

El Boletín para Nuestra Comunicación

INTRODUCCIÓN

Iniciamos nuestra comunicación con Uds. mostrando en el Boletín N°1 cómo la mejor Definición y Caracterización de los reservorios por Estadística Integral Autocorrelada^{MR} (EIA) sostiene la optimización del Desarrollo y Explotación de Yacimientos.

En los siguientes Boletines, y en base a Modelos Estáticos “bien” logrados, como arriba referimos, les acercamos fundamentos y realizaciones de la Simulación Dinámica en Líneas de Flujo (SLF). Mostramos casos aplicando Simulación Conceptual y Simulación de Detalle por Líneas de Flujo. Pudimos, con esta combinación de “buenos” Modelos Estáticos y Dinámicos mostrar cómo se pudo optimizar el Diseño de algunos Proyectos de Recuperación Primaria y particularmente Secundaria.

Volvemos en este Boletín a la Caracterización de los reservorios, con la generación de un Modelo 3D de permeabilidad absoluta que refleja las heterogeneidades, a escala de reservorio y minimiza las incertidumbre,

reconociendo la importancia de esta variable en el proceso productivo de los Yacimientos.

Este Boletín se corresponde con el trabajo “Modelo de Permeabilidades de Reservorio utilizando Redes Neuronales Artificiales e Integración Geoestadística” que presentamos en el VI Congreso de Exploración y Desarrollo de Hidrocarburos. Por cuestiones de brevedad se expone ahora la Metodología y el Desarrollo del Modelo Permeabilidades, mientras que en el Boletín N°8 se completa con los Resultados, Conclusiones y Recomendaciones del Trabajo.

Como en nuestros Boletines anteriores, los invitamos a enviarnos sus comentarios y/o propuestas o requerimos mayor información que la presentada.

De interesarles disponer los Boletines anteriores podrán encontrarlos en nuestra Página Web. Al pie del Boletín encontrarán la dirección de la Página y también otras formas de comunicarse con nosotros.

Finalizamos este Boletín, como siempre, con la Sección Novedades. ▶

MODELO DE PERMEABILIDADES DE RESERVORIO UTILIZANDO REDES NEURONALES ARTIFICIALES E INTEGRACIÓN GEOESTADÍSTICA (1° PARTE)

INTRODUCCION

Permeabilidad: Objetivo Central

Un óptimo manejo del reservorio sólo puede lograrse luego de obtener una imagen detallada y cercana a la realidad de las distribuciones espaciales de las propiedades de la roca. Entre ellas, la permeabilidad desempeña un rol crucial, constituyendo la variable de mayor influencia en el flujo de fluidos en medios porosos (Balan 1995).

La permeabilidad es una función compleja de varios factores interrelacionados tales como la porosidad, la litología, la composición del fluido poral y los procesos post-depositacionales, (Fig. 1). Esta información es desconocida en la mayoría de los casos, por lo que suele buscarse algún vínculo matemático con los registros de pozos convencionales. Sin embargo, la relación entre la lectura de perfiles y la permeabilidad es más complicada que en el caso de la porosidad, y por lo tanto se requieren medidas físicas adicionales para representar su valor (Bhatt 1999, 2001). La mayoría de los modelos empíricos conocidos, se basan fundamentalmente en la porosidad, incluyendo en algunas ocasiones la saturación irreductible de agua, lo que deriva en modelos poco flexibles y que carecen de la capacidad de reflejar el flujo de fluidos en medios porosos. En la Fig. 1 se muestran algunas de las estimaciones de k usadas frecuentemente.

La utilización de Redes Neuronales Artificiales (ANN), como se demuestra en este estudio, constituye un nueva línea de trabajo, que excede la capacidad de predicción de los métodos convencionales. La ventaja de esta técnica es que no requiere que todos los parámetros y las relaciones entre ellos sean especificadas explícitamente.

$$k = a \phi^b \xi^c$$

Función de:

- Superficie interna
- Tortuosidad del circuito poral
- Geometría de la garganta poral

Timur	$k = \frac{C \phi_e^{4.4}}{Sw_{irr}^2}$
Kenyon	$k = a \phi^4 T_m^2$ T _m : Tiempo promedio de Relajación NMR
Canady	$k = \frac{\phi^a}{C} (ST_{att})^b$ ST _{att} : Atenuación de la Amplitud de la onda Stoneley

Fig. 1 - La Permeabilidad y sus Estimaciones

Las Redes "aprenden" a resolver problemas a través de ejemplos y resultan especialmente adecuadas para procesos subjetivos e interpretativos que los humanos pueden llevar a cabo fácilmente pero que no pueden describirse en términos de algoritmos o set de ecuaciones (Mohaghegh 1995). También tienen en cuenta la no linealidad en la distribución de la permeabilidad, ya que son independientes de cualquier forma de función. En contraste con los métodos de regresión lineal, las ANN, tampoco fuerzan la predicción a caer cerca de los valores medios, y por lo tanto permiten preservar la variabilidad real de los datos (Bhatt 1999).

