



Estudio de transformadas multi-atributo para la predicción de propiedades petrofísicas en un campo de petróleo pesado en la Subcuenca de Maturín, Venezuela.

Fabiola Ruiz y Milagrosa Aldana, Universidad Simón Bolívar.

Copyright 2008, ACGGP.

This paper was selected for presentation by an ACGGP Technical Committee following review of information contained in an abstract submitted by the author(s).

Resumen

En el presente trabajo se aplicó el método de transformadas multi-atributo para estimar propiedades petrofísicas a partir de datos sísmicos y registros de pozos en un campo de petróleo pesado. Se utilizaron transformadas lineales y no lineales entre un grupo de valores de registros de pozo y de atributos sísmicos.

La transformada multi-atributo lineal se obtuvo determinando, por mínimos cuadrados, los pesos que mejor ajustaban la propiedad objetivo y los atributos sísmicos. En el modo no-lineal, se entrenaron dos tipos de redes neuronales: la Red Neuronal Multi-Capa (MLFN) y la Red Neuronal Probabilística (PNN), considerando como entrada atributos sísmicos y registros de pozos. La confiabilidad de la transformada se estimó a partir de una cross-validación.

Se realizó una inversión sísmica post-apilado y un análisis de descomposición espectral. El resultado de la inversión no indicó la existencia de anomalías asociadas a las arenas del yacimiento, debido a que la impedancia acústica de las lutitas resulta muy similar a la de las arenas. Sin embargo, la descomposición espectral permitió una buena identificación de rasgos estratigráficos de interés, optándose por incluir los cubos de frecuencias en el análisis multi-atributo, práctica innovadora cuyos resultados se discuten en el presente estudio.

Ante la difícil caracterización sísmica que supone un yacimiento de petróleo pesado, la densidad resultó ser un buen indicador de litología y, debido a esto, se generó un volumen de pseudo-densidad aplicando la transformada multi-atributo MLFN (la más confiable en términos de correlación) a todo el cubo sísmico.

Introducción

El desarrollo de campos productores (que cuentan con un considerable número de pozos perforados) ha acentuado la búsqueda de técnicas, como la inversión sísmica y el modelado, que permitan integrar y establecer una relación entre los registros de pozos y los datos sísmicos (Hampson et al., 2001), con el objetivo de continuar con la caracterización del yacimiento e identificar nuevas zonas de interés. En el presente trabajo se desea ir más allá de la inversión sísmica convencional, al estimar propiedades petrofísicas diferentes a la impedancia acústica, partiendo de atributos sísmicos y no del cubo sísmico original (Hampson et al., 2001). Se busca establecer una relación estadística (lineal o no lineal) entre los

datos sísmicos y los parámetros de yacimiento de un campo maduro de petróleo pesado, ubicado en la Subcuenca de Maturín. El campo cuenta con una producción de 17.6 Mbd (para el año 2008). Su unidad productora (intervalo de interés que cuenta con un espesor de, aproximadamente, 500 pies) fue depositada durante el Mioceno Temprano y Medio, en una planicie deltaica que exhibe una evolución estratigráfica que va desde canales de gran espesor a zonas interdistributarias con mayor contenido lodoso.

Hampson et al., (2001) y Cedillo (2003) aplican una metodología basada en la predicción de propiedades petrofísicas a partir de la aplicación de transformadas lineales y no lineales (redes neuronales) utilizando registros de pozo y atributos sísmicos (incluyendo un volumen de impedancia acústica) como parámetros de entrada. Los autores demuestran la ventaja que supone el uso de Redes Neuronales para derivar las transformadas, brindando resultados mucho más exactos y con mayor resolución, tanto vertical como horizontal, que los obtenidos al aplicar transformadas lineales.

