

EXPR-2-RB-05

CLASIFICACIÓN DE DATOS GEOFÍSICOS MEDIANTE EL USO DE ATRIBUTOS SÍSMICOS NO CONVENCIONALES Y REDES NEURONALES

Rafael E. Banchs*, Juan R. Jiménez, Alejandro Valenciano, David Márquez

PDVSA Intevep, Venezuela

SUMARIO

Se describe una metodología para la clasificación de datos geofísicos mediante el entrenamiento y uso de redes neuronales. Este método puede ser utilizado en diversos dominios para identificar patrones o clases de datos asociados a ciertos puntos de control (datos de pozo) con el fin de clasificar un volumen completo a partir de la información disponible (atributos sísmicos). El método presentado pertenece a la categoría de métodos de aprendizaje supervisado, por lo cual se requiere que las clases a ser identificadas sean conocidas en un subconjunto del volumen de datos (puntos de control). El método descrito es ilustrado con tres aplicaciones específicas a datos reales.

INTRODUCCIÓN

Las técnicas de clasificación y estimación de propiedades constituyen insumos de suma importancia en el proceso de caracterización y monitoreo de yacimientos. Debido a la gran complejidad de los fenómenos físicos relacionados a la medición de parámetros en el subsuelo, la información geofísica no siempre provee respuestas claras y directas a los ingenieros de yacimiento. Es por esta razón que la edición y el procesamiento de los datos se hace necesaria con el fin de transformar los datos a otros dominios en los cuales la información de interés puede ser extraída en una forma más eficiente.

Este trabajo describe una metodología de clasificación de facies sísmicas y/o propiedades litológicas que puede ser utilizada en diversos dominios para identificar patrones o clases con el fin de clasificar un volumen de datos completo. El método aquí presentado pertenece a la categoría de métodos de aprendizaje supervisado, por lo cual se requiere que las clases a ser identificadas sean conocidas en un subconjunto de los datos (generalmente información de pozo).

El uso del método es ilustrado con aplicaciones a datos reales en tres campos petroleros de Venezuela. En el primer ejemplo se realizó una clasificación litológica a partir de los resultados obtenidos en una inversión multicomponente en una sección sísmica arbitraria. En el segundo ejemplo se realizó una clasificación de tipos de arena a partir de los resultados de un análisis fractal basado en ondículas de los datos sísmicos en un horizonte de interés. En el tercer ejemplo se realizó una clasificación de facies litológicas a partir de los resultados de un análisis multifractal de registros de pozo.

REDES NEURONALES PARA CLASIFICACIÓN

El término red neuronal tiene su origen en las similitudes estructurales existentes entre este tipo de procesadores y los sistemas neuronales biológicos. Dependiendo del tipo de aplicación y/o la configuración de la red, existen distintos tipos de redes neuronales. Uno de los tipos más populares de redes neuronales, y que se propone en el presente trabajo como alternativa para el problema de clasificación, es el comúnmente conocido como perceptrón de capas múltiples (Haykin, 1994). La figura 1 ilustra este tipo de red.




Figura 1: Perceptrón de capas múltiples.

El caso particular del perceptrón de capas múltiples presentado en la figura 1, consta de tres capas con tres neuronas, o unidades de procesamiento, cada una. En general, tanto el número de capas a ser utilizado como el número de neuronas en las capas escondidas dependerán del grado de complejidad del problema en consideración. El ajuste de estos parámetros constituye un problema no resuelto, el cual en la práctica se lleva a cabo mediante ensayo y error. Por otra parte, el número de entradas y salidas dependen de los parámetros de información a partir de los cuales se desea realizar la clasificación y del número de clases que se desean identificar, respectivamente.

En este tipo de clasificador las funciones de activación de todas las neuronas de la capa de salida son reemplazadas por una función umbral que exhibe dos únicos posibles valores de salida: activo o inactivo. De esta forma cada una de las neuronas de la capa de salida representa una clase, y su estado de actividad o inactividad es correspondido con la identificación o no de dicha clase respectivamente. El clasificador es entrenado usando el popular método de *backpropagation*.

CLASIFICACIÓN LITOLÓGICA CON DATOS MULTICOMPONENTE

En este primer ejemplo se ilustra el método propuesto para clasificación de facies usando los datos multicomponente de un campo al oriente de Venezuela. En este ejercicio se realizó una clasificación litológica a partir de los resultados obtenidos mediante la inversión multicomponente de una sección sísmica arbitraria.

