

CORRELACIÓN DE REGISTROS ENTRE POZOS CON REDES NEURONALES ARTIFICIALES UTILIZANDO MÚLTIPLES CURVAS O VARIABLES REGISTRADAS

Guillermo Alzate E., John William Branch B., Oscar Mauricio Suárez B. y Carlos Andres Vega S.
Escuela de Procesos y Energía, Facultad de Minas
Universidad Nacional de Colombia, Sede Medellín
gaalzate@unal.edu.co

Recibido para evaluación: 05 de Septiembre de 2006 / Aceptación: 20 de Noviembre de 2006 / Recibida versión final: 30 de Noviembre de 2006

RESUMEN

La correlación de registros entre pozos si se hace del modo tradicional (inspección visual), es una actividad compleja que demanda tiempo y rigurosidad por parte de uno o varios expertos humanos. En este artículo se presenta una herramienta computacional basada en redes neuronales artificiales (RNA) para correlacionar registros entre pozos y los resultados de su aplicación a un caso de campo. Se hace una descripción del proceso de correlacionar curvas de registros entre pozos, y sus exigencias en personal calificado y tiempo, en especial en campos de geología compleja y con un gran número de pozos. Finalmente, se presenta la herramienta de computo desarrollada y su aplicación. Los resultados obtenidos con la herramienta propuesta al aplicarla a cinco pozos, manifiestan un buen desempeño y resulta en una buena y rápida aproximación a los resultados obtenidos por un experto humano en su procedimiento visual de correlación. Esta técnica basada en las RNA presenta buena versatilidad para correlacionar varios tipos de curvas de registros a partir de la identificación en cualquier pozo del campo y/o yacimiento en estudio de un marcador litológico previamente escogido en un pozo de referencia. El resultado final es una herramienta computacional confiable, efectiva y eficaz para realizar el trabajo de correlacionar un marcador estratigráfico de un pozo a otro en un yacimiento de un mismo campo.

PALABRAS CLAVES: Registros de Pozo, Redes Neuronales Artificiales, Correlacion (Estadística).

ABSTRACT

Well logs correlation if it is performed by traditional way (visual inspection) is a complex activity which it takes long time and a rigorous commitment from one or more human experts. This paper presents a computational tool based on artificial neural network (ANN) to correlate logs among wells and also the results for a field study case. It is presented the process of well logs correlation and its requirements of qualified people and time specially for hydrocarbon reservoirs with complex geology and many wells. Finally, it is presented a computational tool and its application. The final results for a five wells' logs study case show a good performance, a fast and close approach to the results obtained by an human expert using the conventional visual inspection procedure. The developed tool based on ANN presents good versatility to correlate several well log curves beginning from the identification in any well of oilfield or reservoir of a lithologic marker previously picked on a reference well. The final result is a reliable and effective computer tool to correlate a stratigraphic marker from a well to another one in a hydrocarbon reservoir or oilfield.

KEY WORDS: Well Logs, Artificial Neural Network, Correlation (Statistics).

1. INTRODUCCIÓN

En la exploración y desarrollo de reservas de hidrocarburos, los registros de pozo y su correlación se constituyen en herramientas fundamentales en la evaluación y caracterización del yacimiento (Bassiouni, 1994; Ryder, 1996; Serra 1985). Los registros de pozos permiten la valoración de ciertas características y propiedades de las formaciones que son atravesadas por un pozo. Entre las principales características que se pueden valorar a partir de los registros de pozo se tienen la resistividad, nivel de saturación de agua, grado de consolidación, porosidad, litología, etc. De otro lado, la correlación de registros entre pozos consiste en establecer comparaciones entre los patrones de comportamiento de las curvas en los registros para un punto o zona específica en el hueco registrado con el fin de establecer la continuidad, espesor, y movimientos estructurales de las diferentes formaciones de interés a lo largo y ancho de la estructura en exploración y explotación (Dienes, 1974; Ruiz, 1996; Valle y Pérez, 1976). Las curvas más utilizadas en los procesos de correlación entre pozos y la generación de secciones estructurales son los registros de rayos gamma y microresistividad.

En la medida que aumenta la extensión delimitada de un yacimiento y el número de pozos perforados, el grupo de geología de exploración y desarrollo requiere técnicas de correlación más rápidas, precisas, y de carácter automático. La correlación de los registros entre pozos en forma convencional se realiza en forma artesanal a partir del reconocimiento visual de patrones por parte de un experto humano, lo que implica una larga y tediosa tarea, con el agravante de la menor disposición de este tipo de personal en las compañías operadoras.

Las RNA proveen un camino rápido y práctico para llegar a una solución óptima y confiable en un proceso de reconocimiento de patrones en registros de pozos (Edwards y Einstein, 1990; Gill, 1970; Hassibi y Ershaghi, 1999; Hawkins y Merrian, 1974; Lim y Kang, 1999; Startzman y Kuo, 1987; Shaw y Cubbit, 1979; Olea y Davis, 1986; Olea, 1994). Este trabajo corresponde a una segunda etapa en la solución al problema planteado, la cual consiste en el desarrollo de una herramienta de inteligencia computacional basada en Redes Neuronales Artificiales (RNA) para realizar la correlación de registros entre pozos, mediante el uso de dos (2) curvas o variables registradas, la curva de rayos Gamma (GR) y la curva de microresistividad, lo cual establece la diferencia fundamental con respecto a la primera etapa desarrollada por Coronel y Parra (Coronel y Parra, 2003).

