

SISTEMA INTELIGENTE AYUDA A INCREMENTAR LA PRODUCCION Y RESERVAS RECUPERABLES EN CAMPOS VIEJOS DE COLOMBIA

Rodolfo Soto B. (Ecopetrol-ICP), Aristóbulo Bejarano (Ecopetrol-ICP), Heberth Ferneynes (Ecopetrol-GCO), Juan Fdo. Ardila (Ecopetrol-GCO), Stephen Holditch (Texas A&M University), Ching Wu (Texas A&M University)

RESUMEN

La innovación se debe dar principalmente en el focus del negocio de Ecopetrol, el cual está relacionado con el hallazgo y la producción de petróleo y gas. Teniendo en cuenta esta premisa, se ha desarrollado un sistema inteligente, "*Oilfield Intelligence (OI)*", como una herramienta de ingeniería para mejorar la caracterización de yacimientos de aceite y gas. *OI* integra redes neuronales, análisis de componentes principales, técnicas de escalamiento y generalización, y un módulo de experticia. Más de 1,200 líneas de programación en Matlab, Fortran 90 y VisualBasic permiten al ingeniero de yacimientos y de campo predecir comportamientos del yacimiento con un alto grado de certeza.

En esta investigación, se han desarrollado los siguientes modelos utilizando el sistema Oilfield Intelligence:

1- Un modelo multivariable en redes neuronales para predecir la permeabilidad de la zona "C" del campo Yariguí-Cantagallo. Este campo es relativamente maduro con información insuficiente, geología compleja y gran variación de la permeabilidad desde 0.1 a 150 md. Durante el pre-procesamiento de la información (control de calidad y determinación de las variables principales) se encontró que la porosidad y el registro gamma-ray son los factores dominantes en la predicción de la permeabilidad. Los valores de coeficiente de correlación y error absoluto son 0.979 y 7.8% respectivamente, comparados con 0.596 y 69.5% por el método convencional de regresión lineal en una gráfica semilogarítmica. El modelo desarrollado se usó para seleccionar las zonas potencialmente petrolíferas con buena permeabilidad. Basados en este soporte, se realizaron trabajos de cañoneo de arenas adicionales en los pozos YR3, YR12, YR17, YR39, YR43, YR65 y YR69. La producción incremental debido a estos trabajos ha alcanzado un promedio de 240 barriles de petróleo por día desde mediados del año 1996, con una producción acumulada de 415,178 barriles de petróleo equivalentes a 6.2 millones de dólares a Junio de 1999.

2- Un modelo multivariable en redes neuronales para predecir las unidades de flujo de la formación Caballos, campo Toldado. La formación está dominada por arenas con porosidad primaria intragranular y secundaria debida a disolución de calcita y dolomita que actúan como elementos de cementación de la roca. Durante el pre-procesamiento de la información (control de calidad y determinación de las variables principales) se encontró que la porosidad, densidad de la roca, el registro sísmico y el registro neutrón son los factores dominantes en la predicción de las unidades de flujo y de la permeabilidad para esta formación. Se determinaron tres unidades de flujo o tipo de roca en este yacimiento y el modelo desarrollado presenta un coeficiente de correlación de 0.925 y un error absoluto de 7.9% comparado con 0.54 de coeficiente de correlación y 79.84% de error absoluto del modelo desarrollado por Davis K. Davis & Associates¹ quien usó conceptos de geometría poral para determinar unidades de flujo y predecir la permeabilidad para esta formación. Los resultados y el tiempo récord utilizando el sistema inteligente durante el modelamiento permiten a Ecopetrol ahorros significativos en la obtención de cada modelo del orden de \$30,000 dólares. Además, se espera que la aplicación del modelo en las operaciones de campo en los próximos meses sea un soporte en las metas de producción incremental que tiene Ecopetrol para este yacimiento.

3- Se utilizaron los atributos de la sísmica 3D para desarrollar un modelo multivariado en redes neuronales con el fin predecir el registro gamma ray en áreas potenciales para las zonas C-4 y C-5 del campo VLE 196, bloque V del Lago de Maracaibo. El coeficiente de correlación del modelo desarrollado utilizando *OI* es de 0.94 con un error absoluto del 11%. Esto abre una ventana de posibilidades de aplicar la sísmica 3D en la predicción de propiedades petrofísicas en áreas prospectivas. También se desarrolló para este mismo campo un modelo multivariado en redes neuronales para la permeabilidad de las zonas C-4 y C-5. El coeficiente de correlación es de 0.985 y el error absoluto es del 8% comparado con coeficientes de correlación que varían entre 0.53 y 0.82 y errores absolutos entre 37 y 97% obtenidos en estudios de yacimientos realizados durante la historia de producción de este campo.