Para evaluar la factibilidad de clasificar litologías a partir de los datos multicomponente, se realizó un estudio preliminar en un pozo del área en el cual se disponía del conjunto completo de mediciones de parámetros elásticos (densidad, velocidad de onda P y velocidad de onda S). Evaluando la gráfica del lugar geométrico generado por estos datos de pozo se pudo constatar la existencia de una clara separación de los valores altos y bajos del gamma ray. El gráfico de densidad vs. velocidades es presentado en la figura 2, donde los puntos azules representan bajos valores del gamma ray (asociados a arenas) y los rojos representan altos valores del gamma ray (asociados a lutitas); mientras que las tonalidades verdes y amarillas representan las zonas de transición.

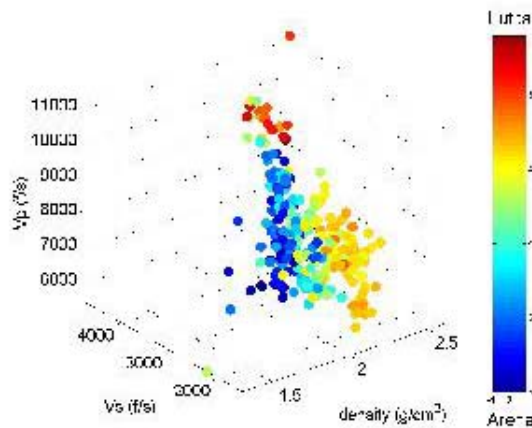


Figura 2: Gráfico de densidad vs. velocidades.

Una vez evaluada la factibilidad de utilizar los datos multicomponente para discriminar litologías se procedió a generar secciones estimadas de densidad e impedancias de ondas P y S con el fin de realizar una clasificación litológica en toda una sección sísmica. Los parámetros elásticos fueron estimados de los datos multicomponente mediante inversión sísmica estratigráfica basada en un modelo convolucional. Este método permite invertir datos apilados de onda convertida con el objeto de obtener una pseudo-impedancia de onda S, de la misma manera que los datos apilados de ondas compresionales son invertidos para obtener impedancia acústica. La densidad es posteriormente obtenida a partir de la impedancia acústica, la pseudo-impedancia de onda S y valores independientemente estimados de V_p/V_s y V_p/V_s , lo cual permite a su vez obtener un set completo de parámetros elásticos: V_p , V_s y densidad (Valenciano y Michelena, 2000).

Una vez obtenidas las secciones de densidad y de impedancias, el clasificador (previamente entrenado con los datos de pozo) fue usado para discriminar litologías en toda la sección sísmica. La figura 3 muestra el resultado final de la clasificación litológica en una sección arbitraria del campo en cuestión. En la figura, las clases identificadas como arenas están representadas en color azul y las clases identificadas como lutitas están representadas en color rojo; mientras que las transiciones se muestran en azul claro y amarillo.




Figura 3: Clasificación litológica a partir de datos multicomponente.

Finalmente, es importante mencionar que en el caso particular de esta área de estudio existe el problema de bajos contrastes de impedancia acústica entre lutitas y arenas, lo cual aumenta la incertidumbre en la caracterización litológica mediante el uso de sísmica convencional. Mediante este ejercicio se pudo constatar que el uso de datos multicomponente en combinación con el clasificador basado en redes neuronales reduce la incertidumbre en el proceso de caracterización litológica. Nótese la clara definición de las arenas (color azul) en la figura 3; lo cual no es posible con la sísmica convencional debido a los bajos contrastes de impedancia antes mencionados.

CLASIFICACIÓN A PARTIR DE ANÁLISIS FRACTAL BASADO EN ONDÍCULAS

En este segundo ejemplo se ilustra el método propuesto para clasificación de facies sísmicas usando los datos sísmicos de un campo al sureste de Venezuela. En este ejercicio se realizó una clasificación de tipos de arenas a partir de los resultados de un análisis fractal basado ondículas de los datos sísmicos en un horizonte de interés (Jiménez *et al.*, 1999).

El análisis fractal basado en ondículas (WBFA) es una técnica que permite analizar cómo varía la energía de la señal respecto a la escala. Al analizar la varianza de los coeficientes de la transformada wavelet en cada nivel de detalle, se observa que satisfacen una ley de potencia respecto a la escala si, y sólo si, la señal que se está estudiando tiene una dimensión fractal asociada. El valor de dicha dimensión está relacionado con el exponente de la ley de potencia antes mencionada. Se ha observado experimentalmente que las señales geofísicas (sísmica y registros de pozo) exhiben este tipo de comportamiento fractal.

