (índice de desplazamiento por depleción - IDD; índice de desplazamiento por segregación - IDS; e índice de desplazamiento hidrostático-

IDH), cuando no se tienen los datos suficientes del yacimiento para aplicar la ecuación de balance de materia - EBM. La segunda aplicación se hizo en el área de registros de pozos, para obtener una correlación directa entre el registro de Rayos Gamma (GR) y la curva del Potencial Espontáneo (SP), cuando las condiciones de algunos pozos son tales que no se puede obtener la curva del SP (por ejemplo cuando se perfora con fluidos no conductivos o con aire), o cuando la curva SP no ofrece resultados definitivos, casos en los cuales se corre una curva de Rayos Gamma.

Este trabajo también presenta la metodología utilizada para realizar las aplicaciones descritas anteriormente.

Los resultados obtenidos en las dos aplicaciones, utilizando la herramienta desarrollada en este trabajo, muestran la capacidad de aprendizaje, la robustez y la flexibilidad de las redes neuronales para resolver problemas de ingeniería, difíciles de solucionar con las técnicas tradicionales.

Introducción

Teniendo en cuenta que las redes neuronales han mostrado ser una alternativa eficiente en la solución de problemas donde es necesario correlacionar parámetros, la industria de los hidrocarburos las ha utilizado en diferentes áreas.

En 1994, Ali J. K, presentó un panorama general de las aplicaciones directas de las redes neuronales a la industria del petróleo. Posteriormente, Mohaghegh en 1995, hace un recuento de las aplicaciones de las redes neuronales, basado en la capacidad que tienen para resolver problemas, combinadas con herramientas convencionales, tales como el análisis estadístico. En un estudio posterior Toomarian y colaboradores (1999), profundizaron en la utilización de las redes neuronales en el campo de la caracterización de propiedades del yacimiento, elaborando algoritmos para analizar los registros eléctricos de pozos, para estimar con mayor exactitud las propiedades de los fluidos y la columna estratigráfica de los pozos.

Teniendo en cuenta las aplicaciones que se han dado a las redes neuronales en la industria del petróleo y los resultados obtenidos, se propone en este trabajo la solución alternativa a dos problemas diferentes encontrados en la ingeniería de yacimientos, a partir de una herramienta *software* que permite generar y entrenar redes neuronales.

La primera aplicación se hace en los yacimientos de aceite saturado, en los cuales el estudio de los mecanismos de desplazamientos se realiza usando los índices de desplazamiento que miden el aporte de cada mecanismo de empuje a la energía del yacimiento. Estos índices se calculan por medio de una manipulación matemática de la ecuación de balance de materia - EBM (Pirson, 1958). Esta ecuación requiere de una gran cantidad de datos que con frecuencia no están disponibles en las historias de producción, por diversas razones, lo que hace de este cálculo una tarea dispendiosa. La herramienta desarrollada en este trabajo permite ser una solución alternativa a este problema utilizando menor

número de variables que las utilizadas en la ecuación de balance de materiales.

Por otro lado, la segunda aplicación se utilizó con registros eléctricos, teniendo en cuenta que algunos campos colombianos presentan inconvenientes para determinar topes de arena, debido a que el tipo de lodo utilizado en los pozos no permite correr el registro de potencial espontáneo - SP y algunos pozos cuentan solamente con el registro Gamma Ray - GR. La herramienta desarrollada en este trabajo presenta una solución alternativa para encontrar la curva del registro SP a partir del registro GR. Esto permite calcular posteriormente topes de arena, espesores y otras características del yacimiento.

Como se podrá ver a lo largo del artículo, los resultados obtenidos en las dos aplicaciones demuestran que el *software* desarrollado se convierte en una herramienta alternativa viable, que permite dar solución a algunos de los problemas que a menudo se presentan en la ingeniería de yacimientos por falta de datos, lo cual no permite utilizar los métodos tradicionales de cálculo.