4- Modelos multivariados en redes neuronales para predecir los recobros primarios, de inyección de agua y de reducción de espaciamento mediante la perforación de pozos adicionales en las formaciones de carbonato de San Andrés y Clearfork en el Oeste de Texas. Los coeficientes de correlación son del orden del 99% con errores absolutos no mayores del 3% comparados con coeficientes de correlación de

0.91 y errores absolutos alrededor del 27% obtenidos y publicados internacionalmente en los últimos 15 años.

INTRODUCCIÓN

La gran mayoría de los modelos del mundo real no son lineales. Las ecuaciones que caracterizan los yacimientos de petróleo y gas no son la excepción. Los yacimientos son sistemas complejos estratificados y no es posible obtener información en cada punto del yacimiento. Durante el modelamiento el ingeniero puede utilizar información de corazones y pruebas de pozos con el fin de obtener resultados aceptables. Sin embargo, la obtención de corazones de cada uno de los pozos durante su perforación es muy costosa y en la práctica lo que se hace es obtener corazones en algunos de los pozos que no representan la heterogeneidad del yacimiento en su totalidad. Un atractivo método para determinar propiedades del yacimiento es obtenerlas a partir de registros de pozos los cuales tienen la ventaja de una detallada descripción de la formación en la dirección vertical. Sin embargo a partir de registros la descripción del yacimiento entre pozos es muy pobre debido a que su radio de investigación en sentido horizontal es de algunas pulgadas. A través de la sísmica 3D es posible obtener un buen cubrimiento areal de las formaciones pero su resolución vertical es muy pobre debido a las grandes longitudes de onda provenientes de las señales acústicas.

Otro de los problemas que necesita ser resuelto durante el modelamiento es la dimensionalidad. ¿Cuántas y cuáles variables deberían usarse en la obtención de cada modelo?. La determinación de los parámetros o variables dominantes y el número óptimo de variables independientes para predecir una variable dependiente no es tarea fácil. En algunas ocasiones no es posible obtener todos los datos de campo debido a los costos. En otros casos, es redundante el número de variables independientes. En ese caso, el modelo representa porciones irrelevantes del espacio multidimensional y el modelo se comportará relativamente mal. Aún si el algoritmo es capaz de representar porciones importantes de ese espacio o mundo real, el uso de un mayor número de variables de entrada, requerirá una mayor cantidad de datos. La experiencia muestra que se podría reducir la severidad del problema si se usan técnicas de estadística multivariada (componentes principales, análisis de factores), de escalamiento y un poco de experiencia sobre el comportamiento físico del modelo.

De lo anterior se puede inferir que calcular reservas de aceite y gas, predecir el recobro primario y secundario, determinar donde perforar y estimar las tasas de producción a partir de propiedades del yacimiento tienen alto riesgo, y es una de las razones del fracaso en la exploración y en los bajos recobros de aceite y gas de los yacimientos. Con el fin de reducir el riesgo y soportado por la revolucionaria tecnología de las computadoras y del software, la industria del petróleo en sus últimos años ha invertido casi todos sus presupuestos de investigación en el desarrollo de modelos sofisticados no-lineales que caractericen mejor los yacimientos con el objetivo de incrementar la producción y las reservas de petróleo y gas. Sin embargo, se requerirá investigación adicional para aplicar nuevas tecnologías y metodologías para obtener mejores modelos que permitan predecir con exactitud las propiedades del yacimiento. De acuerdo con los resultados de una reciente encuesta llevada a cabo por la National Petroleum Council² a 89 compañías, la industria del petróleo y gas requerirán desarrollar aplicaciones que permitan escalar la información para una mejor caracterización de los yacimientos, y la necesidad de estas tecnologías continuaran por un período largo (2000 a 2010).

Una de esas tecnologías tendrá que ver con el desarrollo de herramientas inteligentes (redes neuronales, lógica difusa y análisis multivariado) que puedan resolver ese rompecabezas. Las redes neuronales han mostrado la habilidad sobre otras tecnologías para extraer patrones, estructuras y relaciones entre los datos que la colocan como una de las tecnologías emergentes en los últimos años de acuerdo con el monitoreo que realiza la SRI International^{*3}. También se cree que el siglo 21 será la edad de las máquinas inteligentes y que las redes neuronales llegarán a ser una parte integral de la vida diaria.

