




**PROPIEDAD INTELECTUAL**

**REDES NEURONALES ARTIFICIALES (RNA)**

**EN**

**LAS GEOCIENCIAS E INGENIERÍA**

**DE YACIMIENTOS DE PETRÓLEO Y GAS**

**Agosto 2008**

# **PROPIEDAD INTELECTUAL**

## **REDES NEURONALES ARTIFICIALES (RNA)**

**EN**

### **LAS GEOCIENCIAS E INGENIERÍA DE YACIMIENTOS DE PETRÓLEO Y GAS**

**Autores:**        **MIRTA CÓRDOBA DE GALACHO**  
                         **NÉSTOR GALACHO**

**Agosto 2008**

Todos los derechos reservados por Mirta Galacho y Asociados S.R.L.  
Hecho el depósito que establece la ley 11.723 bajo los números 686970

## **PREFACIO**

Este escrito se ha desarrollado utilizando la rica experiencia ganada a partir de diversos trabajos que la Consultora Mirta Galacho y Asociados S.R.L. ha desarrollado a los largo de veinte años de labor ininterrumpida de estudios de diversos yacimientos de petróleo y gas tanto de Argentina como de otros países Latinoamericanos.

La introducción del uso de Redes Neuronales Artificiales en la estimación de parámetros utilizados en el Modelado Estático y Dinámico de yacimientos de hidrocarburos es relativamente nueva, pero que abre enormes posibilidades en el futuro inmediato para su aplicación de manera generalizada.

No se ha desarrollado un estudio teórico sobre las Redes Neuronales Artificiales sino que se ha enfatizado en su aplicación práctica para la resolución de problemas que con frecuencia se encuentran los geocientíficos e ingenieros en su tarea en yacimientos de petróleo y gas.

Queremos agradecer la inestimable colaboración de los Licenciados en Ciencias Físicas Alberto Iuliano y Carla Romano que aportaron sus conocimientos matemáticos y recopilación bibliográfica, como así también a Mirta Galacho y Asociados S.R.L. que nos ha facilitado material para la publicación que aquí presentamos.

**MIRTA CÓRDOBA DE GALACHO**

**NÉSTOR GALACHO**

## INDICE GENERAL

|                                                                                                                                                      |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| I. Las Redes Neuronales Artificiales.....                                                                                                            | 6  |
| I. 1 Fundamentos y Principales Características .....                                                                                                 | 6  |
| I. 2 Arquitectura de la RNA Utilizada.....                                                                                                           | 7  |
| I. 3 Las RNA y los Conjuntos Pequeños de Datos .....                                                                                                 | 7  |
| II. Modelo de Permeabilidades de Reservorio y Evolución de la Presión Estática de Yacimiento,<br>Utilizando Redes Neuronales Artificiales (RNA)..... | 9  |
| II. A Modelo de Permeabilidades de reservorio, Utilizando RNA.....                                                                                   | 10 |
| II. A.1 Permeabilidad: Objetivo Central en el Modelado Estático .....                                                                                | 10 |
| II. A.2 Breve Descripción del Yacimiento .....                                                                                                       | 10 |
| II. A.3 Metodología.....                                                                                                                             | 10 |
| II. A.3.1 BP-RNA .....                                                                                                                               | 10 |
| II. A.3.2 Procedimientos Geoestadísticos.....                                                                                                        | 11 |
| II. A.4 Desarrollo.....                                                                                                                              | 11 |
| II. A.4. 1 Elección de Parámetros y Análisis de Sensibilidad .....                                                                                   | 11 |
| II. A.4. 2 Tareas Desarrolladas .....                                                                                                                | 13 |
| II. A.5 Resultados.....                                                                                                                              | 15 |
| II. A.6 Conclusiones Y Recomendaciones .....                                                                                                         | 18 |
| II. B Evolución de la Presión Estática de Yacimiento, Utilizando RNA .....                                                                           | 20 |
| II. B. 1 Presión Estática del Yacimiento: Objetivo Central en el Modelado Dinámico .....                                                             | 20 |
| II. B. 2 Breve Descripción del Yacimiento .....                                                                                                      | 20 |
| II. B. 3 Metodología. RNA utilizadas y Etapas de su Aplicación.....                                                                                  | 20 |
| II. B. 4 Desarrollo.....                                                                                                                             | 21 |
| II. B.4.1 RNA. Etapa de Entrenamiento .....                                                                                                          | 21 |
| II. B.4.2 RNA. Etapa de Validación.....                                                                                                              | 21 |
| II. B.4.3 RNA. Etapa de Predicción.....                                                                                                              | 23 |
| II. B. 5 Aplicación de la Presión Estática, Medida y Predicha por la RNA.<br>Balance de Materiales .....                                             | 24 |
| BIBLIOGRAFIA .....                                                                                                                                   | 27 |