Utilizando atributos calculados directamente de los datos sísmicos, cubos de frecuencias y el volumen de impedancia acústica, un proceso de regresión lineal multi-atributo de "paso aprendido" seleccionará la combinación de atributos que mejor estime la propiedad objetivo en la ubicación de los pozos. A partir de esta combinación de atributos se calculará una relación estadística entrenando dos tipos de redes neuronales: la Red Neuronal Multi-Capa (MLFN) y la Red Neuronal Probabilística (PNN). Finalmente, se aplicará la relación calculada a todo el volumen de datos sísmicos, buscando generar un volumen de pseudo-densidad. La técnica se empleará en un total de 12 pozos y un cubo sísmico post-apilado que cuenta con un área de 90 Km².

Al no contarse con datos pre-apilados, es necesario extraer la mayor información posible del volumen disponible, aplicando técnicas robustas como descomposición espectral, inversión acústica y redes neuronales.

Análisis multi-atributo

El análisis multi-atributo se basa en la búsqueda de un operador o transformada, lineal o no lineal, capaz que predecir propiedades petrofísicas a partir de atributos derivados de los datos sísmicos.

La metodología aplicada se divide en dos etapas: la estimación de registros a partir de otros registros y la estimación de registros a partir de atributos sísmicos, generándose volúmenes de pseudo-propiedades.

Ambas etapas constan de dos fases: derivar una relación lineal de atributo simple y una multivariable utilizando la

regresión de paso aprendido (fase lineal) y entrenar dos tipos de redes neuronales utilizando como entrada la transformada lineal obtenida (fase no lineal). En ambos procedimientos se utilizará la cross-validación para estimar la confiabilidad de la relación obtenida calculando, para cada pozo, la correlación entre el registro estimado y el registro original, dejando fuera del entrenamiento el pozo objetivo.

En el análisis utilizando atributos sísmicos se incluyen 29 atributos extraídos de la traza sísmica: atributos de frecuencia, de amplitud, de fase, filtros, el cubo de impedancia acústica y atributos espectrales obtenidos del análisis de descomposición espectral.

Debido a la diferencia entre el contenido de frecuencia de los registros de pozo y los datos sísmicos, fue necesario utilizar un operador convolucional de 5 puntos para disminuir el contenido de frecuencia de los registros de pozo y llevarlos a la misma frecuencia de la sísmica.

Regresión de paso aprendido. La regresión de paso aprendido es utilizada para determinar la combinación de atributos que arroje el menor error de predicción en la estimación de un registro en particular.

Durante el proceso de selección de los atributos, se escoge automáticamente el siguiente atributo que presente la mayor contribución en dirección ortogonal al atributo previo, asegurándose la independencia lineal de todos los atributos de la lista (Hampson et al., 2001).

Red Neuronal Multi Capa (MLFN). La arquitectura de este tipo de red consiste en una capa de entrada, una capa de salida y capas escondidas, donde cada capa posee nodos o neuronas conectados con sus respectivos pesos y cada conexión representa un peso (Figura 1).




Figura 1. Arquitectura de la red neuronal MLFN. (Modificado de Hampson et al., 2001).

El entrenamiento de la red consiste en utilizar ejemplos para encontrar los pesos óptimos. Los ejemplos consisten en una señal de entrada y la correspondiente respuesta deseada de la red. Para cada ejemplo se comparan las salidas obtenidas por la red con las salidas que se desean obtener y se calcula el error. Es posible minimizar el error actualizando los pesos (<ftp://ftp.hampson-russell.com/pub/manuals/neuralNetworks.pdf>).

Las variables en el entrenamiento de este tipo de red son el número de iteraciones y el número de nodos en la capa escondida. Ambos parámetros fueron determinados al realizar pruebas con diferentes valores y observando el comportamiento del error de validación, aumentando el

número de nodos y de iteraciones a medida que el error disminuía.

Red Neuronal Probabilística (PNN). La red neuronal probabilística se basa en emplear uno o más valores medidos, denominados variables independientes, para predecir el valor de una variable dependiente (<ftp://ftp.hampson-russell.com/pub/manuals/neuralNetworks.pdf>).