2. DESCRIPCIÓN DEL PROBLEMA

En la industria del petróleo, la adquisición de datos del subsuelo mediante la operación de adquisición de registros en hueco abierto o entubado, e incluso durante la operación misma de la perforación, es una de las operaciones que más tiempo y dinero demandan. A la par con la actividad de obtener los registros, se presenta la actividad de interpretar dichos registros por parte de un experto humano. La interpretación de los registros es un proceso largo y complejo, y que está relacionada con el tipo de información que se pretende extraer de estos, de las herramientas disponibles para el manejo de la información, y la disponibilidad de personal calificado para desarrollar dicha actividad. El uso combinado de las diferentes curvas o trazas generadas en el proceso de registro de un pozo y su correlación entre los diferentes pozos perforados en un yacimiento, hace posible:

- Definir los límites de extensión de un yacimiento, y de las diferentes formaciones en la columna estratigráfica,
- Generar modelos geológicos para el yacimiento, para usar en etapas futuras de explotación en un campo y evitar su abandono prematuro.

Al correlacionar los registros entre pozos, los geólogos primero identifican en la sección registrada de la columna estratigráfica, patrones característicos, también conocidos como *marcadores*, que son de fácil identificación; y luego buscan su correspondencia entre los diferentes pozos para cada dirección específica de análisis. Por encima y por debajo de los marcadores principales también se pueden identificar otros marcadores cuya correlación sea consistente con las correlaciones laterales de los marcadores principales.

Esta actividad es intensiva en el tiempo, y aún más en presencia de complejidades y complicaciones geológicas que conllevan a la reexaminación de las correlaciones previas y a cambiar marcadores ya establecidos, con el fin de asegurar que efectivamente se han identificado el ó los marcadores en cada uno de los registros del pozo.

Para llevar a cabo un buen proceso de correlación, se debe conocer acerca de diferentes temáticas en geología y evaluación de formaciones, como lo son: ambientes de sedimentación, principios de adquisición de registros y sus medidas, fundamentos de ingeniería de yacimientos, geología de desarrollo y análisis de registros (cualitativos y cuantitativos).

Por lo tanto, es relevante generar e implementar una herramienta capaz de reducir en forma considerable el tiempo empleado por un experto humano para correlacionar registros, y además, ser capaz de emular, en algún grado, el comportamiento intuitivo en la búsqueda de una solución confiable.

El propósito de este trabajo es presentar una técnica que realmente sería una “aproximación” de lo que haría un experto humano en el procedimiento de correlación. La herramienta desarrollada tiene la versatilidad de correlacionar varios tipos de registros, y a modo de ejemplo se presenta su aplicación para el caso de utilizar dos (2) curvas, la de rayos gamma y la de microresistividad. El resultado final es una herramienta computacional, confiable, efectiva y eficaz, para realizar el trabajo de correlacionar un marcador estratigráfico de un pozo a otro en un mismo yacimiento, y que traslada el razonamiento del experto humano de reconocimiento de patrones a un código de computador. La aplicación se programó en la plataforma MATLAB 6.5.

3. CORRELACIÓN DE REGISTROS ENTRE POZOS

La correlación de registros entre pozos pretende establecer y visualizar la extensión lateral de las formaciones de interés, y la relación espacial entre estas a lo largo y ancho del campo a partir del reconocimiento de patrones en las diferentes trazas o curvas para zonas específicas de la sección registrada.

El proceso de correlación de registros entre pozos se inicia con la selección de un “*datum*”, o marcador, el cual puede ser ubicado y distinguido a través de todos los puntos de observación, pozos en el campo y/o yacimiento. En general, un buen *datum* lo constituyen las denominadas lutitas, pues aparecen sobre extensas zonas por encima y/o por debajo de las formaciones de interés, y además, las lutitas son depósitos de baja energía que se asumen han sido depositadas en su mayoría en forma horizontal, y por lo tanto se constituyen en un verdadero plano de estratificación.

Una vez seleccionado el *datum* se eligen en el mapa del campo pozos representativos para una mejor interpretación de la estratigrafía del área y con ellos se orienta la línea del corte o dirección en la cual se haría la correlación. Esta línea es la representación de un plano vertical (sección), donde se proyectaran los pozos. Luego, en la sección se colocan con su distancia a escala las curvas o registros de pozos para los pozos elegidos, y se relacionan a partir de la línea de referencia o *datum*. Estas secciones destacan las diferencias en distancia vertical y espesor para las formaciones por encima y por debajo del plano de referencia o *datum* utilizado. Al realizar lo anterior, se ignoran todos los posibles movimientos estructurales a los cuales la secuencia ha sido expuesta. Después se pueden correlacionar todos los eventos abajo o arriba del plano *datum* comparando las respuestas en los registros.

4. CORRELACION DE REGISTROS MEDIANTE REDES NEURONALES ARTIFICIALES (RNA)

Para aplicar la técnica de las RNA a la correlación de registros de pozos, en general, se requiere de los siguientes pasos:

**Horizonte o marcador principal, de amplia extensión lateral.*

- Clasificación de los datos,
- Preprocesamiento de la información,
- Entrenamiento de la RNA,
- Validación,
- Prueba de la RNA.

Clasificación de los datos. Es fundamental definir los datos, y de estos seleccionar los que conformarían los conjuntos de entrenamiento, de validación, y de prueba. Para el caso en cuestión, la información disponible proveniente de los registros de cinco (5) pozos se subdividió en los tres conjuntos de información, tres (3) pozos en la etapa de entrenamiento, un (1) pozo para la etapa de validación, y un (1) pozo para la etapa de prueba.