## I. LAS REDES NEURONALES ARTIFICIALES

### I. 1 FUNDAMENTOS Y PRINCIPALES CARACTERÍSTICAS

La utilización de Redes Neuronales Artificiales (RNA) 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 especificados explícitamente.

Kaviani (2008) expresó que una RNA es "un sistema de información y procesamiento con ciertas características en común con una red neuronal biológica", confirmando una analogía anteriormente establecida por Fausett (1994).

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 RNA, funcionan como sistemas dinámicos no lineales que aprenden a reconocer patrones a través del entrenamiento.

Haykin (1999) mostró, sobre la base del "Teorema de aproximación universal", que las RNA multicapa, con un número suficiente de nodos ocultos (Fig. 1), **son capaces de predecir cualquier función desconocida.**

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 conjunto de ecuaciones (Mohaghegh 1995). También tienen en cuenta, por ejemplo, la no linealidad en la distribución, como es el caso de la permeabilidad, ya que son independientes de cualquier forma de función.

En contraste con los métodos de regresión lineal, las RNA, 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 RNA 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).

También, como la experiencia de aplicación de las RNA muestra, observamos que no hay un "Método Óptimo universal" de las mismas, por lo que puede ser necesario probar diferentes métodos para cada caso. Tal como veremos, estos aspectos son incluidos en la llamada Etapa de Validación de la RNA aplicada, por un lado se valoran los datos predichos y paralelamente se analiza si el tipo de RNA utilizado es el conveniente.

Dada una estructura básica de la red, se puede lograr una amplia variedad de RNA. Diferentes métodos o criterios para generar la RNA proporcionan predicciones que pueden diferir. También se pueden combinar dos o más redes neuronales para lograr, por ejemplo, mejores Validaciones, generando los llamados "métodos de aprendizaje conjunto," un término que abarca una gran variedad de métodos, sumados o promediados. Se evalúa el tipo de RNA a utilizar cuando se valida la capacidad de predicción de la Red.

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, ver Fig. 1.




Fig. 1 Redes Neuronales Artificiales con sus Capas de Entrada, Salida e Intermedias u Ocultas

## I. 2 ARQUITECTURA DE LA RNA UTILIZADA

En el presente trabajo se utilizó una Red Neuronal de Retro-Propagación Multicapa (Back-Propagational Artificial Neural Network (BP-RNA), Software utilizado: LESA® – Módulo Esteem de Digital Formation).

El proceso de aprendizaje de las BP-RNA, consiste en transmitir hacia delante en la red los valores de entrada y entonces calcular la diferencia entre el Output predicho y el Output medido. 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 medidos (Bhatt 1999, 2001).

El entrenamiento de una RNA estará condicionado, más allá de los datos de entrada utilizados, por 3 parámetros intrínsecos: el número de capas ocultas, 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.

## I. 3 LAS RNA Y LOS CONJUNTOS PEQUEÑOS DE DATOS

Como es conocido, las RNA en los últimos años han tenido una vasta aplicación para problemas de predicción y clasificación en distintas disciplinas, muchas de ellas fuera de la Industria del petróleo y gas. Sin embargo, una de las limitaciones frecuentes e importantes en la utilización de las RNA, ha sido su capacidad limitada para analizar “pequeños conjuntos de datos” produciendo lo que técnicamente se llama “sobre ajuste” (over fitting) de los datos.

Esta es una situación común en las aplicaciones de las Geociencias y la Ingeniería del Petróleo y Gas pues con frecuencia se dispone un número limitado de datos adquiridos en el laboratorio o campo, por encontrarse el yacimiento en la etapa inicial de su desarrollo; por problemas de costos; por limitaciones logísticas; etc. En esos casos se podrán tener:

- Pocas coronas,
- Escasas mediciones de presiones estáticas (requieren la suspensión de la producción del pozo bajo medición)
- Pocos pozos perforados, con toda su información relativa,
- Conjuntos reducidos de Perfiles de pozo, etc.