Redes neuronales artificiales

Una red neuronal artificial es una implementación de un sistema de procesamiento de datos que simula funciones elementales, como lo hace la red nerviosa del cerebro humano, siendo capaz de identificar la información relevante sobre una gran cantidad de datos, (Del Brio M. y Sanz Molina, 1998).

Una red neuronal artificial está conformada por diferentes capas: la capa de entrada, encargada de recibir la información del exterior; la capa oculta (intermedia, que puede ser una o más de una), la cual procesa la información, y la capa de salida, que proporciona el resultado del trabajo de la red neuronal artificial al exterior (figura 1).

La arquitectura de la red neuronal artificial describe el número de capas, las funciones de




Figura 1.
Estructura jerárquica de un Sistema Neuronal Artificial

transferencia en cada una de las capas, (transferencia de información de una neurona a otra), el número de neuronas por capa y las conexiones entre ellas (Hilera y Martínez, 2000).

El entrenamiento de una red neuronal se define como el proceso por el cual se produce un ajuste de los parámetros internos de la red (capas ocultas y sus pesos), a partir de un proceso de estimulación con los datos del problema (patrones). Los algoritmos de entrenamiento se basan usualmente en métodos numéricos iterativos que tratan de minimizar el error absoluto.

Herramienta software (GERENE)

Como se mencionó anteriormente, en este trabajo se presenta el desarrollo de una herramienta *software* para la elaboración, entrenamiento y aplicación de redes neuronales a la industria del petróleo. La herramienta *software* fue desarrollada en el lenguaje de programación C++, el cual permitió la elaboración de una interfase gráfica, amigable con el usuario y fácil de interactuar. Este *software* puede ser instalado en cualquier plataforma Windows (95, 98 o NT). Sus requerimientos mínimos son: procesador 100 MHz, memoria ram 16 mega bites y espacio de 25 Mega bites en disco.

El algoritmo utilizado en el desarrollo de la herramienta fue el *Back-propagation* (Eberthart y Dobbins, 2000), que consiste en un aprendizaje de un conjunto de entradas y salidas dados como ejemplo, empleando un ciclo de propagación-adaptación del error generado, de la diferencia entre la respuesta calculada por la red y la respuesta real. Este proceso se repite hasta alcanzar un error aceptable entre las respuestas.

La figura 2 muestra el procedimiento general para la elaboración y entrenamiento de una red neuronal utilizando la herramienta GERENE.

Para corroborar la validez de la herramienta desarrollada, se realizó una prueba utilizando el ejemplo de la literatura planteado por Prent y Sanchez (1997), en el cual se determina el tipo de crudo (aceite negro, aceite volátil y gas condensado), a partir de datos de producción y de laboratorio (GOR, API, %C7+). Para resolver este ejemplo los autores utilizaron el software NETDEMO (The Math Works Inc.), perteneciente al TOOL BOX de MATLAB Versión 4.2.

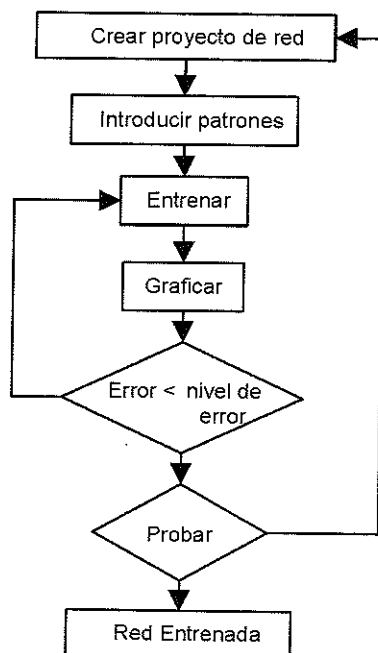


Figura 2.
herramienta
software GERENE

En la tabla 1 se presentan los resultados obtenidos por Prent-Sánchez y los obtenidos por la herramienta GERENE desarrollada en ese trabajo. Al comparar estos resultados con el real, se observa que la herramienta GERENE presenta un error aproximado de 0.4052817, significativamente menor al error de 1.5166283 que presenta la herramienta Matlab.