Preprocesamiento de la información. El tratamiento de los datos de entrada antes de alimentar a la RNA consta de los siguientes pasos:

- Selección de datos con alta resolución vertical.** La resolución de las señales en los registros de pozos es uno de los aspectos más importantes para discriminar patrones litológicos diferentes y definir con claridad los límites de los estratos. Las herramientas de registro deben ser sensitivas a pequeños cambios en la estructura sedimentaria en una formación, la falta de precisión conducirá a deficiencias en las interpretaciones. Para el caso de aplicación en este estudio, los datos de entrada corresponden a los registros de rayos gamma y microresistividad adquiridos en pozos de un mismo campo.
- Fijación del tamaño de la ventana de deslizamiento.** La ventana de deslizamiento es una ventana imaginaria de longitud fija que se desliza a lo largo del registro durante el proceso de “suavización”. El desplazamiento de la ventana entre paso y paso está controlado por la diferencia en profundidad entre datos consecutivos. Con respecto al tamaño de la ventana no hay un criterio específico para definirlo, y en el caso de estudio se estableció el tamaño de ventana de acuerdo con el espesor promedio del marcador en los pozos del conjunto de entrenamiento más dos pies, uno por encima del techo y otro por debajo del piso del marcador, que representan las vecindades del mismo. En la Figura 1 se presenta un esquema que muestra el recorrido de la ventana de deslizamiento a lo largo de la sección del registro bajo análisis.

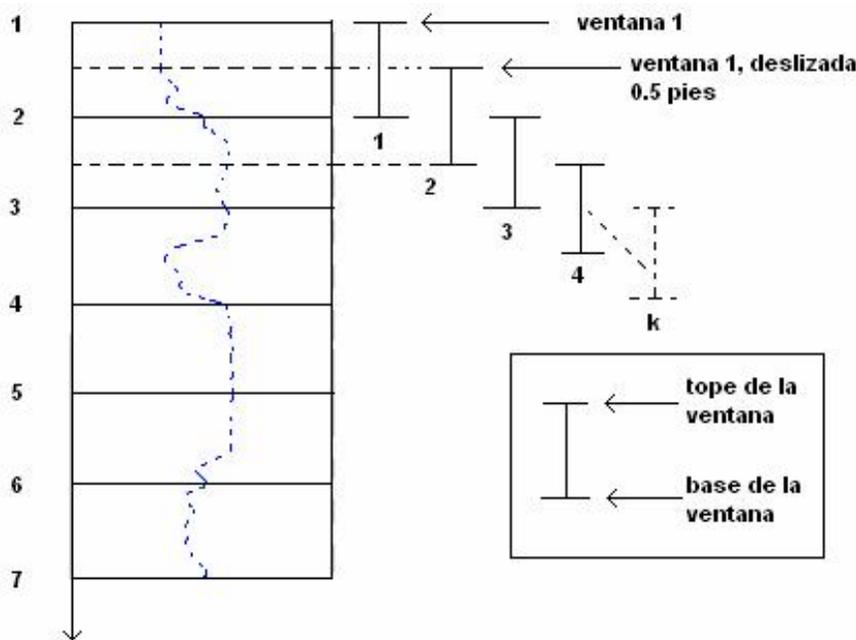


Figura 1. Representación de la ventana de deslizamiento.

iii. *Normalización de los datos de cada ventana de deslizamiento en el registro.* En principio se consideró la posibilidad de estandarizar los datos en ambos registros, pero los registros de microresistividad presentan muchos datos atípicos, lo que resulta en una desviación estándar muy alta y por ende un conjunto de datos estandarizados en exceso pequeños. Por lo tanto, se procedió con la normalización de los datos de entrada mediante la aplicación de la ecuación (1), lo que resulta en un conjunto de datos de entrada a la RNA cuyos valores se encuentran en el rango entre cero (0) y uno (1). Este proceso provee un rango de valores más apropiado para los procesos de reconocimiento de patrones por sistemas tipo RNA, y para las cuales es mucho más fácil reconocer patrones si estos están en un mismo rango de magnitud.

$$X_n = \frac{X_o - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

Donde:

X_{\min} : mínimo valor de los datos a normalizar,

X_{\max} : máximo valor de los datos a normalizar,

X_o : valor del dato a normalizar,

X_n : valor normalizado de X_o .

iii. *Selección del criterio de suavizado de los datos normalizados.* La presencia de ruido en los registros o datos de entrada reduce la calidad de la información y también la confiabilidad de los resultados. La presencia de “ruido” resulta en falsas interpretaciones de los rasgos característicos de la formación. La técnica de suavizado de los datos normalizados de los registros consistió en el ajuste de los datos a funciones tipo serie de Fourier.

A modo de ejemplo, se tiene un registro de pozo con datos en un determinado intervalo de profundidad y con datos cada 0.5 pies. A este registro se le hace un barrido cada 0.5 pies mediante una ventana de deslizamiento de un pie de longitud. Se toma la primera ventana tal como se muestra en la figura 1, y los datos se normalizan. Para los datos normalizados de esta primera ventana, y para cada ventana de deslizamiento, se obtienen los coeficientes de Fourier que en forma consecutiva conforman las filas de la matriz de ventanas. El primer dato de cada fila de la matriz de ventanas hace referencia a la profundidad del tope de la ventana.