Tanto en la MLFN como en la PNN, la cross-validación indica la confiabilidad de la transformada, ya que permite cuantificar (sus valores van de 0 a 1) la efectividad de la transformada al estimar el registro objetivo en ubicaciones donde no se cuenta con pozos perforados.

Los parámetros a variar en el entrenamiento de la PNN son el número de sigmas y el número de iteraciones. No se espera que la variación del número de sigmas afecte significativamente el resultado de la predicción (Hampson et al., 2001). En este sentido, se decidió optar por 25 sigmas para el entrenamiento de la red, el número por defecto en el programa, mientras que el número de iteraciones se determinó de igual manera que en la MLFN.

Análisis de atributos sísmicos

En primer lugar, se realizó un estudio de física de rocas basado en gráficos cruzados o *crossplots*, buscando entender las propiedades de las litologías presentes en el yacimiento.

Los valores de impedancia acústica (IA) de las arenas productoras y las lutitas presentes, tanto dentro de la unidad de interés como suprayacente y subyacente a ésta, son muy similares entre sí, lo que dificulta la identificación del yacimiento utilizando la impedancia acústica. En el gráfico cruzado Densidad vs. IA (Figura 2) se corrobora este hecho. Aunado a lo anterior, es posible notar que la densidad discrimina efectivamente las arenas de las lutitas presentes en el intervalo de interés.

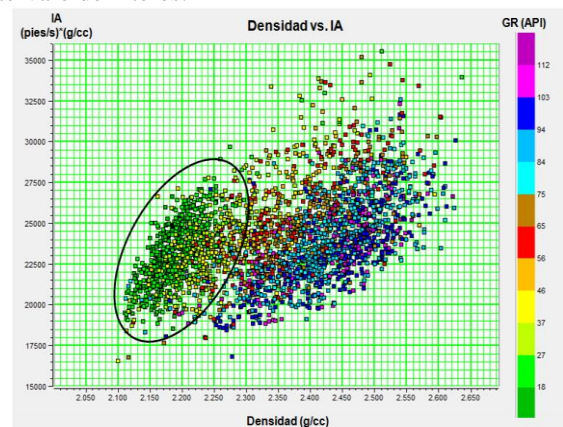


Figura 2. Gráfico cruzado de densidad vs. impedancia acústica.

Se realizó una inversión acústica del cubo apilado, cuyo resultado se muestra en la Figura 3. Se evidencia en esta figura la buena correlación que existe entre el resultado de la inversión y el registro de impedancias del pozo control, a pesar de la poca resolución que posee el volumen de

impedancia. La mayoría de las arenas dentro de la unidad de interés se encuentran por debajo de la resolución sísmica, hecho que constituye un obstáculo al buscar la continuidad de las arenas en el cubo de impedancia. Además, de acuerdo a López y Aldana (2007) la mayor parte de estas arenas poseen poca continuidad lateral y se acuan rápidamente. Sin embargo, el hecho de que la impedancia acústica no discrimine las litologías presentes constituye el principal problema del resultado de la inversión acústica.

A pesar de la poca resolución alcanzada por el volumen de impedancia y su incapacidad para discriminar litologías, no se descarta el hecho de que este atributo ayude en la estimación de las propiedades petrofísicas, lo que sería el objetivo principal de este trabajo.




Figura 3. Perfil de impedancia acústica con el registro de impedancia acústica del pozo 9 (pozo control).

Al observar lo poco satisfactoria que resultó la inversión para caracterizar las arenas del yacimiento, se decidió realizar un análisis de descomposición espectral.

En la Figura 4a se presenta una imagen RGB de 20(rojo)-30(verde)-40(azul) Hz asociada a la base del yacimiento, donde es posible observar anomalías con geometrías particulares, enmarcadas en líneas punteadas amarillas. Se identifica un posible canal con una frecuencia dominante de 30 y 40Hz (azul claro) y un geocuerpo de interés al NO del área, el cual presenta una alta amplitud de las frecuencias 20 y 30 Hz (color amarillo). La geometría de este geocuerpo pudiese asociarse a la presencia de ambientes deltaicos, cuya orientación concuerda con la dirección de sedimentación (S-N) previamente identificada (López y Aldana, 2007).

