

# MODELO DE PERMEABILIDADES DE RESERVORIO UTILIZANDO REDES NEURONALES ARTIFICIALES E INTEGRACION GEOESTADISTICA

Mirta C. de Galacho<sup>(1)</sup>, Martín Iribarne<sup>(2)</sup>, María Laura Loss<sup>(3)</sup>, Pablo A. Vázquez<sup>(4)</sup>,  
MG&A Oil & Gas, Miguel Lavia<sup>(5)</sup>; Pioneer NRA

- (1) mirtagalacho@mgyasoc.com.ar
- (2) martiniribarne@mgyasoc.com.ar
- (3) lauraloss@mgyasoc.com.ar
- (4) pablovazquez@mgyasoc.com.ar
- (5) LaviaM@pioneer.nrc.com

Keywords: Permeabilidad; Reservorios; Caracterización; Validación Cruzada

## ABSTRACT

*Reservoir Permeability Model using Artificial Neural Networks and Geostatistical Integration*

The work objective was to generate a 3D absolute permeability model for Lotena Fm reservoir in Anticlinal Campamento Field, Neuquén Basin, reflecting the permeabilities heterogeneities, at reservoir scale, with minimum uncertainties.

The most accurate permeability prediction at every well location, and its most probable distribution in a grid, has proven to be a convenient way to generate the Model to be used after in Numerical Simulation. Well permeabilities were estimated applying Artificial Neural Networks (ANN) and a geo-statistical technique, Ordinary Kriging, was used for grid property distribution.

The available well logs limited the size of the training data set to use. After running sensitivity analyses it was concluded that the best training data set should have SP, Deep Resistivity and Porosity from Sonic logs, as input parameters, and core permeabilities as output data. A 90% correlation coefficient between core data and predicted permeability, confirmed the applied procedure goodness.

Permeabilities obtained from published relationships, have shown worse correlation than the above referred for ANN approach. The reason for these poor adjustments would probably be that they do not take into account the particular post-depositional effects, on permeability, for each reservoir.

Based on the observation that the generated 3D permeability model allowed the identification of connectivity barriers that explained the lack of some injector – producer connections, it was also concluded that Ordinary Kriging was an accurate method to populate the Grid Model.

Finally a satisfactory production history matching confirmed the quality of the developed permeability model as a new solution for an old problem.

## 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. 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.

La utilización de Redes Neuronales Artificiales (ANN), como se demuestra en este estudio, constituye una 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.

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. 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, mas 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.

### **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 (Fig. VI) 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.

## 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. I) alentó el entrenamiento con un set más restringido de datos, acorde con la información disponible.

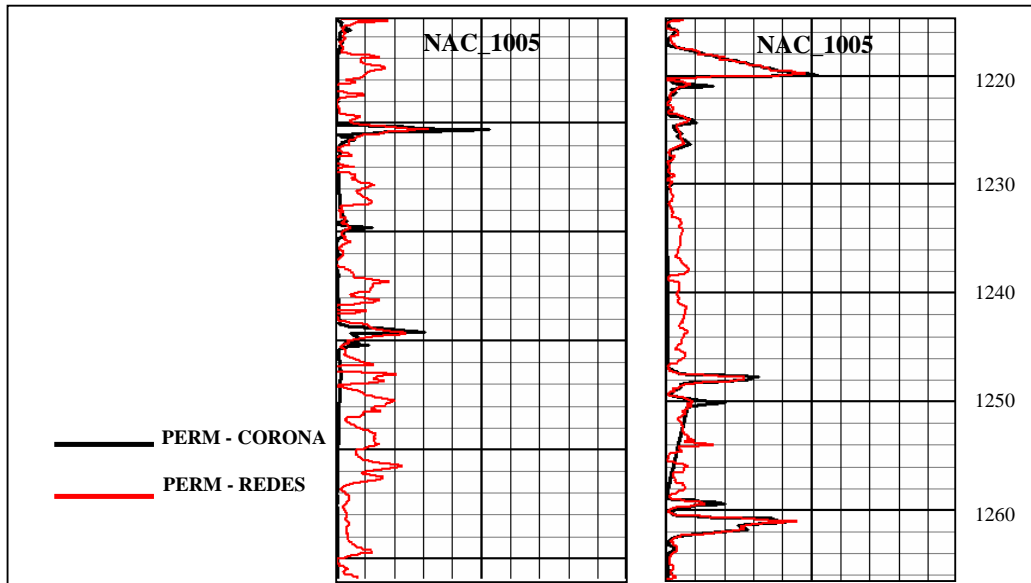


Fig. I- Entrenamiento Inicial de Permeabilidad con Perfiles SP, ILD, DT, RHOB y NPHI

Se efectuaron correlaciones entre los distintos parámetros disponibles (Fig. II) 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.