El procedimiento descrito continúa hasta que la base o fondo de la ventana haya alcanzado el último valor de profundidad en el registro en evaluación. El número de columnas de la matriz de ventanas dependerá del número de armónicos especificado en la serie de Fourier, y el número de filas dependerá del número de deslizamientos que requiere la ventana para recorrer la sección bajo análisis. Para el caso de estudio, la matriz de ventanas se presenta en la ecuación (2).

$$V_i = \begin{bmatrix} h^1 & a_0^1 & a_1^1 & \cdots & a_n^1 & b_1^1 & \cdots & b_n^1 \\ h^2 & a_0^2 & a_1^2 & \cdots & a_n^2 & b_1^2 & \cdots & b_n^2 \\ h^3 & a_0^3 & a_1^3 & \cdots & a_n^3 & b_1^3 & \cdots & b_n^3 \\ h^4 & a_0^4 & a_1^4 & \cdots & a_n^4 & b_1^4 & \cdots & b_n^4 \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots & \cdots & \vdots \\ h^k & a_0^k & a_1^k & \cdots & a_n^k & b_1^k & \cdots & b_n^k \end{bmatrix} \quad (2)$$

Donde:

V_i^z : matriz de ventanas del pozo i ,

h_k : profundidad del tope de la ventana k ,

a_n^k, b_n^k : coeficientes de Fourier de la ventana k .

Entrenamiento de la RNA. El preprocesamiento descrito se aplica a los pozos del conjunto de entrenamiento, de tal forma que a cada pozo del conjunto entrenamiento le corresponde una matriz de ventanas. Luego, se procede a identificar en la matriz de ventanas las filas que corresponden al marcador sugerido por el experto humano, y al no marcador sugerido en este trabajo. Una vez identificadas tales filas, se asigna vector M para los coeficientes de Fourier del marcador, y otro vector NM para los coeficientes de Fourier correspondientes al no marcador. Si el número de pozos del conjunto entrenamiento es tres, entonces deberían asignarse seis vectores, dos por cada pozo como lo muestra el sistema de vectores en la ecuación (3). Este sistema de vectores es fundamental para el entrenamiento de la red.

$$\begin{matrix}
 M_1 & NM_1 & M_2 & NM_2 & M_3 & NM_3
 \end{matrix}$$

$$\left[\begin{array}{c}
 a_{0GR}^1 \\
 a_{1GR}^1 \\
 \vdots \\
 a_{nGR}^1 \\
 b_{1GR}^1 \\
 \vdots \\
 b_{nGR}^1 \\
 a_{0MR}^1 \\
 a_{1MR}^1 \\
 \vdots \\
 a_{nMR}^1 \\
 b_{1MR}^1 \\
 \vdots \\
 b_{nMR}^1
 \end{array} \right]
 \left[\begin{array}{c}
 a_{0GR}^2 \\
 a_{1GR}^2 \\
 \vdots \\
 a_{nGR}^2 \\
 b_{1GR}^2 \\
 \vdots \\
 b_{nGR}^2 \\
 a_{0MR}^2 \\
 a_{1MR}^2 \\
 \vdots \\
 a_{nMR}^2 \\
 b_{1MR}^2 \\
 \vdots \\
 b_{nMR}^2
 \end{array} \right]
 \left[\begin{array}{c}
 a_{0GR}^3 \\
 a_{1GR}^3 \\
 \vdots \\
 a_{nGR}^3 \\
 b_{1GR}^3 \\
 \vdots \\
 b_{nGR}^3 \\
 a_{0MR}^3 \\
 a_{1MR}^3 \\
 \vdots \\
 a_{nMR}^3 \\
 b_{1MR}^3 \\
 \vdots \\
 b_{nMR}^3
 \end{array} \right]
 \left[\begin{array}{c}
 a_{0GR}^4 \\
 a_{1GR}^4 \\
 \vdots \\
 a_{nGR}^4 \\
 b_{1GR}^4 \\
 \vdots \\
 b_{nGR}^4 \\
 a_{0MR}^4 \\
 a_{1MR}^4 \\
 \vdots \\
 a_{nMR}^4 \\
 b_{1MR}^4 \\
 \vdots \\
 b_{nMR}^4
 \end{array} \right]
 \left[\begin{array}{c}
 a_{0GR}^5 \\
 a_{1GR}^5 \\
 \vdots \\
 a_{nGR}^5 \\
 b_{1GR}^5 \\
 \vdots \\
 b_{nGR}^5 \\
 a_{0MR}^5 \\
 a_{1MR}^5 \\
 \vdots \\
 a_{nMR}^5 \\
 b_{1MR}^5 \\
 \vdots \\
 b_{nMR}^5
 \end{array} \right]
 \left[\begin{array}{c}
 a_{0GR}^6 \\
 a_{1GR}^6 \\
 \vdots \\
 a_{nGR}^6 \\
 b_{1GR}^6 \\
 \vdots \\
 b_{nGR}^6 \\
 a_{0MR}^6 \\
 a_{1MR}^6 \\
 \vdots \\
 a_{nMR}^6 \\
 b_{1MR}^6 \\
 \vdots \\
 b_{nMR}^6
 \end{array} \right]
 \tag{3}$$

pozo 1
pozo 2
pozo 3

La fase final del *entrenamiento*, consiste en identificar las posibles combinaciones de a dos vectores (sin reciprocidad) que se puedan dar en el anterior sistema. Así, las dos clases de combinaciones que se pueden presentar son marcador - marcador, no marcador - marcador. A la primera clase se asigna un valor binario de uno (1), y para la segunda un valor de cero (0). Con los vectores del sistema se realizan las posibles combinaciones de acuerdo con los tipos de combinaciones permitidos. Finalmente se obtiene un vector de 18 valores binarios producto de tales combinaciones. Estos valores binarios son las salidas deseadas de la RNA. En la Tabla 1 se muestran las combinaciones de vectores con las respectivas salidas asignadas.