En síntesis la principal ventaja de las ANN radica en la habilidad que poseen para aprender de la experiencia y generalizar dicho aprendizaje a la resolución de nuevos problemas, sin exponerse a una solución predeterminada, como la mayoría de los métodos clásicos (Mohaghegh 1995).

Caso Histórico: Breve Descripción del Yacimiento

Se aplicará la metodología aquí desarrollada para la estimación del Modelo de Permeabilidades del Yacimiento Anticlinal Campamento, ubicado en la Provincia de Neuquén, entre las ciudades de Cutral-Co y Zapala. Anticlinal Campamento inició su producción primaria en 1954 y a fines de 1983 se comenzó el desarrollo de un proyecto piloto de Recuperación Secundaria por Inyección de Agua.

La estructura en la que se encuentra el yacimiento es un anticlinal elongado E-W atravesado por fallas de rumbo aproximado N-S, que lo dividen en tres bloques: Oriental, Central y Occidental. En este trabajo se analizaron los reservorios de la Formación Lotena en el Bloque Oriental.

METODOLOGIA

Fundamentos Básicos y Arquitectura de una Red Neuronal

En el presente trabajo se utilizó una Red Neuronal de Retro-Propagación Multicapa (Back-Propagational Artificial Neural Network, Software utilizado: LESA – Módulo Esteem de Digital Formation). Esta herramienta simula el proceso cognitivo del cerebro y es de mucha utilidad para resolver aquellos problemas que no pueden ser solucionados por los métodos numéricos convencionales. Las ANN, funcionan como sistemas dinámicos no lineales que aprenden a reconocer patrones a través del entrenamiento.

La red tiene dos componentes principales: Nodos o Neuronas y conexiones (nexos ponderados entre las neuronas). Luego de la exposición de las muestras al entrenamiento, las neuronas computan los valores de activación y los transmiten unas a otras, de una forma que depende del algoritmo de aprendizaje que se use.

El proceso de aprendizaje de las BP-ANN, consiste en transmitir hacia delante en la red los valores de entrada y entonces calcular la diferencia entre el Output predicho y el Output deseado (Fig. 2). Esta información de error es propagada hacia atrás con el fin de modificar los pesos de los

links entre capas ocultas. Después de un cierto número de iteraciones, el entrenamiento finaliza logrando la mejor aproximación entre los valores predichos y los deseados (Bhatt 1999, 2001).

El entrenamiento de una ANN estará condicionado, más allá de los datos de entrada utilizados, por 3 parámetros intrínsecos: el número de redes en comité, el número de iteraciones y la cantidad de neuronas en las capas ocultas. La óptima elección de estos parámetros condicionará los tiempos y la bondad de los entrenamientos. No existe modelo matemático que describa la red entrenada, ésta sólo puede definirse por su topología (número de capas y cantidad de neuronas en cada capa) que determinan el número de interconexiones y la fuerza de esas interconexiones.

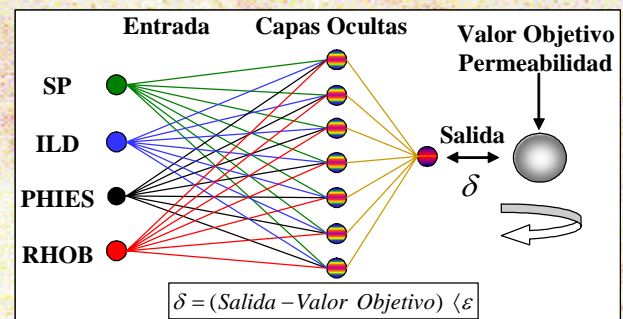


Fig. 2 - Perfiles de Permeabilidad por Redes Neuronales de Retro-Propagación Multicapa

Procedimientos Geoestadísticos

En el proceso de caracterización del reservorio previamente mencionado, interesa fundamentalmente inferir la naturaleza de la distribución de propiedades entre pozos con el suficiente nivel de detalle como para efectuar predicciones posteriores (Jensen J.L. et al. 2000).