REDES NEURONALES

Exactamente como trabaja el cerebro humano es todavía un misterio. Sin embargo se conocen algunos aspectos de este procesador maravilloso. En particular, el elemento básico del cerebro humano es la neurona, que a diferencia de las otras células del cuerpo humano, no se regenera. Estas células del cerebro tienen la habilidad para recordar, pensar y aplicar experiencias previas. Todas las neuronas tienen los mismos tres componentes básicos. Estos componentes son conocidos por sus nombres biológicos como dendritas, soma y axón (Figura 1). Aunque las neuronas por si mismas son extremadamente simples y procesadores lentos, cuando se combinan en una red, podrán ser más rápidos aún que cualquiera de nuestros más avanzados supercomputadores. Las neuronas reciben

señales del exterior o de otras neuronas a través de las dendritas. Entonces, la neurona procesa la señal en su cuerpo, el soma, y envía la señal procesada desde su axón a otras neuronas. Este proceso es conocido como sinapsis⁴ (Figura 2).

La unidad básica de las redes neuronales artificiales es la neurona y a través de ella se simula las cuatro funciones básicas de las neuronas naturales. Una representación de una neurona artificial⁵ se muestra en la Figura 3. En las redes neuronales artificiales nosotros reemplazamos las neuronas por una sumatoria y una transformación non-líneal (una de las más usadas es la función sigmoideal). La salida de esa función se envía como señal de entrada a otras neuronas simulando la sinapsis.

Dos o más neuronas se pueden combinar para formar una capa, y una red neuronal podría contener una o más capas. Todas las variables independientes o de entrada forman la capa de entrada y las variables dependientes o de salida la capa de salida. Entre estas dos capas, una red neuronal puede contener varias capas de neuronas las cuales se conocen como capas ocultas. La Figura 4 presenta una red neuronal con una capa oculta.⁵ En esta red, cada elemento del vector de entrada x es conectado a cada neurona en la capa oculta a través de los pesos W . El efecto neto de las neuronas de entrada, n , sobre cada neurona de la capa oculta es representado de la siguiente forma:

$$n = \sum (W_{S,R} \cdot X_R + b_S) \quad (1)$$

Esta sumatoria es el argumento de la función de transferencia. El resultado de la función de transferencia es la salida o el resultado del proceso efectuado por la neurona en la capa oculta:

$$a = \tanh^{-1} \left(\sum W_{S,R} \cdot X_R + b_S \right) \quad (2)$$

De esta manera, la estructura la estructura de una red neuronal con tres capas ocultas estará representada por la siguiente ecuación:

$$a = \{ \sum W_{4,3} \cdot \tanh^{-1} \left(\sum W_{3,2} \cdot \tanh^{-1} \left(\sum W_{2,1} \cdot \tanh^{-1} \left(\sum W_{1,1} \cdot x + b_1 \right) + b_2 \right) + b_3 \right) + b_4 \} \quad (3)$$

Se debe notar que W y b son los parámetros a ajustar en el proceso de aprendizaje de la neurona. La idea central de las redes neuronales es los pesos, W , y los términos de tendencia, b , sean ajustados para alcanzar un comportamiento deseado. Para ello se pueden utilizar uno de los siguientes algoritmos de optimización: método de Newton, el gradiente o gradiente conjugado. El comportamiento del aprendizaje es uno de los más importantes pasos en el proceso de aprendizaje. Para ello se utiliza un *índice de comportamiento* que mide el error global de la red neuronal. El error global de una red neuronal se define así:

$$E = \sum_p \sum_k (y_{pk}^{real} - y_{pk}^{estimated}) \quad (4)$$

Donde la sumatoria interna tiene en cuenta todas las neuronas en la capa de salida y la sumatoria externa todo el conjunto de datos usados en el entrenamiento.

El algoritmo más popular para el entrenamiento de las redes neuronales es el de propagación hacia atrás (backpropagation).^{6,7} El algoritmo reconoce y reproduce patrones en un proceso iterativo mientras que sus pesos, W , y los términos de tendencia, b , son ajustados para minimizar el error. El proceso se inicia con unos pesos seleccionados al azar y luego se realizan los siguientes cálculos: (1) se evalúa la salida de la red neuronal (paso hacia delante), (2) se calcula el error y se compara con un error objetivo y (3) los pesos y los términos de tendencia son ajustados de acuerdo con el error que es propagado hacia atrás. Estos pasos se repiten hasta cuando el criterio de error es alcanzado.