Aplicación de la herramienta

Como se mencionó anteriormente, la herramienta propuesta, se utilizó como alternativa de solución a dos problemas frecuentes en ingeniería de yacimientos: comportamiento de índices de desplazamiento y registro de pozos para el cálculo de topes de formación.

1) Índices de desplazamiento (IDD, IDS y IDH)

La ecuación general de balance de materiales puede ser utilizada para determinar los diferentes mecanismos de empuje. Esto se hace con el fin de encontrar las magnitudes relativas a las diferentes formas de energía de un yacimiento que produce bajo una combinación de mecanismos de empuje.

Pirson en 1958 manipuló la ecuación de balance de materiales para yacimientos de aceite obteniendo como resultado la siguiente ecuación:

$$IDD + IDS + IDH = 1.0$$

EC.1

Donde:

IDD = Índice de desplazamiento por depleción
IDS = Índice de desplazamiento por segregación (capa de gas).

IDH = Índice de desplazamiento por empuje hidráulico.

Las ecuaciones que representan estos índices son:

$$IDD = \frac{N(B_t - B_n)}{N_p [B_t + (R_p - R_n)B_g]}$$

EC.2

Nótese que la ecuación (1) asume que en un tiempo cualquiera, la suma de los índices de empuje debe ser igual a 1, ya que estos representan la fracción de actividad de cada uno de los empujes en cuestión. Sin embargo, estos índices usualmente varían durante la vida productiva del yacimiento.

$$IDS = \frac{\frac{Nm.B_n}{B_g} (B_g - B_{gl})}{N_p [B_t + (R_p - R_n)B_g]}$$

EC.3

$$IDH = \frac{(W_g - B_w W_p)}{N_p [B_t + (R_p - R_n)B_g]}$$

EC.4

Tabla 1. Validación de la herramienta GERENE

Dato	GOR	API	%C7+	TIPO DE FLUIDO*	RED ORIGINAL (Matlab)	% ERROR MATLAB	RED DE VALIDACIÓN (GERENE)	% ERROR RED GERENE
1	23877	52.5	2.3	2	2.008485	0,424250	1.979950	1,002500
2	1484	41.9	13.9	3	3.022957	0,765233	2.981160	0,628000
3	10	13.7	61.2	1	1.001020	0,102000	1.000009	0,000900
4	1562	41.0	16.3	3	3.006189	0,206300	2.994055	0,198167
5	1247	42.4	14.5	3	3.017509	0,583633	2.989420	0,352667
6	481	32.2	31.9	1	0.992810	0,719000	1.006320	0,632000
7	10043	52.0	5.2	2	2.006254	0,312700	2.004368	0,218400
8	1010	32.0	24.2	3	2.675665	10,811167	2.999351	0,021633
9	48569	49.1	1.5	2	2.006670	0,333500	1.980029	0,998550
10	232	37.3	35.4	1	0.990915	0,908500	1.000000	0,000000
Total % Error						1.5166283		0.4052817

* 1 aceite negro, 2 gas condensado, 3 aceite volátil

Con el fin de aplicar la ecuación de balance de materiales - EBM, en el cálculo de los índices de empuje, se utilizó un ejemplo de la literatura (Smith, 1990) que tiene todos los datos necesarios (N_p , G_p , W_p , R_s , P , B_g , B_t). El obtener resultados exactos con la EBM, permite hacer una comparación con los resultados obtenidos con la herramienta GERENE.

Como el fin de aplicar la herramienta desarrollada en este trabajo, en el cálculo de los índices de empuje, es demostrar que una red neuronal puede servir como solución alternativa cuando no se dispone de todos los datos necesarios para aplicar la EBM, se plantearon 2 redes neuronales: la Red A y la Red B, las cuales relacionan los parámetros del yacimiento con los índices de desplazamiento. La arquitectura de las dos redes se muestra en la Tabla 2.

Tabla 2. Arquitectura de las Redes A y B.