En presencia de información limitada, cualquier descripción del reservorio involucra la aplicación de estadística. Definimos la geoestadística en un sentido amplio como una técnica que permite tener en cuenta las relaciones espaciales entre variables en el proceso de estimación en locaciones no muestreadas. Estas variables incluyen propiedades petrofísicas convencionales (permeabilidad y porosidad), información sísmica (valores de impedancias) o variables geológicas como arenas - arcillas (Kelkar M. et al. 2002). En un estudio geoestadístico tradicional primero se validan y normalizan los datos a utilizar y se buscan correlaciones entre variables estáticas y dinámicas para obtener criterios de corte que permitan definir y caracterizar los límites de los reservorios (Galacho M. et al. 2003). El rango de autocorrelación de los datos se analiza mediante el cálculo de semivariogramas /covarianzas que luego son suministrados al algoritmo de interpolación - extrapolación que se utilice (kriging, cokriging, simulación, etc).

En este estudio se aplicaron los algoritmos de Kriging Ordinario (K.O.). Esta técnica utiliza un procedimiento de

estimación lineal para predecir un valor en una locación no muestreada. El valor estimado resulta un promedio ponderado de los valores vecinos y los pesos dependerán de la relación espacial entre la locación no muestreada y los valores vecinos, así como también de la relación entre datos vecinos (Kelkar M. et al. 2002). La bondad de los modelos generados podrá evaluarse mediante técnicas de validación cruzada.




Fig. 3 - Entrenamiento Inicial de Permeabilidad con Perfiles SP, ILD, DT, RHOB y NPHI

DESARROLLO

Se presenta el desarrollo metodológico en el Caso Histórico.

Elección de Parámetros y Análisis de Sensibilidad

De los 39 pozos perforados en el Yacimiento Anticlinal Campamento, sólo 2 de ellos tienen información de corona disponible y una suite completa de perfiles (NPHI, DT, RHOB, SP, GR, Resistivos) mientras que 11 pozos disponen registros SP, Resistivos y Sónico. Los 25 restantes carecen de perfiles de porosidad.

En base a la información disponible, se efectuaron análisis de sensibilidad con el fin de seleccionar los parámetros de entrada de mayor influencia en la estimación de la permeabilidad.

Inicialmente se entrenó una red ideal, la cuál contaba con la suite completa de perfiles como parámetros de entrada. El objetivo fue exponer la ANN ante las mejores condiciones posibles para verificar su poder de predicción. El excelente ajuste obtenido (Fig. 3) alentó el entrenamiento con un set más restringido de datos, acorde con la información disponible.

Se efectuaron correlaciones entre los distintos parámetros disponibles y se evaluaron varios casos de entrenamiento empleando combinaciones de datos. Finalmente se concluyó que el set más adecuado debía estar conformado por perfiles SP, ILD y Porosidad Efectiva interpretada del Perfil Sónico.

También se variaron los parámetros intrínsecos de las ANN, como fue aumentar el número de iteraciones y cantidad de neuronas en la Capa Oculta, para mejorar el Ajuste (Fig. 4)

Tareas Desarrolladas

En los 11 pozos con registro sónico disponible se calcularon las porosidades efectivas mediante análisis petrofísicos de perfiles y validación con las porosidades medidas en los pozos con corona.




Fig. 4- Análisis de Sensibilidad variando los Parámetros Intrínsecos de la Red

En aquellos pozos carentes de perfiles de porosidad, se estimó esta variable utilizando las ANN. Los análisis multivariados en los pozos que disponían del set completo de perfiles arrojaron como resultado una buena correlación entre los perfiles ISP e ILD con el perfil de porosidad calculado. Se entrenó entonces una red neuronal con los perfiles ISP, ILD, PHIE de los 11 pozos mencionados, lográndose un ajuste muy bueno entre el perfil predicho y la porosidad efectiva calculada (Fig. 5). Estos resultados fueron validados con la porosidad de corona del pozo NAC 1001 (Fig. 6).




Fig. 5- Resultados del Entrenamiento de Porosidad

Este entrenamiento fue aplicado al resto de los pozos logrando así disponer de un perfil de porosidad efectiva en la totalidad de los mismos.

Una vez obtenida la porosidad efectiva se procedió a entrenar una red neuronal que lograra reflejar en sus predicciones la heterogeneidad en la permeabilidad presente a escala de reservorio.