SISTEMA INTELIGENTE

El sistema inteligente desarrollado en esta investigación es llamado *Oilfield Intelligence (OI)*. Más de 1,200 líneas de programación en MATLAB constituyen el sistema inteligente. OI está compuesto de cinco módulos: (1) un módulo de entrada de datos, (2) un módulo de pre_procesamiento de la data, (3) un módulo de diseño de la arquitectura de la red neuronal, (4) un módulo gráfico y (5) un módulo de inferencia que contiene los algoritmos de optimización. La Figura 5 muestra la arquitectura de OI y la Figura 6 muestra la interface gráfica del usuario con cada uno de los módulos.

METODOLOGÍA

En general la metodología que nosotros aplicamos a todos los casos ha sido la siguiente:

1. Revisión bibliográfica: se evalúan los estudios de yacimientos, análisis de corazones y registros de pozos, historia de producción del campo y de los pozos, análisis de pruebas de presión, estudio de comportamiento pozos y análisis de candidatos a cañoneo o estimulación, etc.
2. Control de calidad de la información: se utiliza el concepto de distribución normal para cada una de las variables y por pares de variables junto con elipses de 95% de confianza para determinar la calidad de los datos.
3. Determinación de variables de dominantes: el concepto de componentes principales y análisis de factores es utilizado por el sistema inteligente con el fin de utilizar las variables estrictamente necesarias que explican el comportamiento real de la variable dependiente.
4. Diseño y entrenamiento de la red neuronal: utilizando las variables dominantes independientes y la variable dependiente se simulan diferentes arquitecturas para la red neuronal usando durante el proceso de aprendizaje con el fin de optimizar el modelo.
5. Evaluación y comparación del modelo en redes neuronales: se utilizan los conceptos de coeficiente de correlación, error global absoluto y gráfica de residuos para determinar la validez del modelo y para compararlo con otros modelos desarrollados por otros métodos.
6. Escalamiento del modelo al yacimiento: se utilizan los conceptos geoestadísticos de kriging y cokriging para aplicar los modelos en redes neuronales con el fin de realizar la simulación de yacimientos.
7. Recomendación de trabajo de pozos: basado en los modelos desarrollados y una evaluación de otras variables como comportamiento de los pozos, ubicación del pozo en el yacimiento, etc.. se recomienda el trabajo a realizar con el fin de incrementar la producción y las reservas recuperables

CAMPO YARIGUÍ-CANTAGALLO: CARACTERÍSTICAS DEL YACIMIENTO

El campo Yariguí-Cantagallo está localizado en el Magdalena medio en Colombia a 30 kilómetros del norte del campo Casabe. Geológicamente está limitado por la falla Cantagallo y por la falla Caño Patico al sureste. Existen una serie de fallas que dividen el campo en 5 bloques. El quinto bloque es el más importante por su extensión y producción. El pozo Cantagallo-2 fue el descubridor del campo en 1942, con una producción inicial de 286 barriles de aceite por día. La gravedad API del aceite fue de 20.1⁰. En este campo la gran mayoría de los pozos han sido desviados. Las arenas productoras corresponden a la formación La Paz, del terciario superior. Dos ambientes deposicionales han sido caracterizados de acuerdo con las propiedades eléctricas de la roca, denominadas "Arenas Cantagallo" y "Arenas C". Las "Arenas Cantagallo" corresponden al principal horizonte productor del campo.

Desde 1942 a 1960, cuando el campo Yariguí fue desarrollado, se encontró un problema de evaluación de las zonas productoras. Resultados inesperados fueron obtenidos durante pruebas de formación, agua en cambio de aceite y las incertidumbre sobre las arenas productoras se hizo grande.⁸ El primer esfuerzo para mejorar el entendimiento del yacimiento se hizo con un programa de corazonamiento en los pozos Yariguí-13 y Yariguí-14. Después del estudio de corazones, se usaron junto a los análisis de corazones los registros de pozos para abrir a producción zonas potencialmente petrolíferas. Sin embargo, las arenas de zona "C" no fueron abiertas a producción debido al cuestionamiento sobre arenamiento, baja permeabilidad y altos valores de saturación de agua. En el año de 1996, Ecopetrol desarrolló un programa para incrementar la producción en el campo. Conociendo las dificultades para identificar con claridad las zonas alta y baja permeabilidad, se utilizó la metodología descrita anteriormente para predecir la permeabilidad con alto grado de certeza.

DESARROLLO Y VALIDACIÓN DEL SISTEMA INTELIGENTE

La topología de la red neuronal para predecir la permeabilidad de la zona "C" del campo Yariguí-Cantagallo está compuesta de dos capas ocultas, con 15 neuronas en cada una de ellas. Dos neuronas en la capa de entrada (gamma ray y porosidad del registro neutrón) y una neurona (permeabilidad) en la capa de salida. El coeficiente de correlación fue 0.9655 y un error absoluto de 2.34% (Figura 7) ⁹ comparado con un coeficiente de correlación de 0.694 y un error absoluto de 83.2% usando regresión lineal (Figura 8).