Tabla 1. Combinación de vectores con sus respectivas salidas deseadas.

Combinatoria de vectores	Valor asignado
1 vs 1	1
1 vs 3	1
1 vs 5	1
2 vs 1	0
2 vs 3	0
2 vs 5	0
3 vs 1	1
3 vs 3	1
3 vs 5	1
4 vs 1	0
4 vs 3	0
4 vs 5	0
5 vs 1	1
5 vs 3	1
5 vs 5	1
6 vs 1	0
6 vs 3	0
6 vs 5	0

Consolidación de la RNA final. Se implementó una red con regla de aprendizaje supervisado de tipo feed-forward backpropagation, es decir, una red con conexiones hacia delante que utiliza la regla de aprendizaje retropropagación de errores. La mejor arquitectura que se obtuvo fue la de dos capas ocultas con once y trece neuronas respectivamente. Las funciones de transferencia implementadas en las capas fueron *lineal de saturación*, *lineal*, *Logsigmoidal* *logarítmica*. Se implementó como función de entrenamiento la *resilient backpropagation*. En la Tabla 2 se resume la arquitectura conseguida para la RNA.

Tabla 2. Arquitectura de la RNA.

Capa	Número de neuronas	Función de transferencia
1	1	Lineal de saturación
2	11	Lineal
3	13	Lineal
4	1	Logsigmoidal

Válidación de la RNA. Después del proceso de entrenamiento los pesos de las conexiones en la red neuronal quedan fijos. Es importante comprobar la calidad del modelo resultante, es decir, se debe comprobar si la red neuronal puede resolver nuevos problemas del tipo general, para los que ha sido entrenada. Por lo tanto, con el propósito de validar la red neuronal se requiere de otro conjunto de datos denominado *conjunto de validación*. Este conjunto está compuesto por uno o varios pozos que no pertenezcan al conjunto de entrenamiento, y para estos pozos la profundidad del marcador sugerida por el experto humano debe conocerse. La validación de la RNA requiere establecer un criterio de decisión basado en la diferencia entre la profundidad obtenida por la red (la ventana con mayor grado de correlación) y la sugerida por el experto humano. En caso de no validar la RNA se procede a cambiar su arquitectura.

Prueba de la RNA. En la prueba de la RNA se evalúa el desempeño de la red al aplicarla a los pozos de un *conjunto de prueba*. Para el proyecto en cuestión, y dada la escasez de información para realizar la prueba, se evalúa el desempeño de la RNA con toda la información disponible.

5. CASO DE ESTUDIO – APLICACIÓN RNA

Esta sección presenta los resultados de la aplicación de la RNA diseñada y ajustada en la correlación de registros entre pozos. Esta red se diseñó para aplicarse a un conjunto de pozos de cualquier campo, y en particular, se presentan los resultados obtenidos para un campo en Colombia. Con la información de registros para los pozos disponibles, se creó una base de datos conformada por la profundidad y los valores de los registros de rayos gamma y microresistividad. Esta base de datos fue dividida en los tres conjuntos independientes: entrenamiento, validación y prueba.

Para el campo en estudio, se tomó una muestra de cinco pozos, con tres pozos como *pozos de entrenamiento*. En cada uno de estos pozos se identificaron, mediante la matriz de ventanas, las dos ventanas correspondientes al marcador y no marcador. Los dos pozos restantes de la muestra se tomaron como *pozos vecinos*, uno para *validación* y otro para *prueba*.

Para proceder con la correlación, es necesario identificar el marcador geológico presente en el campo, a partir del conocimiento de las formas tipo de tales marcadores en el registro. El marcador debe poseer características geológicas que le permita ser observado en una amplia extensión lateral y/o en cada uno de los pozos de estudio.

En el caso de estudio, se identificó un estrato de *lutita* que manifiesta una alta radioactividad natural y que presenta respuestas en el registro de rayos gamma que oscilan entre 120 y 190 unidades API. Este marcador presenta en el registro de microresistividad una respuesta muy baja que oscila entre 1 y 23 ohm.m.

Debido a las características estratigráficas y de ambiente marino de depositación, para las formaciones involucradas en el caso de estudio, se requiere utilizar registros de pozo que faciliten una adecuada descripción de los estratos y de sus características litológicas. En concordancia, la correlación se efectuó con base en los registros de rayos gamma y de microresistividad, este último por su alta resolución se constituye en el registro preferido para los propósitos de correlación litoestratigráfica.

En cuanto al desarrollo e implementación de la herramienta de correlación, se desarrolló un programa en *MatLab 6.5*, el cual a través de la ventana de deslizamiento de longitud fija, 20 pie, realiza el barrido de la matriz de información. Esta matriz está constituida por tres columnas, de las cuales la primera corresponde a la profundidad del registro, la segunda y tercera a las respectivas lecturas de rayos gamma y microresistividad. Para cada posición de la ventana en el registro, el programa preprocesará la información antes de pasar a alimentar la RNA.

La Tabla 3 presenta la profundidad de los sectores marcadores y no marcadores para cada uno de los pozos utilizados. La información acerca de las zonas no-marcadores es útil sólo en los pozos que constituyen el conjunto de entrenamiento.

Tabla 3. Profundidad de los marcadores y no marcadores.