En la Figura 4b se muestra una imagen RGB de 35-45-55Hz generada haciendo un corte paralelo a la base a -30ms de ésta. A simple vista es posible identificar gran cantidad de rasgos estratigráficos con orientación S-N, paralela a la dirección de sedimentación. Resulta interesante observar la respuesta en frecuencia de los canales: los ubicados al NE del área presentan un color amarillento a verde, hecho que implica una alta amplitud de las frecuencias de 35 y 45Hz; los canales ubicados al Oeste y al Sur presentan una anomalía color morado a negro, asociado a frecuencias más altas (55Hz), posiblemente debido a una diferencia de espesores. Girolodi et al., (2005) han relacionado anomalías de baja frecuencia a grandes espesores, lo que permite inferir que, posiblemente, los canales al NE del área poseen mayores espesores que los ubicados al Sur y Oeste.

Al observar los buenos resultados arrojados por el análisis de descomposición espectral, se optó por incluir cubos de las frecuencias 25Hz, 35Hz, 45Hz y 55Hz en el análisis multi-atributo.




Figura 4. a) Imagen RGB de 20-30-40 Hz asociada a la base del yacimiento. b) Interpretación de la imagen RGB de 35-45-55 Hz generada haciendo un corte paralelo a la base a -30ms de ésta. Las líneas punteadas amarillas enmarcan los geocuerpos de interés.

Predicción del registro de densidad a partir de registros de pozo. Con base en lo observado en el *crossplot* de Densidad vs. Impedancia acústica (la densidad discrimina efectivamente entre arenas y lutitas), se procedió a estimar el registro de densidad en el intervalo de interés, primero a partir de los registros de Gamma Ray, Sónico y Resistividad y finalmente a partir de atributos sísmicos.

La curva de error de validación de la regresión multi-atributo (regresión de paso aprendido) (Figura 5) indica que los tres registros disponibles son estadísticamente significativos. Estos son, en orden, (Gamma Ray)^{1/2}, (Sónico)² y 1/Resistividad.




Figura 5. Gráfico del error de validación (rojo) y el error de predicción (negro) de la regresión multi-atributo calculada utilizando tres registros para la estimación de la densidad

La Red Neuronal Multi-Capa (MLFN) fue entrenada utilizando 7 nodos en la capa escondida y 30 iteraciones, mientras que la Red Neuronal Probabilística (PNN) se entrenó utilizando 25 sigmas y 30 iteraciones. En la Figura 6 se comparan los resultados obtenidos al estimar el pozo control (pozo 9) con las transformadas obtenidas mediante el entrenamiento de ambas redes neuronales, donde los valores de cross-validación y error de validación indican

que la Red Neuronal Multi-Capa arroja la mejor predicción del registro objetivo en zonas donde no se cuenta con pozos perforados. Sin embargo, visualmente ambas transformadas predicen efectivamente el registro de densidad en el pozo control.




Figura 6. Comparación entre la cross-validación de la MLFN y la PNN. El registro color negro corresponde a la densidad original y el rojo a la estimada a partir de registros de pozo.

Como era de esperarse, la estimación de la densidad mejoró significativamente al entrenar las redes neuronales. Esto puede observarse en la Figura 7, donde se presentan los registros estimados a través de las diferentes técnicas para el pozo 8, en el cual se obtuvieron los mejores resultados de predicción.