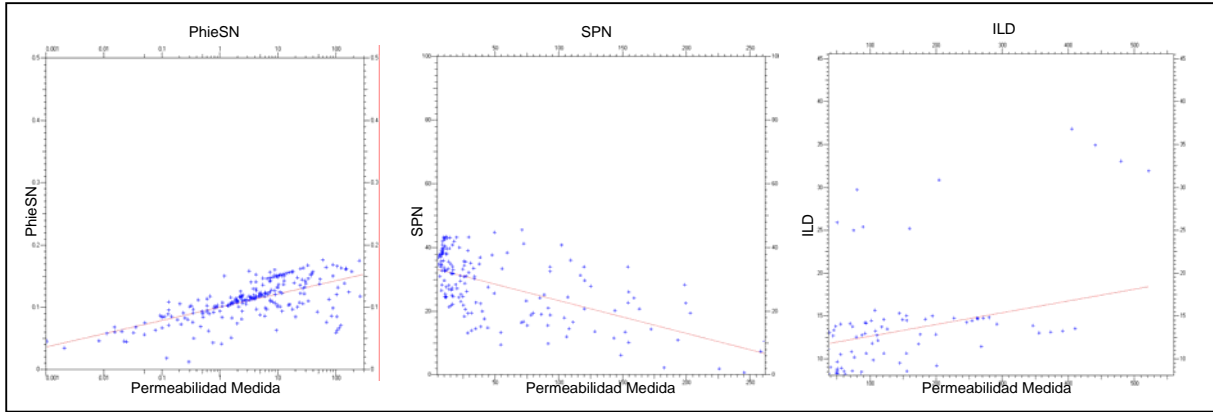


Fig. II- Correlación entre la Permeabilidad Medida y los Perfiles SPN, ILD y PHIESN.

Otro análisis consistió en ir variando los parámetros intrínsecos de las ANN, hasta obtener el mejor ajuste (Fig. III).




Fig. III- Análisis de Sensibilidad variando los Parámetros Intrínsecos de la Red (Aumento del número de iteraciones y cantidad de neuronas en la capa oculta)

**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.

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. IV). Estos resultados fueron validados con la porosidad de corona del pozo NAC 1001 (Fig.V).




Fig. IV- Resultados del Entrenamiento de Porosidad

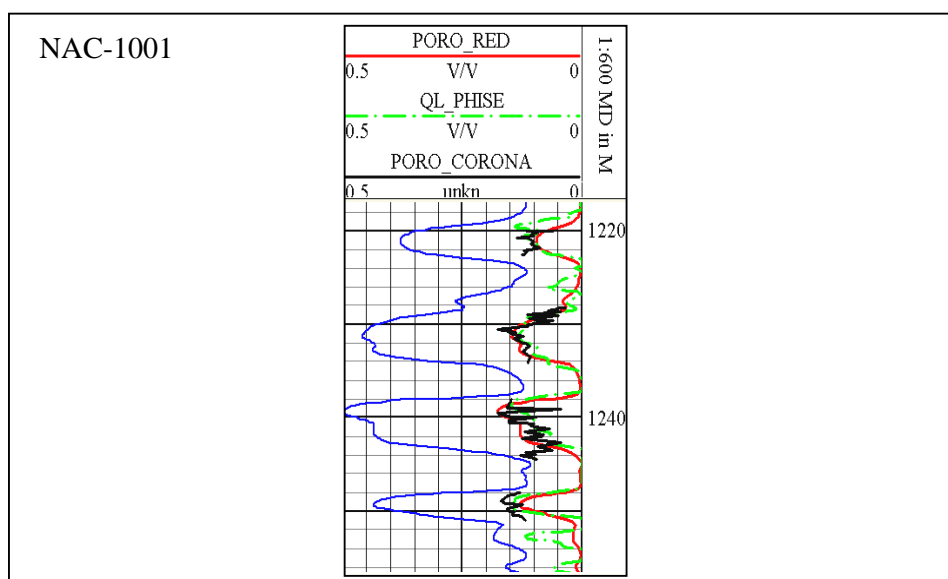


Fig. V- Aplicación del Entrenamiento y Validación con la Porosidad de Corona

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.