Conjunto	Pozo	Sector (pies)	Tope Marcador (pies)	Tope No Marcador (pies)
Entrenamiento	X-1	10463.5 -10574.5	10549.5	10470
	X-2	10500 -10680	10595	10570
	X-3	10540 -10820	10699	10685
Validación	X-4	10655 - 10885	10785	
Prueba	X-5	10450 - 10680	10576.5	

Una vez ajustada la estructura de la RNA, se ejecuta el programa con la información proveniente de los pozos que integran el conjunto de validación. Los resultados que integran el archivo de salida del programa para cada pozo están representados por una matriz de dos columnas. La primera columna contiene los datos correspondientes a las profundidades de los topes de la ventana de deslizamiento, y la segunda acerca del grado de correlacion (entre 0 y 1) entre la ventana de deslizamiento y la ventana correspondiente al marcador del pozo de referencia. Es decir, se presenta información acerca del grado de similitud entre la ventana que contiene el marcador para la zona y la ventana bajo estudio en cada pozo del conjunto de validación. Las Figuras 2 a 6 presentan los resultados de la RNA para los cinco pozos utilizados como conjunto de prueba. Los resultados son diagramas del grado de correlación con profundidad, donde se especifican las profundidades en las cuales se logra un grado de correlación entre ventanas mayor que 95%. A partir de estos diagramas se identifica la ventana que según la RNA corresponde al marcador (lutita) y a sus vecindades, por encima y por debajo. Para esta identificación se propone sólo considerar casos en los cuales el grado de correlación sea mayor a 0.995 (99.5%).

6. ANÁLISIS DE RESULTADOS

Para el pozo X-1, Figura 2, la red reconoció una sección a 10548.5 pies con alto grado de correlacion y que presenta correspondencia con la ventana marcadora propuesta por el experto humano. El margen de error en la identificación fue de 1 pie con respecto a la ventana marcadora propuesta por el experto humano.

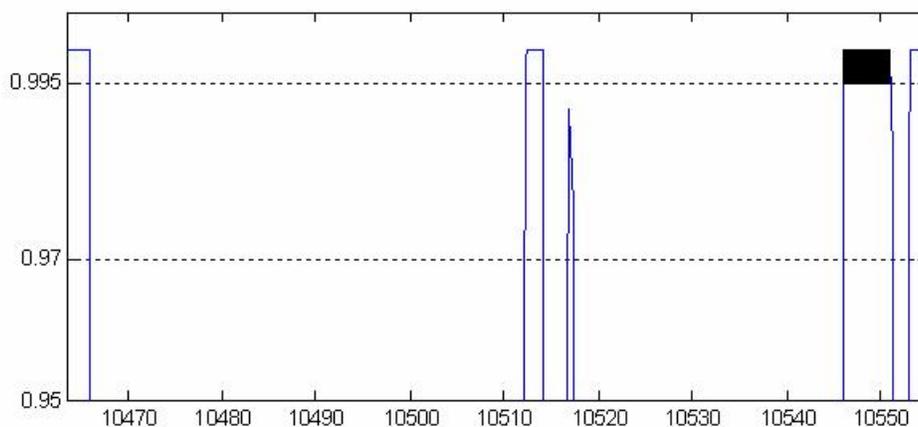


Figura 2. Grado de correlación en función de la profundidad de la ventana, pozo X-1.

Para el pozo X-2, la red reconoció una sección a 10595 pies, Figura 3, la cual presenta un alto grado de correlación y coincide con la ventana marcadora preestablecida por el experto humano con diferencia de 1.75 pies.

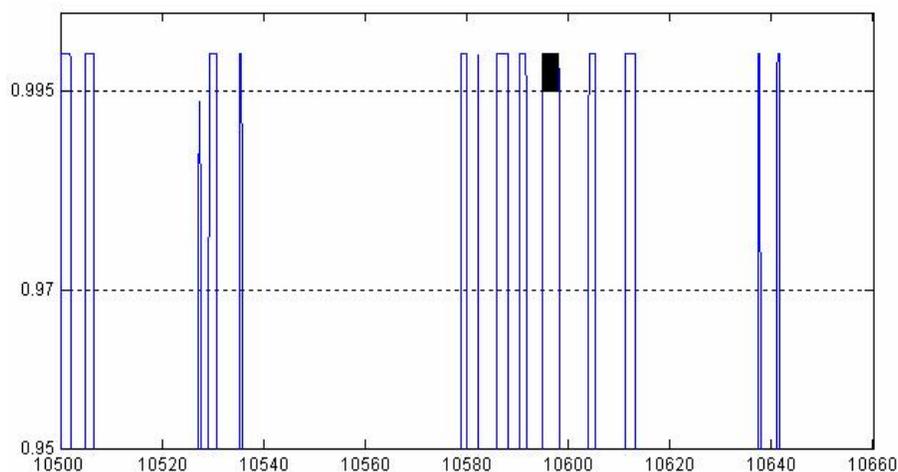


Figura 3. Grado de correlación en función de la profundidad de la ventana, pozo X-2.

Para el pozo X-3, Figura 4, ubicado en la zona sur del campo en estudio, se detectaron tres secciones con posibilidad de ser la ventana marcadora propuesta por el experto humano a las profundidades de 10571.5 pies, 10689.75 pies, y 10697.5 pies, respectivamente. Sin embargo, la ventana marcadora propuesta por el experto humano está a 10699 pies, que se encuentra más cercana a la tercera ventana ubicada por la RNA. A pesar de que la red arrojó mayor probabilidad para la primera ventana, se puede ver claramente en el gráfico que hay gran cantidad de inflexiones que son clasificadas como la ventana marcadora como resultado de la constante presencia de lutitas intercaladas.