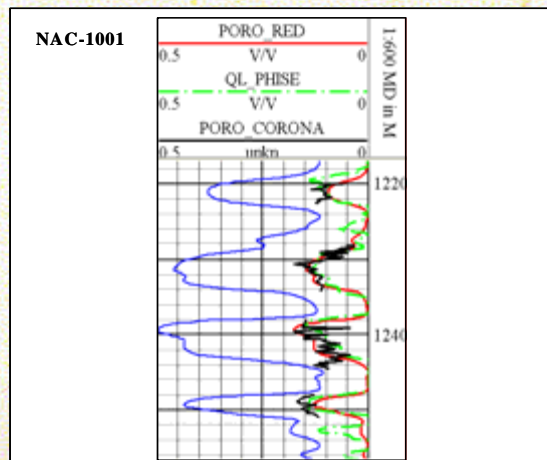


Fig. 6- Aplicación del Entrenamiento y Validación con la Porosidad de Corona

La Red Neuronal, que fue entrenada en los dos pozos con corona disponible, utilizó 3 neuronas en la capa de entrada: registros de pozo SPN, ILD y Porosidad Efectiva Sónica; 15 y 8 neuronas repartidas en dos capas ocultas y 1 neurona en la capa de salida: la permeabilidad absoluta en condiciones de NOBP. Los parámetros básicos seleccionados según los análisis de sensibilidad fueron: 30 sistemas expertos en paralelo y 500 iteraciones.

Es importante aclarar que el entrenamiento se efectuó seleccionando aquellos tramos de corona que tuvieran una respuesta coherente y acorde a las relaciones generales entre perfiles observadas en las arenas del yacimiento. El entrenamiento obtenido fue aplicado al resto de los pozos para lograr perfiles de permeabilidad sintéticos.

NOVEDADES

Deseamos comentarles que el software **ESTEEM**, utilizado en la realización de este trabajo es un módulo del programa **LESA de Digital Formation, Inc.** ESTEEM es una poderosa herramienta para generar y validar datos a partir de información confiable mediante el uso de redes neuronales de manera fácil y rápida.

Se selecciona una serie de curvas de entrada de uno o más pozos para predecir los valores de otras curvas simuladas o sintéticas. Luego se entrena la red con pozos que tengan la información a reproducir, en este trabajo fue la Permeabilidad de coronas, después estos resultados pueden

A continuación se realizaron los análisis variográficos que representan las tendencias de distribución areal y vertical de la permeabilidad (Fig. 7), y se aplicó la técnica de Kriging Ordinario respetando estas tendencias para obtener un modelo tridimensional y continuo de las permeabilidades.

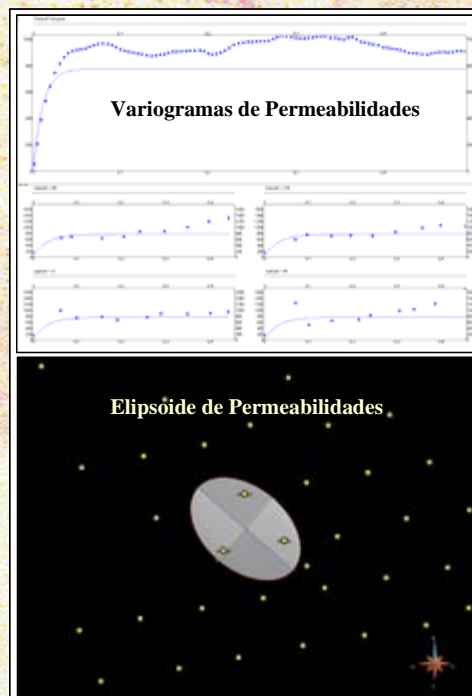


Fig. 7- Tendencias de Variación Espacial Vertical y Areal de la Permeabilidad

Colofón

En el Boletín N°8 se presentará la 2° Parte de este trabajo con los Resultados, Conclusiones y Recomendaciones.

aplicarse a otros pozos con perfiles de entrada similares y predecir las curvas de salida deseadas o validar resultados.

El programa permite realizar simultáneamente varios entrenamientos, para optimizar la predicción, variando la cantidad de iteraciones, de redes en comité y redes ocultas, etc. Tiene un visualizador que permite ver gráficamente los resultados y hacer comparaciones.

MG&A es representante en Latinoamérica de Digital Formation, Inc.™

Contáctenos

: mgyasoc@mgyasoc.com.ar

: www.mgyasoc.com.ar

(5411) 4325-8985; Gratuito desde México: 01 800-123-4788