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.

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

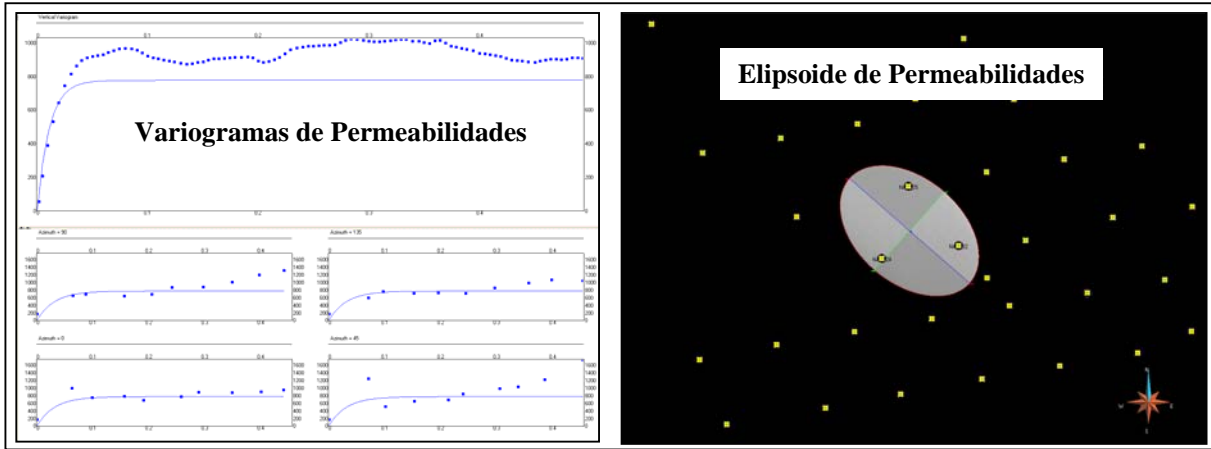


Fig. VI- Tendencias de Variación Espacial Vertical y Areal de la Permeabilidad

## RESULTADOS

El entrenamiento de la red neuronal generó una ajustada predicción de la permeabilidad medida en corona, lográndose un 90% de correlación entre el dato medido y el estimado (Fig. VII). La aplicación posterior de este caso en los pozos sin corona generó perfiles sintéticos de permeabilidad, con valores entre 10 y 250 md, restringidos a las arenas del reservorio (Fig. VIII)

Los resultados de la distribución de la permeabilidad en la grilla del modelo utilizando Kriging Ordinario pueden observarse en la Fig. IX.