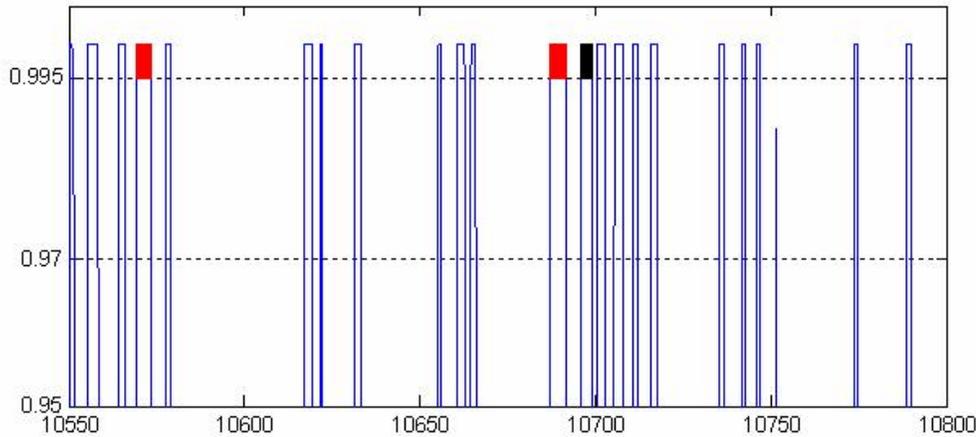


Figura 4. Grado de correlación en función de la profundidad de la ventana, pozo X-3.

Para el pozo X-4, la red detectó cuatro ventanas como posibles marcadores, Figura 5. La ventana marcadora sugerida por el experto humano a 10785 pies, coincide con una de las cuatro ventanas, con un pequeño desfase de 0.25 pies. Este pozo fue el mejor en cuanto al desempeño de la red.

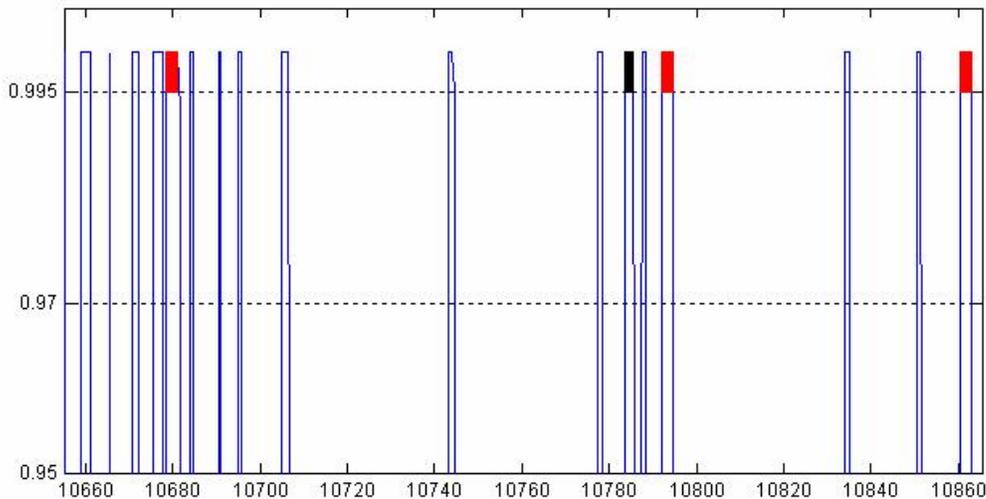


Figura 5. Grado de correlación en función de la profundidad de la ventana, pozo X-4.

Para el pozo X-5, la red detectó dos posibles secciones con posibilidad de ser el marcador propuesto por el experto humano. Una a 10523.5 pies y otra a 10575.25 pies. Sin embargo, la red mostró mayor correlación en la segunda como se muestra en la Figura 6. La selección de la segunda ventana como la mejor aproximación al marcador se determina por el grado de acercamiento en distancia, 1.25 pies.

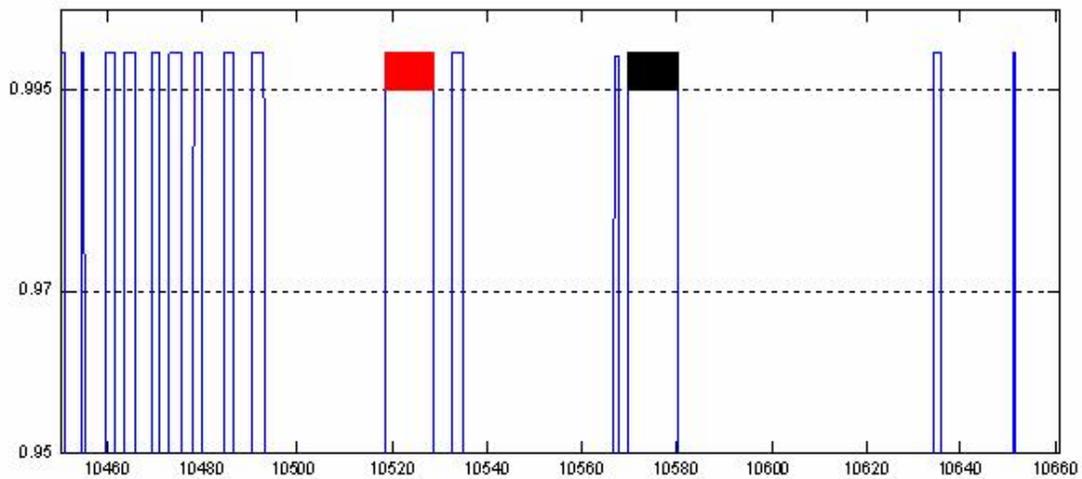


Figura 6. Grado de correlación en función de la profundidad de la ventana, pozo X-5.