Se mostrará en este trabajo, utilizando ejemplos de aplicación, que las RNA son atractivas, pues permiten modelar **relaciones complejas, no lineales** y de allí realizar predicciones de otros datos faltantes.

Coincidiendo con otros autores, pudimos verificar que las RNA disminuyen efectivamente el error de predicción cuando existe una relación subyacente entre las variables, tema que es de gran importancia en los casos de aplicación de pequeños conjuntos de datos.

En esos casos, el uso de las RNA puede dar lugar a un sobre-ajuste al tren de datos, logrando una mala predicción de otros puntos (Fig. 2). En este estudio, verificamos que las BP-RNA logran un buen comportamiento del error de validación con un número limitado de datos, y que éste puede disminuirse modificando el número de Capas Ocultas o Nodos.




Fig. 2 Predicción inadecuada de las RNA, como una función sobreajustada  
La RNA ajusta a todos los puntos dato, pero interpola  
y extrapola pobremente. Kaviani (2008)

Después de esta breve reseña de las RNA y sus características, presentaremos dos ejemplos de aplicación, uno desarrollado en las Geociencias y el otro en la Ingeniería de Yacimientos de petróleo y gas.

En el primero se predicen valores de permeabilidad de un yacimiento, escasamente disponibles por el número limitado de coronas extraídas y en el segundo se predice la evolución de la presión estática de yacimiento, escasamente medida pues se requiere la suspensión de la producción del pozo bajo medición.

## **II. MODELO DE PERMEABILIDADES DE RESERVORIO Y EVOLUCIÓN DE LA PRESIÓN ESTÁTICA DE YACIMIENTO, UTILIZANDO REDES NEURONALES ARTIFICIALES (RNA)**

La primer realización de este trabajo es generar un modelo de permeabilidad 3D para el reservorio de la Fm. Lotena en el campo Anticlinal Campamento, Cuenca Neuquina, República Argentina, que refleje las heterogeneidades, a la escala del reservorio, con mínimas incertidumbres.

La predicción más adecuada de la permeabilidad en todas las locaciones de pozo y su más probable distribución en una grilla, ha probado ser un camino conveniente para generar esa variable del Modelo estático a ser usado luego en una Simulación Numérica Dinámica del campo. Las permeabilidades de pozo fueron estimadas aplicando Redes Neuronales Artificiales (RNA) y luego se utilizó la técnica estadística Kriging Ordinario, para la distribución de la propiedad en la grilla.

El grupo de perfiles de pozo disponible limitó el tamaño del conjunto de datos de entrada. Se realizaron análisis de sensibilidad y se concluyó que el mejor conjunto de datos de entrenamiento estaba compuesto por los siguientes perfiles: Potencial Espontáneo (SP), Resistividad Profunda y Porosidad (de los perfiles sónicos), como parámetros de entrada y permeabilidades de corona, como datos de salida. Se obtuvo un coeficiente de correlación del 90% entre los datos de corona y la permeabilidad predicha, lo que confirmó la bondad del procedimiento aplicado.

Se observó que el modelo generado de permeabilidades permitió identificar barreras de conectividad indicadas previamente por la falta de conexión entre pares de inyector-productor, lo que permitió también concluir que el Kriging Ordinario fue un método adecuado para poblar la grilla del modelo.

Finalmente un muy satisfactorio del Ajuste Histórico de la producción en un Modelo Numérico Dinámico confirmó la calidad del modelo de permeabilidades logrado, como una nueva solución para un viejo problema.

La segunda realización de este trabajo es generar mediante el uso de RNA la evolución temporal de las Presiones Estáticas de un reservorio a medida que se lo explota.

Se aplica en este caso a un yacimiento de petróleo, con un importante casquete de gas y un limitado empuje de agua, desarrollado en la Formación Quintuco de la Cuenca Neuquina. La producción de este yacimiento se obtiene de zonas de porosidad y permeabilidad primaria, pero también secundaria de zonas metamorfoseadas y fracturadas. Se produce Gas y Condensado en unos pocos pozos terminados en el Casquete de Gas y Petróleo Negro, en el resto de los pozos, terminados en la zona petrolífera.

La Presión Estática del Reservorio es una función compleja de las características estáticas del mismo, fundamentalmente de su tamaño poral efectivo ligado al proceso de producción en marcha, pero también de los mecanismos de producción, que en el caso del yacimiento presentado es una combinación de empuje por gas disuelto en el petróleo, expansión del petróleo y del casquete de gas, compactación de la roca y el agua y entrada limitada de agua.