Características de Arquitectura	Red A	Red B
Neuronas de entrada	7	4
Neuronas ocultas	3	5
Neuronas de salida	3	3
Número de patrones	68	68
Factor de Momentum	0.075	0.075
Tasa de aprendizaje	0.15	0.05
Número máximo de iteraciones	15000	10000
Error cuadrático	< 1%	< 0.5%

Como se ilustra en la tabla, para la Red A, se utilizaron 7 neuronas de entrada que corresponden a N_p , G_p , W_p , R_s , P , B_g , B_t y 3 neuronas de salida, que corresponden a cada uno de los índices.

La metodología utilizada para aplicar la herramienta a los dos casos propuestos, fue la siguiente:

- 1) Se hizo el cálculo exacto de la EBM.
- 2) Se entrenó una red neuronal (red A, tabla 2) con el 80% de los datos disponibles.
- 3) Se probó la eficiencia de la red con el 20% de los datos disponibles restantes.
- 4) Y finalmente, se compararon los resultados obtenidos con EBM y con GERENE.

Los resultados de los índices obtenidos por la EBM y por la herramienta, se ilustran en la figura 3. Esta figura muestra que los resultados de la herramienta GERENE son muy similares a los resultados obtenidos con la EBM.

Teniendo en cuenta que muchas veces no se cuenta con los datos necesarios para aplicar la EBM, se propone una Red B utilizando menor número de variables de entrada que las utilizadas en la Red A, para obtener los índices de empuje del yacimiento en estudio. El objetivo de la Red B es mostrar la eficiencia de la red para calcular los índices de empuje cuando no se tiene toda la información necesaria para utilizar la EBM. Los valores que permiten comparar la eficiencia de la Red B, son los datos reales EBM y los obtenidos con la Red A.

Las entradas escogidas para la nueva red (Red B) son N_p , G_p , W_p y R_s . Las características de esta red se muestran en la tabla 2. Por otro lado, la tabla 3 muestra algunos valores utilizados para el entrenamiento de las redes A y B.

Tabla 3. Datos utilizados para calcular EBM, Red A y Red B (Smith, 1990).

Tiempo	Meses	20	70	120
N_p	MMstb	2.9670	7.0210	10.1020
G_p	MMMscf	2.1056	7.0425	12.0485
W_p	MMcf	0.3363	1.8786	3.5187
R_s	scf/stb	501.6	417	361
P	Psia	1972	1708	1536
B_g	cf/scf	0.00704	0.00812	0.00909
B_t	cf/stb	7.6329	8.1885	8.7107

En la figura 4 se comparan los resultados obtenidos con la EBM y con la Red B. Como ilustra la figura, los resultados de IDD, IDS e IDH, para los dos casos, son muy similares. Osea que el ajuste de la nueva red (Red B) es prácticamente igual al alcanzado con la EBM.

Los resultados obtenidos demuestran que las redes neuronales tienen capacidad para establecer relaciones entre variables sin importar la complejidad de estas, sin introducir relaciones matemáticas ni ecuaciones. Por esto las redes neuronales se convierten en una herramienta de gran potencial en la solución de problemas de la industria petrolera.

2) Registros de pozos

Para la identificación de topes de formación y su posterior correlación dentro de un campo, es necesario tener el mismo registro en cada uno de los pozos de dicho campo, ya sea el Gamma Ray (GR) o la curva del potencial espontáneo (SP), acompañado de un estudio de por lo menos un núcleo de cualquiera de los pozos a correlacionar.




Figura 3. Indices de empuje calculados con la EBM y con la Red A

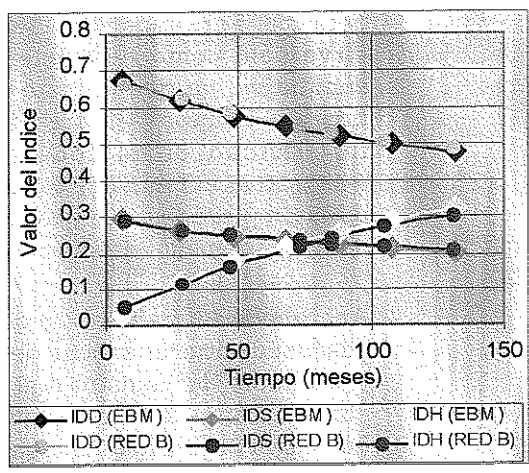


Figura 4. Resultados obtenidos con la EBM y con la Red B

Gamma Ray (GR), por lo que, no es posible correlacionar el pozo corazonado con el resto de pozos del campo. Además, correr registros Gamma Ray en la mayoría de pozos tendría un inconveniente económico por el alto costo que esto representa.