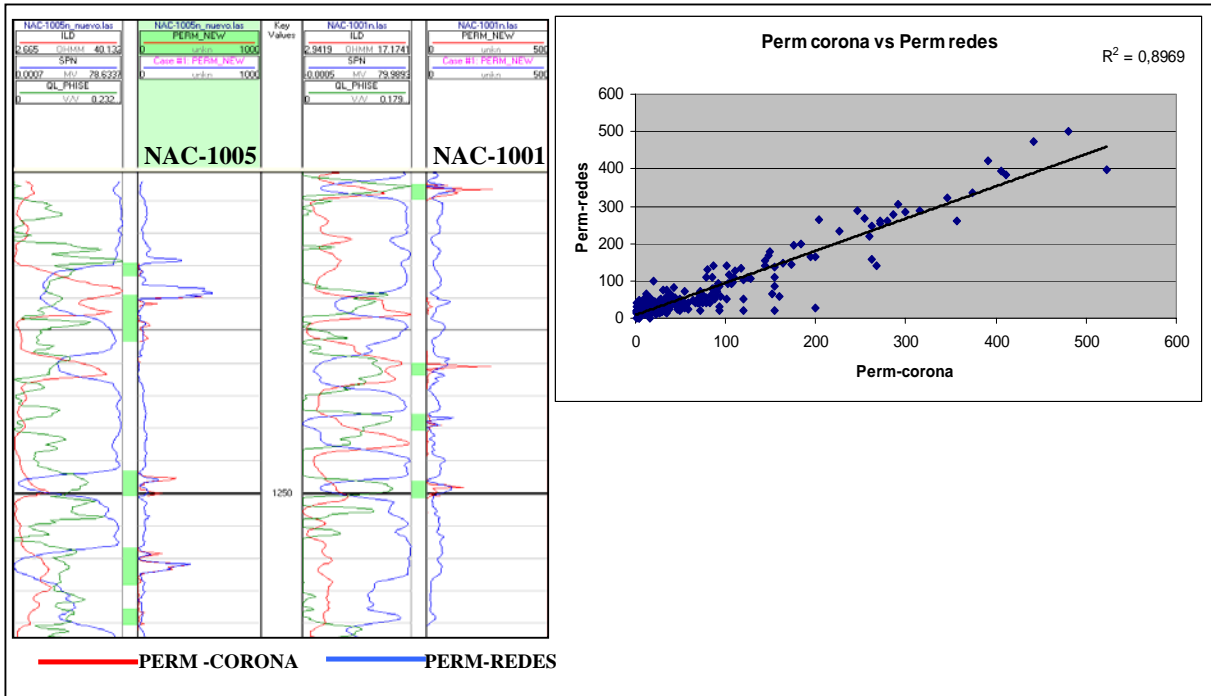


Fig. VII- Correlación entre la Permeabilidad Medida y la Estimada por Redes

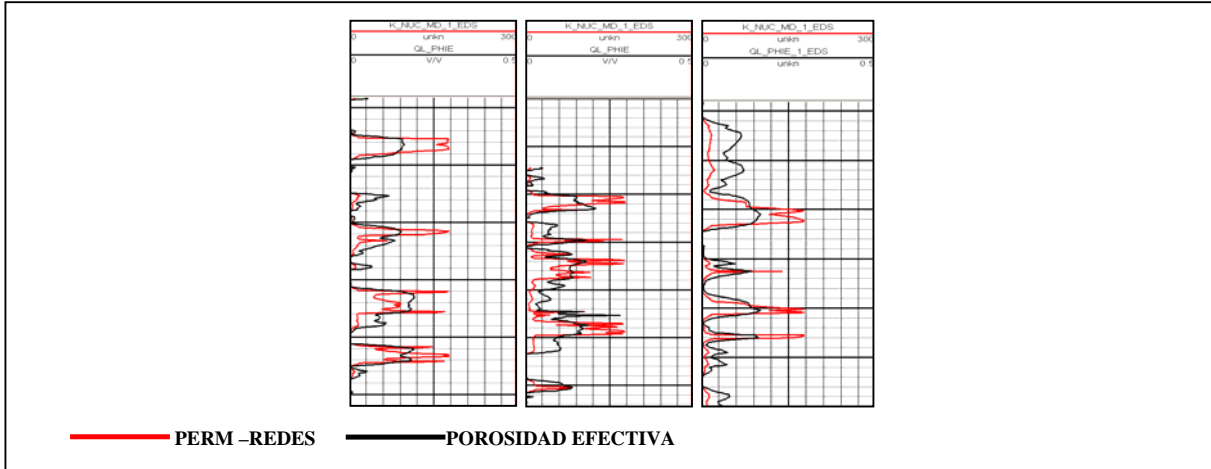


Fig. VIII- Aplicación del Entrenamiento y Generación de Perfiles de Permeabilidad Sintéticos

La bondad del Modelo de Permeabilidades generado se valoró teniendo en cuenta los siguientes aspectos:

- Que las tendencias mostradas por la permeabilidad fueron en general similares y congruentes con las mostradas por el registro eléctrico SP, con la dirección mayor de extrapolación en sentido NW-SE. (Fig. VI y IX)
- Que las zonas de baja permeabilidad en el modelo coinciden con barreras de conectividad que permiten explicar la falta de relación entre productor e inyector a ambos lados de la barrera, durante el piloto de Inyección de Agua.
- Que esto puede observarse en los mapas de Delimitación y Caracterización de Subunidades Hidráulicas donde las barreras de conectividad coinciden con zonas de bajas permeabilidades (Fig. X)
- Que las zonas de mayor Permeabilidad predichas por el modelo se corresponden con los pozos de mayor acumulada de petróleo (Fig. XI)
- Que en la Simulación Numérica por Diferencias Finitas el modelo mostró un excelente ajuste respecto de la producción histórica. Este resultado (Fig XII y XIII) representa una crossvalidación del modelo desde un punto de vista dinámico.
- Que el Ajuste Histórico arriba referido se logró al cabo de 6 corridas y los únicos parámetros que se modificaron fueron los puntos extremos de la permeabilidad relativa.
- Que en ese Ajuste no fue necesario modificar el modelo de permeabilidad absoluta, lo cual confirma la aproximación del modelo a la situación real del yacimiento.