Las RNA aplicadas en este trabajo, en la predicción de las Presiones Estáticas, han mostrado un alto coeficiente de ajuste en la etapa de validación de las mismas, lo que la convierten en una herramienta de gran valor en la optimización de la producción de los yacimientos de hidrocarburos.



## **II. A MODELO DE PERMEABILIDADES DE RESERVORIO, UTILIZANDO RNA**

### **II. A.1 PERMEABILIDAD: OBJETIVO CENTRAL EN EL MODELADO ESTÁTICO**

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 al tiempo de la depositación, los procesos post-depositacionales, etc. 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 irreducible de agua, lo que deriva en modelos poco flexibles y que carecen de la capacidad de reflejar el flujo de fluidos en medios porosos.

### **II. A.2 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.

### **II. A.3 METODOLOGÍA**

Las permeabilidades de pozo fueron estimadas aplicando Redes Neuronales Artificiales (RNA) y luego se aplicó la técnica estadística Kriging Ordinario, para la distribución de la propiedad en la grilla.

#### **II. A.3.1 BP-RNA**

Se aplicaron las RNA de Retropropagación, previamente descriptas, para obtener la permeabilidad definida en cada pozo.

El grupo de perfiles de pozo disponible limitó el tamaño del conjunto de datos de entrada. Se realizaron análisis de sensibilidad y se concluyó que el mejor conjunto de datos de entrenamiento estaba compuesto por los siguientes perfiles: Potencial Espontáneo (SP), Resistividad Profunda y Porosidad (de los perfiles sínicos), como parámetros de entrada y permeabilidades de corona, y permeabilidades de corona, como datos de salida. Se obtuvo un coeficiente de correlación del 90% entre los datos de corona y la permeabilidad predicha, lo que confirmó la bondad del procedimiento aplicado.

### **II. A.3.2 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.

### **II. A.4 DESARROLLO**

#### **II. A.4. 1 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 RNA ante las mejores condiciones posibles para verificar su poder de predicción. El excelente ajuste obtenido (Fig. I) alentó el entrenamiento con un conjunto 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 RNA, 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)

## II. A.4. 2 TAREAS DESARROLLADAS

En los 11 pozos con registro sísmico 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 RNA. 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 (Presión Neta de Confinamiento). Los parámetros básicos seleccionados según los análisis de sensibilidad fueron: 30 sistemas expertos en paralelo y 500 iteraciones.




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

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 aplicó la técnica de Kriging Ordinario respetando estas tendencias para obtener un modelo tridimensional y continuo de las permeabilidades.

## II. A.5 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).




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




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

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

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 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 explican 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 validación cruzada 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 buena 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

## II. A.6 CONCLUSIONES

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: Presión Neta de Confinamiento).
- 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.

## **II. B EVOLUCIÓN DE LA PRESIÓN ESTÁTICA DE YACIMIENTO, UTILIZANDO RNA**

### **II. B. 1 PRESIÓN ESTÁTICA DEL YACIMIENTO: OBJETIVO CENTRAL EN EL MODELADO DINÁMICO**

Sin duda el conocimiento de la Evolución de la Presión Estática de un Yacimiento, a medida que se lo explota, es fundamental para la optimización del Modelado Dinámico del mismo, ya sea utilizando las herramientas de la Ingeniería Clásica de Reservorios o la Simulación Numérica Dinámica. De esa optimización surgirán distintas prácticas de explotación que permitirán maximizar los caudales y la recuperación de los hidrocarburos del yacimiento.

La Evolución de la Presión Estática del Yacimiento tiene una directa relación con el tamaño poral efectivo del mismo que responde al proceso de producción en marcha. Las determinaciones de ese Hidrocarburo en sitio se realizan mediante Balance de Materiales, que requiere el conocimiento de las Presiones Estáticas.

En definitiva la Presión Estática del Reservorio es una función compleja de las características estáticas del mismo, fundamentalmente de su tamaño poral efectivo ligado al proceso de producción en marcha, pero también de los mecanismos de producción, es una combinación de empuje por gas disuelto en el petróleo, expansión del petróleo y del casquete de gas, compactación de la roca y el agua y entrada limitada de agua.