Como solución a este problema se propone hallar una relación directa entre el registro Gamma Ray (GR) y la curva de potencial espontáneo (SP), ya que en la literatura no se encontró ninguna referencia acerca

de la relación entre estos dos registros. A pesar de esto se puede intuir que la relación numérica entre estos registros debe existir, ya que las propiedades de los componentes de la formación y su respuesta a los impulsos de las herramientas de registros, poseen formas similares y se usan para determinar la litología dentro del pozo.

En un campo Colombiano se pretendió hacer la correlación de los topes de formación con base en un núcleo extraído de un pozo perforado con lodo base aceite. Debido al tipo de lodo no fue posible correr el registro de potencial espontáneo (SP) y en su defecto se corrió el registro de Gamma Ray (GR).

Como respuesta al problema expuesto, se recurrió a la capacidad de las redes neuronales

El problema radica en que la mayoría de los pozos del campo poseen la curva de potencial espontáneo (SP) pero no tienen el registro

Como respuesta al problema expuesto, se recurrió a la capacidad de las redes neuronales

para hallar una relación existente entre el registro Gamma Ray (GR) y la curva del potencial espontáneo (SP) para el campo en particular, lo cual conduce a crear una nueva red (Red C) con una neurona de entrada (GR) y una neurona de salida (SP). De esta manera la red se encargará de generar una curva de potencial espontáneo (SP artificial) a partir de un registro Gamma Ray (GR).

Para alimentar la red neuronal fue necesario obtener datos de pozos que tuviesen los registros de GR y SP (figura 5). Se utilizaron los registros de dos pozos cercanos al pozo corazonado; del primero se extrajeron los datos necesarios para entrenar la red neuronal (pozo de entrenamiento) y con el segundo se probó la red (pozo de prueba). La cercanía de los pozos garantiza que la respuesta de la red frente a los datos del pozo corazonado será la mejor.

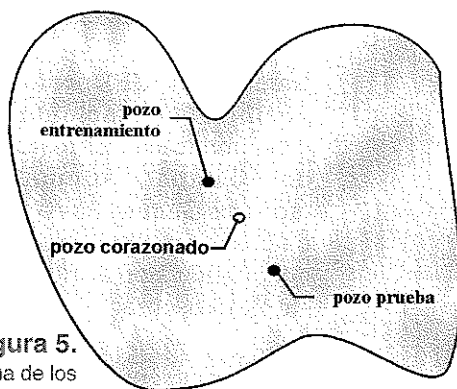


Figura 5. Esquema de los pozos del campo.

Las características de la red neuronal entrenada (red C) se presentan en la tabla 5.

Neuronas de entrada	1
Neuronas ocultas	4
Neuronas de salida	1
Número de patrones	340
Factor de Momentum	0.85
Tasa de aprendizaje	0.0075
Número máximo de iteraciones	15000
Error cuadrático	< 1%

Los valores de factor de *momentum* y tasa de aprendizaje presentados anteriormente se obtuvieron por prueba y error hasta alcanzar el error cuadrático mostrado. La escogencia de 4 neuronas en la capa oculta no fue al azar, ya que se entrenaron otros proyectos de red con mayor o menor número de neuronas ocultas, pero con resultados más deficientes.

Luego del entrenamiento de la red se alcanzó un error cuadrático menor al 1%, el cual se considera satisfactorio para alcanzar el objetivo propuesto inicialmente. La red se entrenó con diferentes factores de *momentum* y tasas de aprendizaje hasta alcanzar este nivel de error.