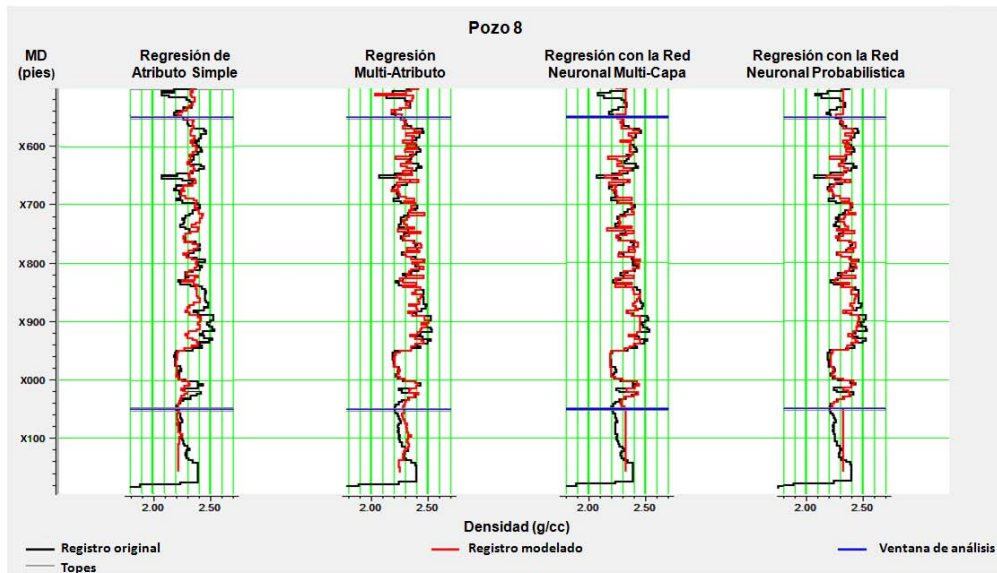


Figura 7. Comparación entre los registros de densidad original (negro) y densidad estimados (rojo) al aplicar las cuatro transformadas en el pozo 8.

Predicción del registro de densidad a partir de atributos sísmicos. Los atributos espectrales y de frecuencia fueron los más significativos a la hora de derivar la transformada multi-atributo (mucho más que la inversión acústica) para la predicción del registro de densidad. La cross-validación indicó que los primeros 6 atributos (Filtro 15/20-25/30, (Cubo 35Hz)², 1/Cubo 25Hz, 1/Cubo 45Hz, Fase Instantánea Coseno y 1/Inversión) constituyen la mejor combinación (estadísticamente hablando) para la estimación del registro de densidad.

Esta transformada fue utilizada para el entrenamiento de las redes neuronales Multi-Capa y Probabilística. La Red Neuronal Multi-Capa fue entrenada utilizando 30 nodos en la capa escondida y un total de 60 iteraciones. Para la Probabilística se utilizaron 25 sigmas y 50 iteraciones.

Finalmente, se aplicaron ambas transformadas obtenidas del entrenamiento de las redes neuronales en el pozo control, cuyo coeficiente de cross-validación es el que definirá cuál de las transformadas se aplicará a todo el cubo para generar el volumen de pseudo-densidad. En la Figura 8 se observa que el mayor coeficiente de validación corresponde a la transformada generada a partir del entrenamiento de la Red Neuronal Multi-Capa.

En este sentido, se decidió aplicar la transformada derivada del entrenamiento de la Red Neuronal Multi-Capa a todo el volumen sísmico, obteniendo un volumen de pseudo-densidad que, de acuerdo al análisis de física de rocas, permitirá caracterizar las arenas del yacimiento de interés.