Las RNA aplicadas en este trabajo en la predicción de las Presiones Estáticas han mostrado un alto coeficiente de ajuste en la etapa de validación de las mismas.

### **II. B. 2 BREVE DESCRIPCIÓN DEL YACIMIENTO**

Se trata de un yacimiento de petróleo con un importante Casquete de gas y un limitado empuje de agua desarrollado en la Formación Quintuco de la Cuenca Neuquina.

Este yacimiento produce por porosidad y permeabilidad primaria, pero también secundaria de zonas metamorfoseadas y fracturadas.

Se produce Gas y Condensado en los pozos terminados al Casquete de Gas y Petróleo Negro en los terminados en la zona petrolífera.

Se busca mediante la aplicación de RNA, previamente descriptas, predecir la presión dinámica del reservorio, en estadios posteriores de la explotación, en función de los datos de producción acumulada de petróleo, agua y gas ( $N_p$ ,  $W_p$  y  $G_p$ ).

Una vez que se dispongan los datos de presión necesarios, mediante la aplicación de Balance de Materiales, se estimará el Petróleo Original en sitio.

### **II. B. 3 METODOLOGÍA. RNA UTILIZADAS Y ETAPAS DE SU APLICACIÓN**


Se aplican también en este caso las BP-RNA previamente utilizadas. Las características de las Redes en sí y de su entrenamiento son las previamente desarrolladas.

Se vuelven a indicar las Etapas de su uso, que más abajo se desarrollan en este Caso Histórico

1. **Entrenamiento:** La red aprende las relaciones no lineales entre las variables de entrada y de salida. Estas relaciones pueden controlarse con las capas ocultas.
2. **Validación:** Se aplica la red a valores de entrada, cuyas salidas son conocidas y se las compara

con las obtenidas por redes neuronales.

3. **Aplicación:** Se aplica la red a un conjunto de variables de entrada cuyas salidas no se conocen.



## II. B. 4 DESARROLLO

### II.B.4.1 RNA. ETAPA DE ENTRENAMIENTO

Como se ha dicho previamente, los Datos de Entrada para este Análisis son la producción Acumulada de Gas (Gp), Acumulada de Agua (Wp) y Acumulada de Petróleo (Np) y la Presión Estática (P) como dato de salida.

| DATE   | GP<br>(Km <sup>3</sup> ) | WP<br>(m <sup>3</sup> ) | NP<br>(m <sup>3</sup> ) | P<br>(kg/cm <sup>2</sup> ) |
|--------|--------------------------|-------------------------|-------------------------|----------------------------|
| Jul-89 | 180000                   | 240                     | 49820                   | 309,4                      |
| Abr-90 | 600000                   | 240                     | 143160                  | 313,7                      |
| May-91 | 1450000                  | 240                     | 319630                  | 297,9                      |

Fig. XIV Datos utilizados para el Entrenamiento de la RNA

Se puede observar en la Fig. IVX que sólo se usan para el entrenamiento de la RNA tres puntos en la Evolución temporal de este reservorio, distanciados 1 año entre sí, es lo que se llama un “conjunto pequeño de datos” (small data set). Notar que en el período de entrenamiento no se produjo agua.

El entrenamiento utilizando SMALL DATA SETS se realiza mejor cuando existe una relación funcional entre las variables de entrada y salida.

$$P = P ( Np, Wp, Gp, x1, x2,...,xn)$$

### II.B.4.2 RNA. ETAPA DE VALIDACIÓN


En este caso se utilizó un conjunto de mayor tamaño, 21 puntos, desde Diciembre-91 hasta Enero-06, que de todas maneras debe ser considerado un “conjunto pequeño de datos”.

Se observa en la Fig. XV una muy buena predicción de datos lograda en la Etapa de Validación de la RNA, con errores relativos menores del 3 %. Estos datos nos permiten considerar que la RNA es una herramienta muy adecuada para la predicción de la Presión Estática de este reservorio de alta complejidad.