La figura 6 ilustra la respuesta de la red entrenada (Red C) y los datos reales del SP para un intervalo del pozo de prueba, donde se aprecia que esta red constituye una herramienta eficaz a la hora de evaluar los topes de una formación, generando una curva de potencial espontáneo (SP). Cabe anotar que la curva del potencial espontáneo (SP) generado por la red sirve solo como instrumento de carácter cualitativo; ya que en este ejemplo no será posible calcular el SSP (SP estático), la resistividad de la zona lavada (R_{mf}), la resistividad del agua de formación (R_w), entre otras propiedades que pueden ser calculadas de valores tomados del registro SP convencional.

Analizando la grafica 6 se observa un ajuste adecuado entre las salidas de la red entrenada y los datos del registro real para el pozo de entrenamiento. Esto indica que la red generará una curva SP adecuada para el objetivo que se persigue: la identificación de topes y espesores de formación.

Luego del análisis de resultados se prosiguió a probar la red con todos los datos del registro Gamma Ray del pozo de prueba, el cual consta de un total de 2860 datos, obteniéndose la respuesta deseada por parte de la red (SP artificial).

Por otro lado, la figura 7 presenta las curvas con los datos del pozo de prueba. Se muestra la

curva SP real y la curva SP obtenida con la red neuronal. Estas curvas ilustran sólo un intervalo de 500 pies de los datos del pozo de prueba, mostrando una diferencia entre los datos extremos (picos) del SP generado y el SP real, la

cual es producto de la generalización de la red al momento de ajustar los datos de entrenamiento. También se puede observar que el SP generado por la Red C identifica mejor las intercalaciones de arcillas y arenas.




Figura 6. Curva del registro SP (real) vs. registro SP (artificial)

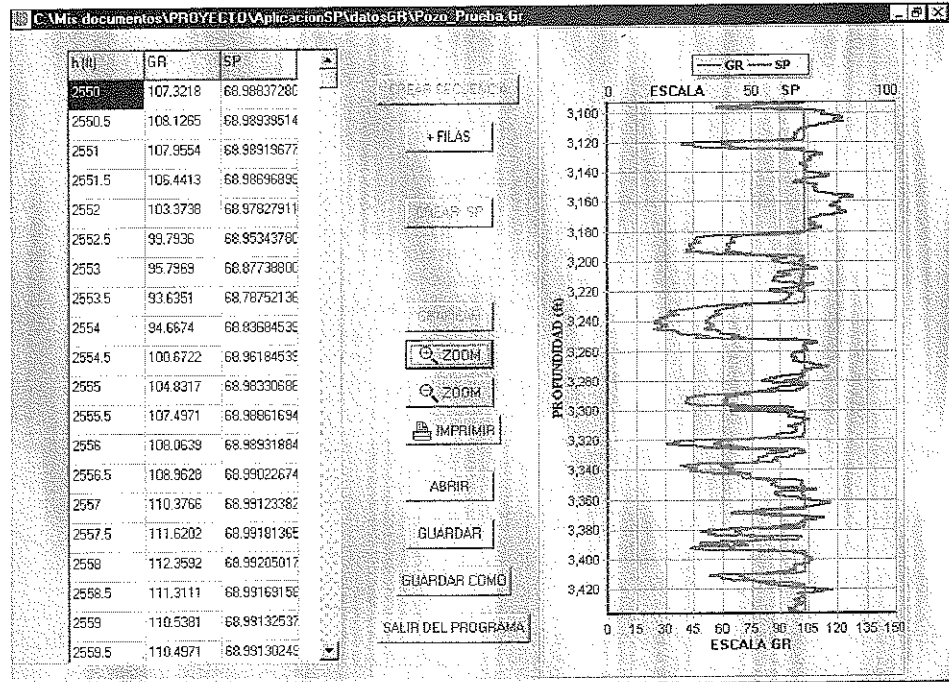


Figura 7. Resultados de la aplicación de registros.