Haciendo uso de esta técnica de análisis fractal basado en ondículas, se ha podido constatar que existen dimensiones fractales asociadas a distintos tipos de litología. De esta forma, es posible identificar los ambientes sedimentarios de acuerdo a sus propiedades fractales en el espacio transformado, el cual

consiste en un espacio bidimensional definido por dos parámetros resultantes del análisis WBFA. Estos parámetros son la constante de proporcionalidad y el exponente de la ley de potencia.

En el área donde se realizó el experimento, se disponía de información de 24 registros de pozos, una caracterización a priori de los ambientes sedimentarios en un intervalo de interés, un volumen de datos sísmicos y los horizontes interpretados en el intervalo de interés. El objeto de este estudio era evaluar la factibilidad de delimitar las áreas que presentan mayor contenido de arenas limpias, las que presentan arenas sucias y sus respectivas zonas de transición. El método se aplicó a los pozos en primer lugar, utilizando registros del tipo gamma ray, donde se logró apreciar una evidente separación de los distintos tipos de arena. Para obtener un mapa de toda el área se aplicó el método WBFA al volumen de datos sísmicos, entrenando la red neuronal con la información correspondiente a las localidades de los pozos. En la figura 4 se muestra el mapa de distribución de arenas obtenido para el intervalo de interés. En dicho mapa el color amarillo representa las arenas limpias, el gris las arenas sucias y el rojo las zonas de transición.




Figura 4: Mapa de distribución de arenas usando un clasificador basado en redes neuronales.

El porcentaje de éxito estimado para la clasificación es de aproximadamente un 80%, el cual se puede verificar a partir de las clases obtenidas para cada uno de los pozos usados en el estudio. Adicionalmente, el resultado obtenido corrobora el modelo sedimentológico del área, según el cual la cantidad de arenas sucias aumenta en la dirección sudoeste. También es interesante notar como las zonas de transición se ubican, como es de esperarse, entre las áreas de arenas limpias y sucias.

CLASIFICACIÓN DE FACIES LITOLÓGICAS EN REGISTROS DE POZO

En este tercer ejemplo se ilustra el método propuesto para clasificación usando registros de pozo del tipo gamma ray en un campo en el occidente de Venezuela. En este ejercicio se realizó una clasificación de facies litológicas a partir de los resultados de un análisis multifractal de los registros de pozo (Márquez *et al.*, 2001).

El análisis multifractal de registros de pozo se basa en el estudio de las propiedades de intermitencia y no estacionaridad exhibidas por los registros. Estas propiedades pueden caracterizarse a través del estudio de diferentes estadísticos de alto orden de la señal en cuestión. Se ha podido determinar que para las series de tiempo que satisfacen propiedades multiescala, estos estadísticos tienen un comportamiento en forma de ley de potencias cuyo exponente está dado por una familia de parámetros. Esta familia de parámetros denominados $C(q)$ y $H(q)$ (para $q = 1, 2, 3, \dots$) nos permite cuantificar las propiedades de intermitencia y no estacionaridad, respectivamente, las cuales son propuestas como elementos base para un método automático de clasificación de facies litológicas.

Mediante un estudio preliminar se pudo evidenciar que ciertos tipos de registros de pozo, como por ejemplo, gamma ray, potencial espontáneo, sónico y resistividad exhiben un comportamiento del tipo multifractal. En el caso particular del campo en cuestión, se estudiaron las propiedades de los registros gamma ray de 19 pozos correspondientes a dos facies litológicas distintas, que fueron catalogadas como arenas sucias y arenas limpias. En la figura 5 se presenta la ubicación resultante para cada uno de los 19 pozos en el espacio bidimensional definido por dos de los parámetros de la familia de parámetros anteriormente mencionada, específicamente los correspondientes a $q = 1$, denominados C1 y H1 (Márquez *et al.*, 2001).