Los pozos Yariguí-17 y Yariguí-69 fueron los dos primeros pozos en una serie de éxitos que llevamos a cabo. Nosotros usamos el modelo en redes neuronales y los registros de pozos con el fin de identificar las arenas a ser cañoneadas. La Figura 9 ilustra uno de los buenos ejemplos de cómo el modelo ayudó a nuestras recomendaciones en el pozo Yariguí-69. La permeabilidad predicha por la red fue de 6 md. para el intervalo 7688'-7692'. Como se puede observar en esta Figura, esta zona es de baja permeabilidad en el tope de acuerdo con la lectura de gamma ray. También, pudiera decirse que hacia el tope, la arena es apretada debido a su valor alto de resistividad y no a saturación de hidrocarburos. Hacia la base del intervalo, la lectura de gamma ray es mejor pero la resistividad tiene un valor bajo indicando zona de agua. Aunque este intervalo fue inicialmente seleccionado a cañoneo, fue descartado teniendo en cuenta los valores de permeabilidad (Tabla 1). Otras zonas en el mismo pozo fueron recomendadas a cañoneo (ver Figura 10 y Tabla 2). La producción en este pozo después de las recomendaciones incrementó en 150 barriles por día. Se llevó a cabo una prueba de presión y después del análisis se encontró que la permeabilidad fue de 60 md. Lo cual concuerda con la predicción del modelo en redes neuronales para la permeabilidad (Tabla 3). La Tabla 4 muestra la producción acumulada a Junio de 1999 en cada uno de los pozos donde se realizó trabajo de cañoneo en arenas "C" basado en el análisis de registros y en los valores de permeabilidad predicho por modelo en redes neuronales.

APLICACIÓN DEL SISTEMA INTELIGENTE A OTROS YACIMIENTOS

El sistema inteligente se viene aplicando con éxito en otros yacimientos con el fin de obtener mejores modelos que permitan una mejor caracterización y explotación de los mismos. A continuación se presenta un resumen de los resultados donde se ha usado el sistema Oilfield Intelligence:

1. Modelo de Permeabilidad para la Formación Caballos, Campo Toldado: Las Figuras 11 y 12 muestran una comparación entre la permeabilidad calculada y medida según el modelo de regresión y el método de Davis & Davis. Este último utiliza conceptos de geometría poral para determinar unidades de flujo o tipos de toca y a partir de estos construye modelos de permeabilidad. Los coeficientes de correlación son 0.4656 y 0.5336, y los errores absolutos son 2176 y 79% respectivamente. La Figura 13 muestra una gráfica de residuos del modelo de Davis & Davis y de la cual se puede inferir que el modelo no trabaja en casi todo el rango de permeabilidades por su tendencia de desviación alrededor de cero. Basados en esta evaluación, se procedió aplicar la nueva metodología desarrollada con el sistema inteligente con el fin de mejorar el modelo de permeabilidad. Nosotros usamos el sistema inteligente para realizar control de calidad de la información, determinar las variables dominantes en el modelo de permeabilidad y desarrollamos un modelo en redes neuronales con dos capas ocultas de 10 y 8 neuronas en cada una de ellas. Se determinó que las variables dominantes provenientes de los registros fueron el *PEF*, *NPHI*, *RHOB*, y la porosidad efectiva calculada de registros o de corazones. El modelo final presenta un coeficiente de correlación de 0.925 y un error absoluto de 7.9% (ver Figura 14). La Figura 15 muestra una gráfica de residuos donde se puede observar que el modelo funciona en todo el rango de valores de permeabilidad para la formación Caballos del campo Toldado. Teniendo en cuenta los resultados del modelo, se aplicó en todas las zonas de interés para cada uno de los pozos y luego se utilizaron conceptos geostadísticos de kriging y cokriging con el fin de escalar el modelo a todo el yacimiento y así utilizarlo en la simulación de yacimientos (Figura 16).
2. Modelo para Predecir el Registro Gamma Ray Usando Atributos Sísmicos y de Permeabilidad a Partir de Registros de Pozos, Campo VLE 196, Bloque V, Lago de Maracaibo: El objetivo en esta parte de nuestra investigación fue mostrar la potencia del sistema OI en la caracterización de yacimientos por medio de desarrollar correlaciones entre los atributos sísmicos y los registros de pozos. Estas correlaciones pueden ser usadas para interpolar propiedades en el área de control de pozos o para extrapolar los modelos con el fin de predecir las propiedades del yacimiento donde solamente existan datos sísmicos. El campo VLE 196 Lamar está localizado en la parte sur-central del Lago de Maracaibo, Venezuela. Desde que el campo fue descubierto en 1958, se han producido aproximadamente 200 millones de barriles de los 550 a 600 millones de barriles del aceite