En la Tabla 4 se resumen los resultados obtenidos para la correlación de los registros de los cinco pozos que conforman el caso en estudio. Para cada pozo se presenta la profundidad del tope de la ventana que contiene el marcador determinada por la RNA en este estudio; también se presenta la profundidad preestablecida por un experto humano, y la diferencia en pies entre el dato del experto y el dato de la RNA para la RNA en este estudio y la que presentan Coronel y Parra (2003).

Tabla 4. Profundidad establecida para los marcadores por la RNA.

Pozo	Profundidad RNA (pies)	Profundidad Experto Humano (pies)	Diferencia (pies)	Diferencia (pies)
X-1	10548.50	10549.50	1.00	3.00
X-2	10596.75	10595.00	1.75	2.50
X-3	10571.50	10699.00	127.5	3.0
	10689.75		9.25	
	10697.50		1.50	
X-4	10680.00	10785.00	105.0	0.25
	10784.50		0.50	
	10793.25		8.25	
X-5	10861.75	10576.50	76.75	1.25
	10523.50		53.0	
	10575.25		1.25	

7. CONCLUSIONES

- La RNA configurada logró aprender a reconocer en cada pozo el marcador geológico preestablecido por el experto humano, aún en presencia de considerables cambios laterales.
- El modelo neuronal programado resultó en una herramienta muy versátil para la correlación de las curvas de rayos gamma y microresistividad. Es una herramienta práctica, rápida y eficaz para correlacionar patrones marcadores presentes en los registros de pozo.
- El criterio de suavización de los datos en los registros por series de Fourier resultó apropiado, el ajuste y representación de los marcadores por este criterio redujo la dimensionalidad de los datos sin perder información significativa presente

en los datos originales del registro de rayos gamma y microresistividad.

- Al comparar los resultados con el modelo RNA en este estudio con los obtenidos por un modelo RNA similar pero que utiliza una sola curva (Coronel y Parra, 2003), se concluye que la precisión de la correlación con RNA aumenta al usar un mayor número de curvas de información de entrada al proceso de correlación.
- Aunque en este estudio el número de pozos que integran el conjunto de entrenamiento fue menor al utilizado por Coronel y Parra (2003), los resultados obtenidos muestran mejor precisión en cuanto a la profundidad del marcador preestablecido por el experto humano, aunque en algunos casos aumentó el número de sectores en los registros como posibles candidatos a marcadores.

8. BIBLIOGRAFÍA

- Bassiouni, Z., 1994. Theory, measurement, and interpretation of well logs. Society of Petroleum Engineers (SPE) Textbook. 372 P.
- Coronel, J. y Parra, W., 2003. Correlación de registros entre pozos usando redes neuronales artificiales. Tesis de grado, Ingeniería de Petróleos, Universidad Nacional de Colombia, sede Medellín, 123 P.
- Dienes, I., 1974. General formulation of the correlation problem and its solution in two special situations. *Mathematical geology*, No.1, pp.73-81.
- Edwards, K. y Einstein, E., 1990. Comparison of an expert system to human experts in well log analysis and interpretation. *SPE Formation Evaluation*, March, pp. 39 – 45.
- Gill, D., 1970. Application of statistical zonation method to reservoir evaluation and digitized log analysis. *AAPG Bulletin*, No.5, pp. 719-729.
- Hassibi, M. y Ershaghi, I., 1999. Reservoir heterogeneity mapping using an automated pattern recognition approach. *Artículo SPE (Society of Petroleum Engineers) 56818*, 10 P.
- Hawkins, D.M. y Merriam, D.F., 1974. Zonation of multivariate sequences of digitized geologic data. *Mathematical Geology*, No.3, pp. 263-269.
- Lim, J.S. y Kang, J.M., 1999. Interwell log correlation using artificial intelligence approach and multivariate statistical analysis. *Artículo SPE 54362*, 9 P.
- Olea, R. y Davis, J., 1986. An Artificial approach to lithostratigraphic correlation using geophysical well log. *Artículo SPE 15603*, 12 P.
- Olea, R., 1994. Expert systems for automated correlation and interpretation of wireline logs. *Mathematical Geology*, Vol. 26, No. 8, pp. 879 – 897.
- Ruiz, O. D., 1996. Métodos básicos de correlación estratigráfica. Facultad de Ciencias. Universidad Nacional de Colombia, sede Medellín.
- Ryder, M., 1996. The geological interpretation of well logs. Hasted press, New York.
- Serra, O., 1985. Análisis de ambientes sedimentarios mediante perfiles de pozos. Schlumberger Technical Services.
- Shaw, P. y Cubbit, J.M., 1979. Stratigraphic correlation of well logs and other method automated approach. *Geomathematical and petrophysical studies in sedimentology publication*, pp. 127-148.
- Startzman, R.A. y Kuo, T.B., 1987. A rule-based system for well log correlation. *SPE, Formation Evaluation*, September, pp. 311 – 319.
- Valle, V. y Pérez, J., 1976. Marcas eléctricas de correlación geológica y su identificación. *Revista del Instituto Mexicano del Petróleo*, Vol. 8, No. 3, pp. 42 – 64.