| <b>DATE</b> | <b>GP<br/>(Km<sup>3</sup>)</b> | <b>WP<br/>(m<sup>3</sup>)</b> | <b>NP<br/>(m<sup>3</sup>)</b> | <b>P<br/>(kg/cm<sup>2</sup>)</b> | <b>P_ANN<br/>(kg/cm<sup>2</sup>)</b> | <b>Error<br/>relativo<br/>(%)</b> |
|-------------|--------------------------------|-------------------------------|-------------------------------|----------------------------------|--------------------------------------|-----------------------------------|
| Dic-91      | 2050000                        | 630                           | 466060                        | 290,9                            | 289,5                                | <b>0,46</b>                       |
| Ene-92      | 2100000                        | 870                           | 471680                        | 290,8                            | 289,0                                | <b>0,61</b>                       |
| Feb-93      | 2860000                        | 2920                          | 650140                        | 280,6                            | 282,1                                | <b>0,53</b>                       |
| Mar-93      | 2940000                        | 3100                          | 667000                        | 277,7                            | 281,3                                | <b>1,31</b>                       |
| Ago-93      | 3380000                        | 4700                          | 793650                        | 280,5                            | 277,6                                | <b>1,03</b>                       |
| Oct-93      | 3600000                        | 5700                          | 861380                        | 274,6                            | 275,8                                | <b>0,44</b>                       |
| Nov-93      | 3700000                        | 6270                          | 901670                        | 275,8                            | 275,1                                | <b>0,25</b>                       |
| Dic-94      | 5120000                        | 12960                         | 1358950                       | 264,1                            | 264,1                                | <b>0,00</b>                       |
| Mar-95      | 5380000                        | 13220                         | 1442950                       | 263,3                            | 262,2                                | <b>0,42</b>                       |
| May-95      | 5560000                        | 13290                         | 1506820                       | 261,1                            | 260,9                                | <b>0,06</b>                       |
| Dic-95      | 6350000                        | 15720                         | 1757630                       | 252,2                            | 255,2                                | <b>1,19</b>                       |
| May-96      | 7000000                        | 25240                         | 1970880                       | 251,6                            | 250,5                                | <b>0,43</b>                       |
| Ago-96      | 7400000                        | 48630                         | 2165130                       | 247,0                            | 247,9                                | <b>0,35</b>                       |
| Sep-96      | 7500000                        | 57310                         | 2223400                       | 245,7                            | 247,2                                | <b>0,63</b>                       |
| Dic-96      | 7900000                        | 79250                         | 2377190                       | 244,9                            | 244,2                                | <b>0,28</b>                       |
| Ene-97      | 8030000                        | 89190                         | 2435310                       | 244,2                            | 243,2                                | <b>0,39</b>                       |
| Feb-97      | 8160000                        | 98200                         | 2487530                       | 241,5                            | 242,2                                | <b>0,31</b>                       |
| Ago-97      | 8840000                        | 149910                        | 2834480                       | 244,4                            | 237,7                                | <b>2,73</b>                       |
| Sep-97      | 8980000                        | 157030                        | 2888900                       | 232,1                            | 236,7                                | <b>2,00</b>                       |
| Ago-98      | 10600000                       | 231270                        | 3390420                       | 223,4                            | 224,5                                | <b>0,50</b>                       |
| Mar-99      | 11600000                       | 279290                        | 3647690                       | 216,2                            | 216,7                                | <b>0,25</b>                       |
| Abr-00      | 12850000                       | 348280                        | 4016830                       | 208,2                            | 208,0                                | <b>0,11</b>                       |
| Abr-01      | 14640000                       | 403110                        | 4382260                       | 200,7                            | 195,2                                | <b>2,74</b>                       |
| Nov-01      | 15927190                       | 462480                        | 4646620                       | 186,1                            | 186,3                                | <b>0,09</b>                       |
| Dic-01      | 15927190                       | 472170                        | 4681400                       | 182,4                            | 186,8                                | <b>2,43</b>                       |

Fig. XV Comparación entre datos de presión (P) y la predicción de la presión con redes neuronales (BP-RNA) con sus errores relativos.

En la Fig. XVI se observa que los datos de Presión Estática predichos por la RNA tienen un coeficiente de Correlación del 99% con los medidos.