CONCLUSIONES

1. Se desarrolló una herramienta *software* (GERENE) para la elaboración y entrenamiento de redes neuronales, con el algoritmo de retropropagación, la cual se aplicó para resolver problemas comunes de la industria del petróleo.
2. El *software* desarrollado se aplicó para calcular los índices de desplazamiento IDD, IDS e IDH, utilizando menor número de variables que las utilizadas por la EBM. Los resultados obtenidos muestran ser confiables.
3. Se elaboró una aplicación que genera un registro SP artificial a partir de un registro de rayos gamma, cuando no es posible obtener topes de formación con los datos existentes. Este nuevo registro SP fue útil en la identificación de topes de formación; sin embargo su utilidad es mucho mas amplia para hacer otros cálculos indispensables en el análisis de los yacimientos de hidrocarburos.
4. Con la herramienta de conversión de registro se comprobó una vez más, la capacidad de las redes neuronales para relacionar parámetros en los cuales no existe una relación matemática preestablecida.
5. La herramienta desarrollada puede ser aplicada en campos viejos donde no se

- disponga de la información necesaria para usar los métodos tradicionales de cálculo.
6. Con el fin de ampliar la capacidad de la herramienta desarrollada, se recomienda implementar otros algoritmos (Kohonen, Hopfield, etc), diferentes al algoritmo de retropropagación.

Nomenclatura

- N_p = producción acumulativa de aceite, MMSTB.
 N = aceite inicial in situ, MMSTB.
 B_t = factor volumétrico de formación total, cf/STB
 R_p = relación acumulativa gas/aceite producidos, (G_p/N_p) , scf/STB.
 R_s = relación gas en solución / aceite, scf/STB
 B_g = factor volumétrico de formación del gas, cf/scf.
 W_e = flujo de agua acumulativo del acuífero hacia el yacimiento, cf.
 W_p = agua producida acumulativa, STB.
 B_w = factor volumétrico de formación del agua, bbl/STB.
 i = subíndice indicando condiciones iniciales.
 m = volumen inicial de gas libre/vol. inicial de petróleo.
 G_p = producción acumulativa de gas, MMM.

Referencias

- Ali J.K. "Neural Networks: A New Tool for the Petroleum Industry?". SPE 27561. 1994.
- Del Brío B. Martín y Sanz Molina A. "Redes Neuronales y Sistemas Borrosos". Ra-Ma Textos Universitarios. Madrid. España, 1998.
- Eberthart Russell y Dobbins Roy. "Neural Network PC Tools". Academia Press, 1990.
- Hileria J. y Martínez V. Redes Neuronales Artificiales, Fundamentos, Modelos y Aplicaciones. Alfa omega. 2000.
- Mohaghegh S. "Neural Network: What It Can do for Petroleum Engineers". SPE 29219. JPT(Enero/95).
- Mohaghegh S. and Ameri S. "Artificial Neural Network as a Valuable Tool for Petroleum Engineers". SPE 29220, 1995.
- Pirson Sylvain "Elements Of Oil Reservoir Engineering". 2nd Ed. McGraw Hill Book Company, 1958.
- Prent Larry y Sánchez Sigifredo "Predicción del tipo de fluido de un yacimiento basado en datos PVT y de producción usando redes neuronales". Universidad Industrial de Santander. Escuela de Petróleos, Bucaramanga, 1997.
- Smith, Charles. 1990. "Applied Reservoir Engineering". Volúmenes 1 y 2.
- Toomarian, N., B, Barhen, J., Glove. C.W and Aminzadeh. "Oil Reservoir Properties Estimation Using Neural Networks". JPL Report. NASA Research Press. 1999.

Autores:

MIGUEL FERNANDO PÉREZ IZQUIERDO, Ingeniero de Petróleos
MIKE ALBERTO ROZO ANAYA, Ingeniero de Petróleos
ROBERT ULLOA JIMÉNEZ, Ingeniero de Petróleos

El artículo presentado corresponde a la tesis de grado de los autores para optar el título de Ingenieros de Petróleos de la Universidad Industrial de Santander, UIS. Bucaramanga, Colombia.