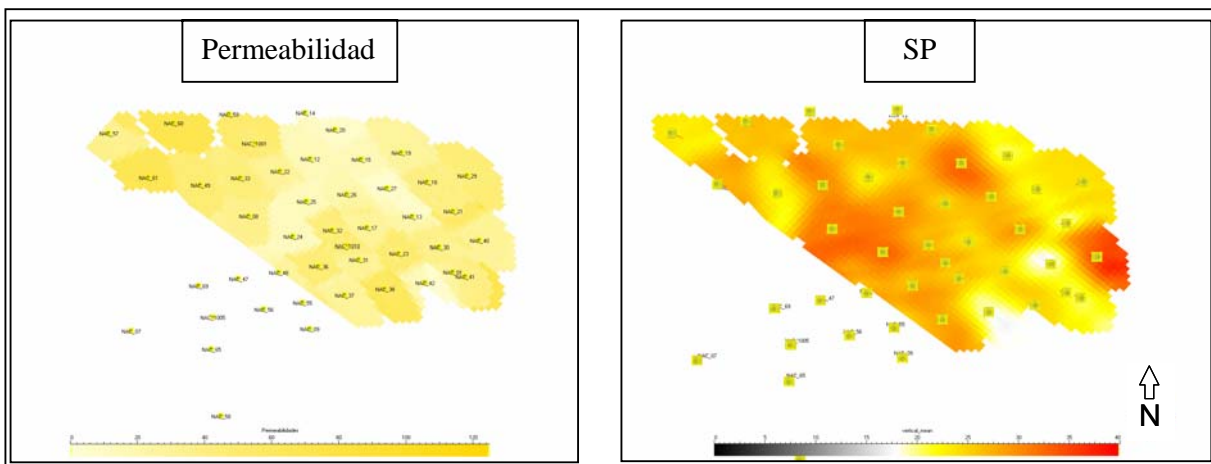


Fig. IX- Distribución de la Permeabilidad en la Grilla Tridimensional por Kriging Ordinario. El eje mayor de extrapolación es coincidente con el de la distribución del perfil SP.

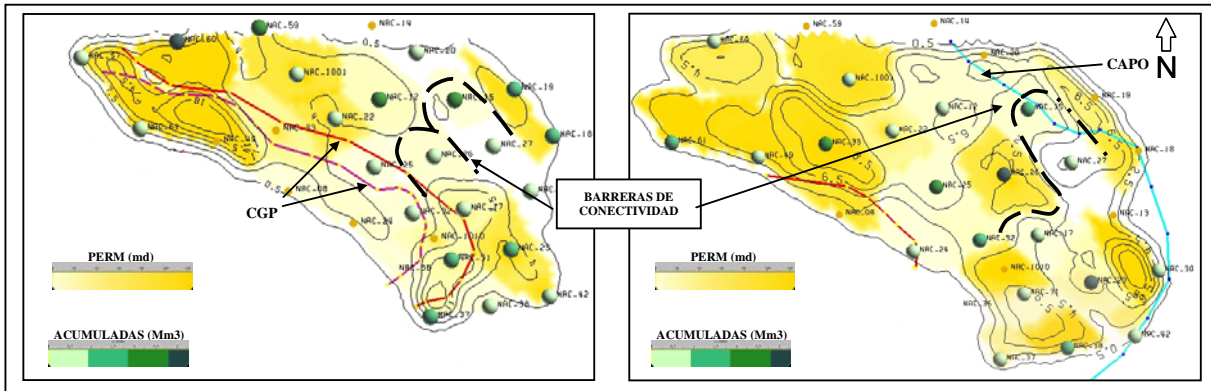


Fig. X- Barreras de Conectividad predichas por el Modelo para dos Niveles del Yacimiento