original in-situ a través de los 50 pozos completados en las arenas C-4 y C-5 de la formación Misoa. Nosotros usamos atributos sísmicos 3D (amplitud, fase, frecuencia, tensión de reflexión y cuadratura), profundidad y localización de los pozos como variables de entrada y el registro gamma ray como variable de salida con el fin de obtener un modelo sintético del registro gamma ray. El número de datos usados durante el entrenamiento, prueba y validación fueron aproximadamente de 11,800, los cuales cubrieron del área piloto desde el sur (pozo VLE 1140) al norte (pozo VLE 987) y desde el oeste (pozo VLE 449) al este (pozos VLE 571 y VLE 987). El proceso de aprendizaje fue terminado una vez se logró un error absoluto razonable (12.65%). El coeficiente de correlación en este caso fue de 0.8615. La Figura 17 compara el registro gamma ray real contra la predicción del modelo para un pozo usado en el entrenamiento y otro usado como prueba del modelo. Nosotros podemos ver en esas figuras como el modelo predice bastante bien el registro gamma ray. También, desarrollamos un modelo de permeabilidad a partir de datos de corazones y registros de pozos usando el sistema inteligente. Alrededor de 200 pruebas de laboratorio con corazones del pozo VLE 1063 fueron utilizadas en este caso. La Tabla 5 muestra un resumen de los resultados de los diferentes modelos de permeabilidad.

3. Desarrollo de Modelos de Recobro Mediante Reducción de Espaciamento para Yacimientos de Carbonato en el Oeste de Texas: Finalmente, nosotros usamos datos de los yacimientos de carbonato de San Andres y Clearfork del Oeste de Texas usando el sistema OI para obtener modelos que permitan predecir el recobro último primario ,*PRUR*, el recobro último al iniciar la inyección de agua, *IWUR*, y el recobro de aceite último al reducir espaciamento mediante la perforación "infill", *IDUR*. La Tabla 6 muestra un resumen comparativo de los resultados entre los diferentes modelos. El error absoluto promedio de nuestros modelos es menor del 3% comparado con el 25% de los otros modelos y los coeficientes de correlación son muy cercanos a 1.

CONCLUSIONES

Una revisión de los resultados obtenidos durante esta investigación nos permite resaltar las siguientes conclusiones:

1. Se ha desarrollado un sistema inteligente, Oilfield Intelligence, que ayudará al ingeniero obtener una mejor descripción de los yacimientos. Se han integrado los conceptos de estadística multivariada, control de calidad y redes neuronales a través de una interface amigable con el usuario que le permite ser usada fácilmente.
2. La aplicación de esta tecnología en el campo Yariguí-Cantagallo le ha representado a Ecopetrol una producción acumulada de 415,478 de barriles equivalente a 6.2 millones de dólares. La predicción del modelo concuerda con los resultados de campo.
3. Los modelos desarrollados usando Oilfield Intelligence de permeabilidad para la formación Caballos del Campo Toldado (Colombia), de permeabilidad y registro gamma ray a partir de atributos sísmicos para las zonas C-4 y C-5 del campo VLE 196, Bloque V en el Lago de Maracaibo (Venezuela), y de recobro para las unidades de San Andres y Clearfork en el Oeste de Texas (USA) muestran que son superiores comparados con los modelos desarrollados con otras metodologías reconocidas en la literatura.
4. Esta innovación tecnológica ubica a Ecopetrol en el liderazgo mundial en esta área del conocimiento que redundará en una mejor explotación de sus yacimientos.

NOMENCLATURE

API = gravedad del aceite a condiciones de tanque, °API
IDUR = recobro último de aceite debido a reducción de espaciamento o perforación "infill"
NPHI = registro neutrón de porosidad, fracción
PEF = registro fotoeléctrico de la formación
PRUR = recobro último de aceite debido a recobro primario
RHOB = registro de densidad de matriz, g/cc
IWUR = recobro último al inicial la inyección de agua