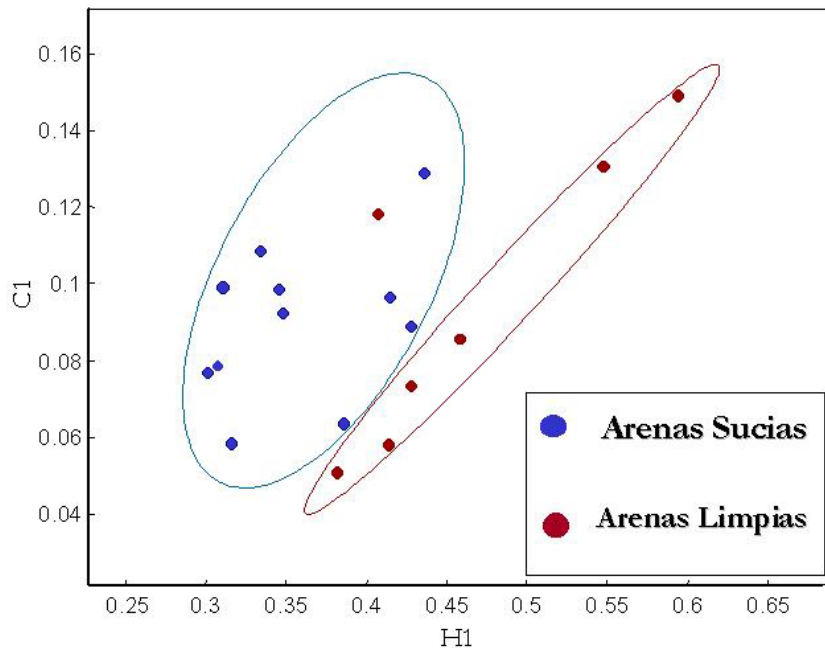


Figura 5: Ubicación de los pozos en el espacio de los parámetros H1 y C1.

Como se observa en la figura, una clara separación entre los pozos ubicados en arenas limpias y los ubicados en arenas sucias puede ser extraída por el clasificador. El éxito de la clasificación usando los parámetros de la figura 6 fue de un 90%. Sin embargo, este resultado pudo ser mejorado entrenando el clasificador con un mayor número de parámetros. De hecho, el clasificador fue reentrenado con cuatro parámetros: H1, H2, C1 y C2, lográndose discriminar la totalidad de los pozos.

CONCLUSIONES Y RECOMENDACIONES

Como resultado de los ejemplos presentados en el presente trabajo se puede evidenciar la gran ventaja de usar un perceptrón de capas múltiples como herramienta para la clasificación de facies sísmicas y/o litología. La metodología descrita en este trabajo pertenece a la categoría de algoritmos de aprendizaje supervisado, para los cuales es necesario el conocimiento previo de las clases que se desean identificar.

Futuros trabajos en el área de clasificación de facies sísmicas y/o litológicas mediante el uso de redes neuronales deben orientarse en tres direcciones principalmente:

1. Evaluar las ventajas y desventajas de usar otras arquitecturas de redes neuronales, distintas al perceptrón de capas múltiples, en el problema de clasificación.
2. Desarrollar técnicas estadísticas para la estimación de la incertidumbre asociada a los mapas de facies obtenidos mediante el uso de esta técnica.

3. Adaptar técnicas de aprendizaje no supervisado para la identificación de clases en datos geofísicos, de forma que se puedan generar mapas de clases a partir de la propia estructura de los datos sin conocimiento previo de las clases existentes.

CONTRIBUCIONES TÉCNICAS

La combinación de atributos no convencionales (multicomponente y multiescala) con clasificadores neuronales supervisados, constituyen una poderosa herramienta que puede ayudar en el proceso de interpretación, delineación y caracterización de un yacimiento. En particular la metodología presentada, no sólo constituye una gran herramienta de asistencia al intérprete, sino que contribuye a disminuir el riesgo exploratorio, de desarrollo y el tiempo para la caracterización de los yacimientos.

BIBLIOGRAFÍA

- Haykin, S.; 1994, *Neural Networks: A Comprehensive Foundation*, Macmillan, Toronto.
- Jimenez, J., Michelena, R. and Peinado, A., 1999, Facies recognition using wavelet-based fractal analysis on compressed seismic data, 69th Ann. Internat. Mtg: Soc. of Expl. Geophys., 1922-1925.
- Marquez, D., Jimenez, J. and Monsalve, A., 2001, Facies recognition using multifractal analysis, 71st Ann. Internat. Mtg: Soc. of Expl. Geophys., 580-582.
- Valenciano, A. and Michelena, R., 2000, Stratigraphic inversion of poststack P-S converted waves data, 70th Ann. Internat. Mtg: Soc. of Expl. Geophys., 150-153.