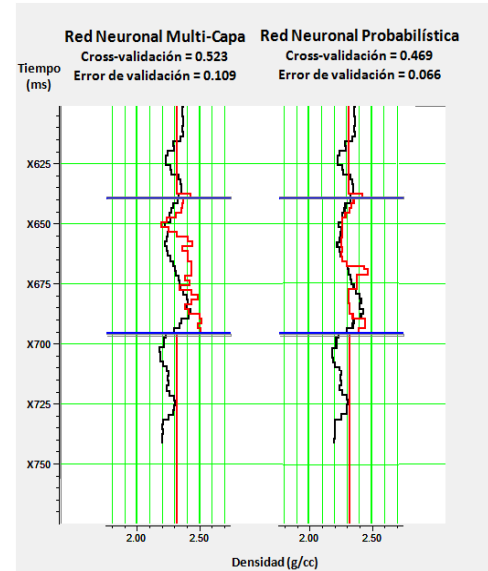


Figura 8. Comparación entre el coeficiente de validación de la MLFN y la PNN en el pozo control (pozo 9). El registro color negro corresponde al registro de densidad original y el rojo al estimado.

En la Figura 9 se observa la buena correlación que existe entre el perfil de pseudo-densidad generado y los registros de densidad, especialmente en la ubicación del pozo 9, pozo control que permite validar la predicción. Además, se corrobora lo observado en el análisis de física de rocas: las arenas poseen valores de densidad más bajos que las lutitas.

En la Figura 10 se muestra el mapa de pseudo-densidad generado en la base, tomando una ventana de 20ms hacia el tope del yacimiento. Los valores de densidad observados en el mapa representan, para cada punto, un promedio de las densidades en el intervalo de 20ms.

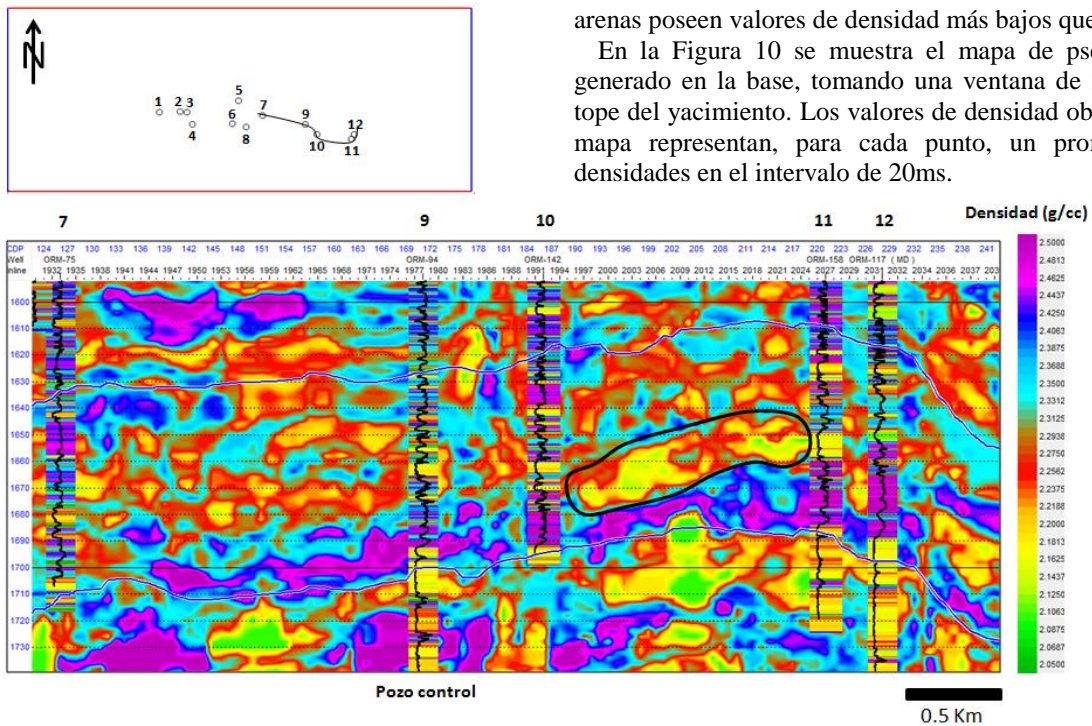


Figura 9. Perfil de pseudo-densidad correspondiente a una línea arbitraria que pasa por los pozos 7, 9, 10, 11 y 12. Los registros gamma ray pertenecientes a estos pozos se encuentran superpuestos a la línea. Enmarcado en negro se muestra la continuidad de una de las arenas (zona de baja densidad) más gruesas del intervalo de interés.