REFERENCES

1. *Petrophysical Analysis, Caballos Formation, Toldado Field, Colombia: Repor*, Davis K. Davis & Associates, Inc., January 1999.
2. Moritis, G.: "Study Ranks Oil, Gas Industry Technology Needs," Oil & gas Journal, (October, 1995) 93, No. 44, 31-33.
3. "Inventing the Future Through Technology Innovation", SRI International, 1998
4. Anderson, D. and McNeill, G.: "Artificial Neural Network Technology," report, Griffiss, AFB, NY, (1985).
5. Soto Becerra, Rodolfo: "Reservoir Characterization Using Core, Well Log, and Seismic Data and Intelligent Software," Dissertation, Texas A&M, College Station, Texas (1998).
6. Werbos, P.: "Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences," Ph.D. dissertation, Harvard U., Cambridge, MA (1974).
7. Rumelhart, D.E., Hinton, G.E., and Williams, R.J.: "Learning Internal Representations by Back-Propagation Errors," *Nature* (1986) **323**, 533-536.
8. Van swa Gosad, R. M. And de Ruiter, W. J.: " A Study Petrophysical Data from Yariguí, Colombia," Report, The Hague, Casabe, Colombia, January 1959.
9. Soto B, Rodolfo, J. F., Ardila, H. Ferneynes, and A. Bejarano:"Use of neural Networks to Predict the Permeability and Porosity of Zone "C" of the Cantagallo Field in Colombia," SPE 38134, Petroleum Computer Conference, Dallas, Texas, 8-11 June 1997.
10. Garcia Herrera, I.: "Different Methodologies for Obtaining a Permeability Distribution in the Misoa Formation," Ms Thesis, Texas A&M U., College Station, TX (1998).
11. Wu, C.H., Lu, G.F., Gillespie, W., and Yen, J.: " Statistical and Fuzzy Infill Drilling Models for Carbonate Reservoirs," paper SPE 37728 presented at the 1997 SPE Middle East Oil Show & Conference, Bahrain, 15-18 March.

Tabla 1. – Predicción de la Permeabilidad en el Intervalo 7688´-7692´ del Pozo Yariguí-69.

Profundidad	GR	ILD	SP	PHIE	Permeabilidad
ft	UAPI	Ohm-m	mv.	fraction	NN, md.
7688	55.29	6.46	-54.25	0.174	4.22
7688.5	55.30	7.09	-63.89	0.1737	6.24
7689	55.07	7.92	-73.53	0.1729	5.42
7689.5	54.14	8.70	-79.71	0.1753	2.33
7690	52.92	9.12	-81.87	0.1773	2.78
7690.5	52.50	9.21	-84.84	0.1688	2.49
7691	53.30	8.77	-87.17	0.1533	1.69
7691.5	55.56	8.31	-89.03	0.1326	0.48

Tabla 2. – Predicción de la Permeabilidad en el Intervalo 7882´-7907´ del Pozo Yariguí-69.

Prof.	GR	ILD	SP	PHIE	K
ft	UAPI	Ohm-m	mv.	fraction	NN, md.
7883	47.47	10.47	-67.3	0.1791	50.5
7883.5	46.29	11.39	-75.2	0.1885	58.57
7884	46.77	11.93	-79.1	0.1878	59.38
7884.5	47.94	12.37	-83.0	0.1814	52.02
7885	48.42	12.65	-85.2	0.1764	59.89
7885.5	48.65	12.87	-87.0	0.1744	62.92
7886	49.13	13.00	-88.3	0.1734	62.82
7886.5	49.35	13.07	-89.4	0.1753	60.09
7887	50.75	13.16	-89.6	0.1707	59.82
7887.5	52.43	13.31	-90.1	0.1645	24.88
7889	51.30	13.41	-89.8	0.1691	35.71
7889.5	51.03	13.15	-89.2	0.1735	62.13
7890	51.74	12.63	-87.5	0.1705	59.33
7890.5	53.38	11.87	-85.1	0.1577	60.32
7891	55.73	11.11	-81.7	0.1322	30.66
7894	50.33	9.46	-74.0	0.1653	9.69
7894.5	44.49	9.59	-74.6	0.195	1.70
7895	42.14	9.69	-74.5	0.2047	6.93
7896	46.96	9.81	-70.7	0.1722	11.88
7896.5	52.37	9.68	-67.0	0.1456	15.15
7897	56.86	9.46	-58.7	0.1121	2.8

Tabla 3. – Resultados en la Pruebas de Producción para el Intervalo 7882´-7907´ en el Pozo Yariguí-69.

Presión del Yacimiento	2685 psi
Producción	120 BOPD
Relación Gas-Aceite	300 pc/bbl
Factor Volumétrico	1.145 bbl/bbl
Viscosidad del aceite a cond. yac.	4.2 cp.
Gravedad API	20.3
Permeabilidad	60 md.