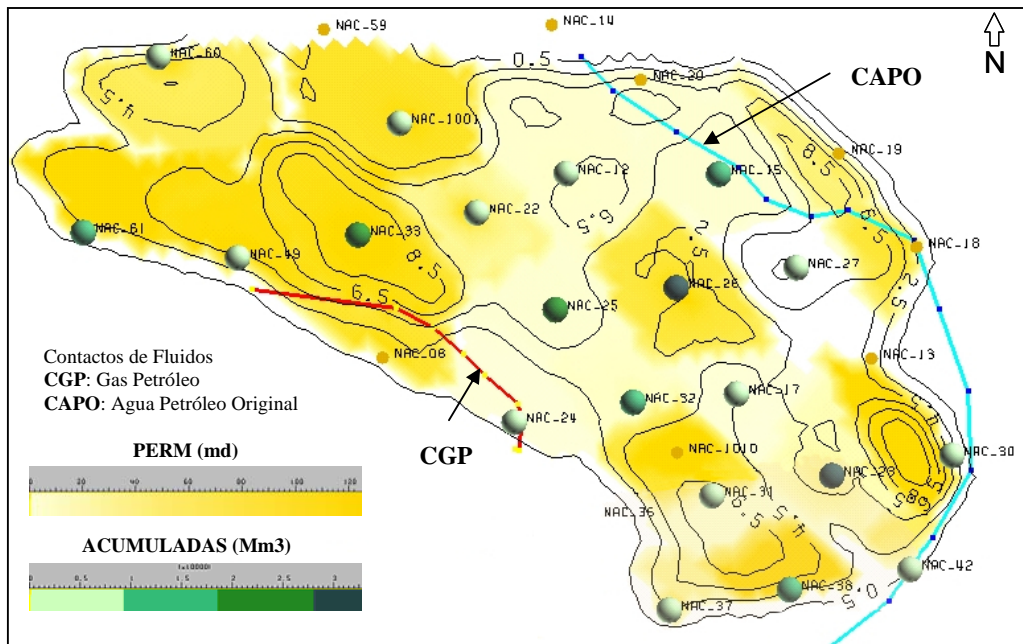


Fig. XI- Relación entre Acumuladas de Producción y Permeabilidades




Fig. XII- Simulación Numérica por Diferencias Finitas. Ajuste Histórico Global



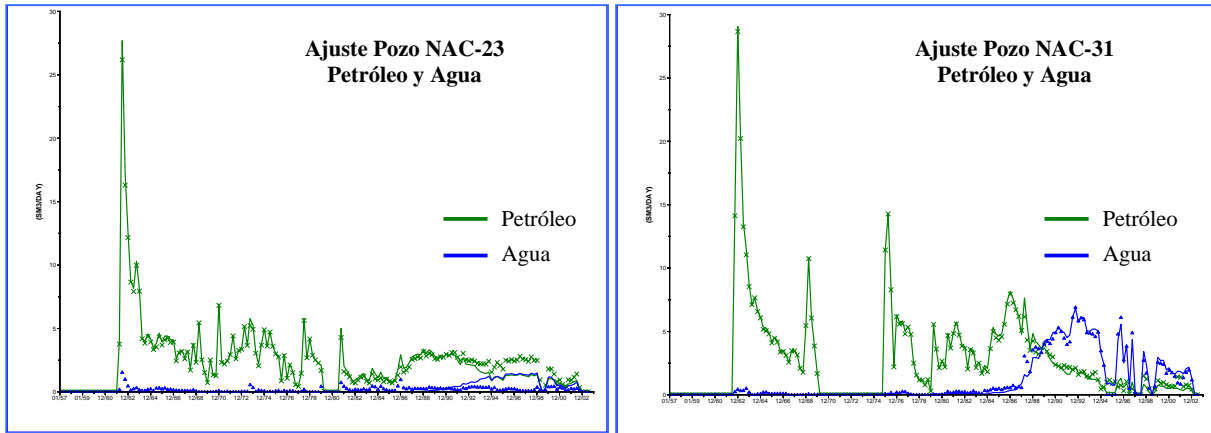


Fig. XIII- Simulación Numérica por Diferencias Finitas. Ajuste Histórico Pozo a Pozo

## CONCLUSIONES Y RECOMENDACIONES

Del modelo generado pueden extraerse las siguientes conclusiones:

- Las redes neuronales han demostrado ser en este yacimiento un confiable método de predicción, ya que respetaron las tendencias mostradas por otras variables, como la litología y la producción de petróleo.
- Al mismo tiempo lograron reproducir la variabilidad y heterogeneidad de la permeabilidad a escala de reservorio, sin generar valores “promedio” por zonas, al no ajustarse a leyes matemáticas predeterminadas.
- Los resultados del modelo fueron validados a través de caracterizaciones estáticas (distribución y espesores de arenas definidas a partir de SP) y dinámicas (acumuladas de producción y ajustes históricos durante la simulación numérica).