#### II.B.4.3 RNA. ETAPA DE PREDICCIÓN

Se la RNA entrenada y validada para predecir los valores de Presión Estática del Reservorio entre Noviembre 2001 y Enero 2006, tal como se muestra en la Fig. XVII

| DATE   | GP<br>(Km <sup>3</sup> ) | WP<br>(m <sup>3</sup> ) | NP<br>(m <sup>3</sup> ) | P_ANN<br>(kg/cm <sup>2</sup> ) |
|--------|--------------------------|-------------------------|-------------------------|--------------------------------|
| Nov-01 | 15927190                 | 462480                  | 4646620                 | 186,3                          |
| Dic-01 | 15927190                 | 472170                  | 4681400                 | 186,8                          |
| Ago-03 | 20230000                 | 687260                  | 5360550                 | 158,9                          |
| Sep-04 | 23120000                 | 814580                  | 5783590                 | 147,0                          |
| Abr-05 | 24620000                 | 872620                  | 5976670                 | 143,0                          |
| May-05 | 24620000                 | 879980                  | 6004550                 | 147,5                          |
| Dic-05 | 26218865                 | 929010                  | 6176160                 | 142,0                          |
| Ene-06 | 26218865                 | 935260                  | 6201140                 | 147,7                          |

Fig. XVII Valores de Presión estimados por la RNA

En la Fig. XVIII se observan las Presiones Estáticas del yacimiento en función del tiempo en las distintas Etapas de las RNA: Entrenamiento, Validación y Predicción.





Fig. XVIII Presiones Estáticas en las Etapas de Entrenamiento, Validación y Aplicación de la RNA

## II. B. 5 APLICACIÓN DE LA PRESIÓN ESTÁTICA, MEDIDA Y PREDICHA POR LA RNA.

### BALANCE DE MATERIALES

Como se expresó previamente se utilizarán los datos de la Presión Estática, medidos y predichos, para plantear un Balance de Materiales. En las Figs. XIX y XX se muestran las Evoluciones de Producción y Acumulada que se aplicarán en el Balance de Materiales.






Fig. XX Acumuladas de Producción de Gas, Agua y Petróleo

Se plantea la Relación de Balance de Materiales, que considera actuando sobre el petróleo los mecanismos de Empuje de Gas Disuelto en el Petróleo y la Expansión de la formación, el petróleo y del agua.

$$F = N (E_o + E_{f,w})$$

Donde F es el Volumen de Reemplazo por efecto de la Producción.

$$F = N_p(B_o + (R_p - R_s)B_g)$$

$E_o$  es el Factor de Expansión y Empuje por gas Disuelto de la zona de petróleo.

$$E_o = B_o - B_{oi} + (R_{si} - R_s)B_g$$

$E_{f,w}$  es el Factor de compactación de la formación y el agua

$$E_{f,w} = B_{oi} \left( \frac{c_w S_{wc} + c_f}{1 - S_{wc}} \right) \Delta p$$

Si los mecanismos de producción relevantes son los aquí considerados la relación entre F, Volumen de Reemplazo y  $(E_o + E_{f,w})$  Factores de Gas Disuelto y Expansión de Fluidos y Formación, debe ser una recta de pendiente N, el volumen inicial de Petróleo in situ, de lo contrario mostrará apartamientos, que indican que deben incluirse otros mecanismos, como Expansión del Casquete e Intrusión de Agua.

La linealidad que se observa, ver Fig. XXI, entre F y  $(E_o + E_{f,w})$ , con un coeficiente de ajuste del 99%, indica que los mecanismos de producción son los efectivamente actuantes en el yacimiento, que el petróleo inicial in situ, N, es 282.83 MMSTB, y complementariamente que la estimación de presiones de las RNA ha sido exitosa.






Fig. XXI Balance de Materiales

## 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"
- Ingrassia, S.; Morlini, I.: "Neural Network Modeling for Small Datasets". Technometrics, Volume 47, Number 3, August 2005, pp. 297-311(15). Publisher: American Statistical Association.
- Kaviani, D., Bui, T. D., Jensen, J. L. y Hanks, C. L.: "The application of artificial neural networks with small data sets: an example for analysis of fracture spacing in the Lisburne Formation, Northeastern Alaska". SPE 103188 (2007).
- Oyerokun, A., Schlumberger; Thomas, B., Marietta College; Aminian, K., Ameri S., West Virginia University: "Prediction of Flow Units and Permeability Using Artificial Neural Networks", SPE Western Regional/AAPG Pacific Section Joint Meeting, 19-24 May 2003, Long Beach, California Paper Number 83586-MS.
- Galacho, M., Iribarne M., Loss M. L., Vázquez P.A., Lavia M.: "Modelo de Permeabilidades de Reservorios utilizando Redes Neuronales Artificiales e Integración Geoestadística". VI Congreso de Exploración y Desarrollo de Hidrocarburos, IAPG, Mar del Plata, Argentina, Nov. 2005.