Tabla 4. –Producción Acumulada a Junio de 1999 debido a Trabajos de Cañoneo Adicional.

Yariguí -13	20498
Yariguí -39	23708
Yariguí -65	40437
Yariguí -43	20578
Yariguí -45	66519
Yariguí -17	99456
Yariguí -69	144582
TOTAL ACUMULADO, bbls	415,178
Dolares equivalente	6.2 Millones




Tabla 5. – Resumen Comparativo de los Resultados de los Modelos de Permeabilidad para el Campo VLE 196, Lago de Maracaibo, Venezuela

Method	Independent Variables	Correlation Coefficient between Measured and Predicted Permeability	Average Absolute Error %
Standard Regression ¹⁰	Porosity and Flow Units	0.8523	62.4
Nonparametric & GRACE Program ¹⁰	Porosity and Flow Units	0.9295	38.1
Berg Modified ¹⁰	Porosity and Flow Units	0.8384	97.78
Neural Networks	Porosity and Flow Units	0.9501	27.92
Nonparametric & GRACE Program	Porosity and Gamma Ray	0.8627	62.33
Neural Networks	Porosity and Gamma Ray	0.9756	18.03

Tabla 6. – Resumen Comparativo de los Resultados de los Modelos de Recobro para los Yacimientos de San Andres y Clearfork, Oeste de Texas

Method	Parameter	Independent Variables	Correlation Coefficient between Measured and Predicted Parameter	Average Absolute Error %
Standard Regression ¹¹	PRUR _{San Andres}	Area, Porosity, Sw, h _{net} , NOPW, Viscosity	0.9226	24.49
Standard Regression ¹¹	PRUR _{Clearfork}	Area, Porosity, Sw, h, Depth, Permeability, FVF, Viscosity	0.9472	21.51
Standard Regression ¹¹	IWUR _{San Andres}	PRUR, WSW, Sw	0.9056	34.17
Standard Regression ¹¹	IWUR _{Clearfork}	PRUR, NOWW, Depth, Permeability, h _{gross} , h _{net}	0.9682	17.01
Standard Regression ¹¹	IDUR _{San Andres}	IWUR, NOIW, Depth, Gross	0.9649	21.20
Standard Regression ¹¹	IDUR _{Clearfork}	IWUR, NOIW,	0.9221	26.30
Neural Network	PRUR _{San Andres and Clearfork}	Basin, Area, Porosity, Sw, FVF, API gravity,	0.999	1.0

Neural Network	IWUR _{San} Andres and Clearfork	Basin, Area, h_{net} , Porosity, Sw, API, Viscosity, FVF, NOWW, PRUR	0.998	2.1
Neural Network	IDUR _{San} Andre and Clearfork	Basin, Area, h_{net} , porosity, Sw, API, Viscosity, FVF, NOIW, IWUR	0.999	3.3

Fig. 1.- SimpleNeurona (McLaren et al⁴)Fig. 2. – Comunicación entre Neuronas (McLaren et al⁴)Figura 3. – Representación de una Neurona Artificial⁵




Figura 4. – Arquitectura de una Red Neuronal con una Capa Oculta⁵




Figura 5. – Arquitectura del Sistema Oilfield Intelligence⁵




Figura 6. – Interface gráfica con el Usuario del Sistema Oilfield Intelligence⁵




Figura 7. – Log Permeabilidad vs. Porosidad de Corazones⁹




Figura 8. – Permeabilidad de la Red Neuronal vs. Porosidad de Corazones⁹




Figura 9. – Registros para el Intervalo 7688'-7692' del Pozo Yariquí-69




Figura 10. – Registros para el Intervalo 7882' -7907' del Pozo Yariquí-69




Figura 11. – Permeabilidad vs. Porosidad de Corazones, Campo Toldado




Figura 12. – Modelo Permeabilidad, Formación Caballos, Campo Toldado Según Davis & Davis




Figura 13. – Gráfica de Residuos para el Modelo Permeabilidad, Formación Caballos, Campo Toldado Según Davis & Davis




Figura 14. – Permeabilidad del Sistema Inteligente vs. Permeabilidad Real, Formación Caballos, Campo Toldado




Figura 15. – Gráfica de Residuos Modelo Sistema Inteligente, Formación Caballos, Campo Toldado




Figura 16. – Escalamiento del Modelo Sisema Inteligente Usando Geoestadística, Formación Caballos, Campo Toldado




Figura 17. – Comparación Registro Gamma Real y de la Red Neuronal para el Pozo 1063 Campo VLE 196, Lago de Maracaibo, Venezuela