Sin embargo, y aunque resulte evidente, no debería olvidarse que un buen resultado depende de la calidad de los datos de entrada casi exclusivamente. Por ello, en la etapa previa al modelado se recomienda tener en cuenta los siguientes factores:

- La cantidad de información de corona disponible, su distribución en el reservorio y el número de perfiles condicionará la bondad de la predicción posterior ya que la capacidad de generalización de la red estará basada en la diversidad de datos y situaciones a las que se la exponga durante su entrenamiento.
- Las tareas previas al entrenamiento de una Red Neuronal requieren de una exhaustiva búsqueda de relaciones confiables entre variables, de análisis de sensibilidad que permitan seleccionar los parámetros de entrada y de la elección cuidadosa de los datos de salida más representativos. Para este fin los análisis estadísticos de los datos de entrada respecto del patrón a reproducir (en este caso la permeabilidad) resultan de suma utilidad para admitir o descartar conjuntos de datos.
- Para evitar los errores de combinar datos de permeabilidad medidos en distintas condiciones, se recomienda expresar los mismos a una única NOBP (Net Overburden Pressure).
- Es conveniente que los entrenamientos de permeabilidad se efectúen por zona, facie, bloque o cualquier otra diferenciación geológica que implique una variación en la relación entrada-salida de la Red. Se evitarán así predicciones erróneas o poco confiables, en detrimento de la versatilidad de la red neuronal. Si la información disponible por zonas es escasa o irrelevante, entonces un entrenamiento global de las Redes es más recomendable, tal como se realizó en el caso aquí presentado.

## AGRADECIMIENTOS

Los autores agradecen a la empresa Pioneer Natural Resources Argentina por autorizar la presentación de este trabajo que ha utilizado parte de la información del Yacimiento Anticlinal Campamento.

## BIBLIOGRAFIA

- Balan, B.; Mohaghegh, S. D. y Ameri, S.: “State-Of-The Art in Permeability Determination From Well Log Data: Part 1-A Comparative Study, Model Development”, SPE 30978, SPE Eastern Regional Conference and Exhibition, Morgantown, West Virginia, U.S.A.(Setiembre 1995).
- Bhatt, A. y Helle, H. B. : “Porosity, Permeability and TOC prediction from well logs using a neural network approach”, 61<sup>st</sup> Annual EAGE Meeting, Helsinki, Finlandia (Junio 1999).
- Bhatt, A.; Helle, H.B. y Ursin, B.: “Application of Committee Machines in Reservoir Characterization While Drilling: a Novel Neural Network Approach in Log Analysis”, 6<sup>th</sup> Nordic Symposium on Petrophysics, Trondheim, Noruega (Mayo 2001).
- Galacho, M.C.; Monsalvo, G. F.; Vázquez, P. y Wouterlood, C. J.: “La Estadística Integral Autocorrelada y la Optimización del Desarrollo y Explotación de los Campos”, 3<sup>er</sup> Congreso E\_Exitep, Veracruz, México (Febrero 2003).
- Jensen, J.L.; Lake, L. W.; Corbett, P.W. y Goggin, D. J.: “Statistics for petroleum engineers and geoscientists”, Second Edition, Elsevier Science, Amsterdam, Holanda (2000).
- Kelkar, M. y Pérez, G.: “Applied Geostatistics for Reservoir Characterization”, Society of Petroleum Engineers, Richardson, Texas, U.S.A. (2002).
- Mohaghegh, S. D.; Balan, B. y Ameri, S.: “State-Of-The Art in Permeability Determination From Well Log Data: Part 2-Verifiable, Accurate Permeability Predictions, The Touch - stone of All Models”, SPE 30979, SPE Eastern Regional Conference and Exhibition, Morgantown, West Virginia, U.S.A.(Setiembre 1995)
- Mohaghegh, S. D.: “Recent Development in Application of Artificial Intelligence in Petroleum Engineering”, SPE 89033 (Mayo 2004).
- “Tutorial sobre Redes Neuronales Artificiales”. (<http://www.gc.ssr.upm.es/inves/neural/ann2>)
- “Introduction to Neural Networks”. (<http://www.cs.bham.ac.uk/jbx/inc>)