Tanto el canal como el posible delta al NO del área poseen bajas densidades asociadas a arenas. Para el resto del área se observa una distribución heterogénea de arenas y lutitas, debido a la convergencia de dos ambientes sedimentarios: uno dominado por corrientes canalizadas y el segundo dominado por el oleaje (López y Aldana, 2007).

Los registros de densidad y gamma ray validan las anomalías de densidad observadas en cada uno de los pozos. Los pozos 1 y 3 se encuentran sobre zonas de baja densidad y sus registros de gamma ray y densidad muestran una predominante presencia de arenas en este intervalo. Por otro lado, los pozos 5 y 9 se ubican en zonas de altas densidades, asociadas a lutitas y en sus registros de gamma ray y densidad se observa un mayor contenido lutítico.

Al comparar la Figura 10 con la la imagen RGB de 20(rojo)-30(verde)-40(azul) Hz generada en la base del yacimiento (Figura 4a) se evidencia la buena correlación que existe entre el mapa de pseudo-densidad y la imagen RGB. Se observa una clara relación entre la frecuencia y la litología: las zonas de baja densidad (arenas) corresponden a las zonas donde las frecuencias 20 y 30Hz presentan una alta amplitud (zonas amarillas en la imagen RGB). Las zonas de alta densidad (mayor contenido lutítico) se asocian a zonas de frecuencias mayores a 40Hz (zonas azul oscuro y morado).

Conclusiones

Los resultados obtenidos apuntan a la importancia de la aplicación de técnicas geoestadísticas, tales como redes neuronales, en la disminución de la incertidumbre asociada a la caracterización de yacimientos, especialmente en campos de petróleo pesado.

En el presente trabajo se entrenaron dos tipos de redes neuronales, la Red Neuronal Multi-Capa (MLFN) y la Red Neuronal Probabilística (PNN). En general, el entrenamiento de redes neuronales aumentó el poder de predicción de la

transformada multi-atributo en la estimación de la densidad a partir de registros de pozo y a partir de atributos sísmicos en el área de estudio. En particular, la MLFN mostró la estimación más confiable del registro de densidad en términos de la cross-correlación.

En el área de estudio, la descomposición espectral permitió la identificación de rasgos estratigráficos de interés. Al incluir los cubos de frecuencias en el análisis multi-atributo, fue posible establecer una relación empírica entre la frecuencia dominante y el contenido litológico, lográndose una efectiva caracterización del yacimiento. El análisis multi-atributo permite obtener volúmenes de pseudo-propiedades, tales como la densidad, a partir de datos sísmicos post-apilados. En este sentido ofrece una alternativa interesante al estudiar zonas con características similares a la del presente trabajo y donde no se cuente con datos sísmicos pre-apilados.

Referencias

1. Cedillo, I., Aldana, M., y Angulo, R., 2004, Estudio de transformadas multiatributo para predecir propiedades de registro en una arena del Eoceno inferior en el Lago de Maracaibo: Memorias del XII Congreso Venezolano de Geofísica, 1-8.
2. Giroldi, L., Lopez, A., Blangy, J. P., y Cordova, J. C., 2005, Seismically-driven appraisal and development: A case study from Bolivia's Chaco Basin: The Leading Edge, **24**, 1099-1108.
3. Hampson, D. P., Shuelke, J. S., y Quirein, J. A., 2001, Use of multiattribute transforms to predict log properties from seismic data: Geophysics, **66**, No.1, 220-236.
4. López, M., y Aldana, M., 2007, Facies recognition using wavelet based fractal analysis and waveform classifier at the Oritupano -A Field, Venezuela: Nonlinear Processes in Geophysics, **14**, 325-335.
5. <ftp://ftp.hampson-russell.com/pub/manuals/neuralNetworks.pdf>

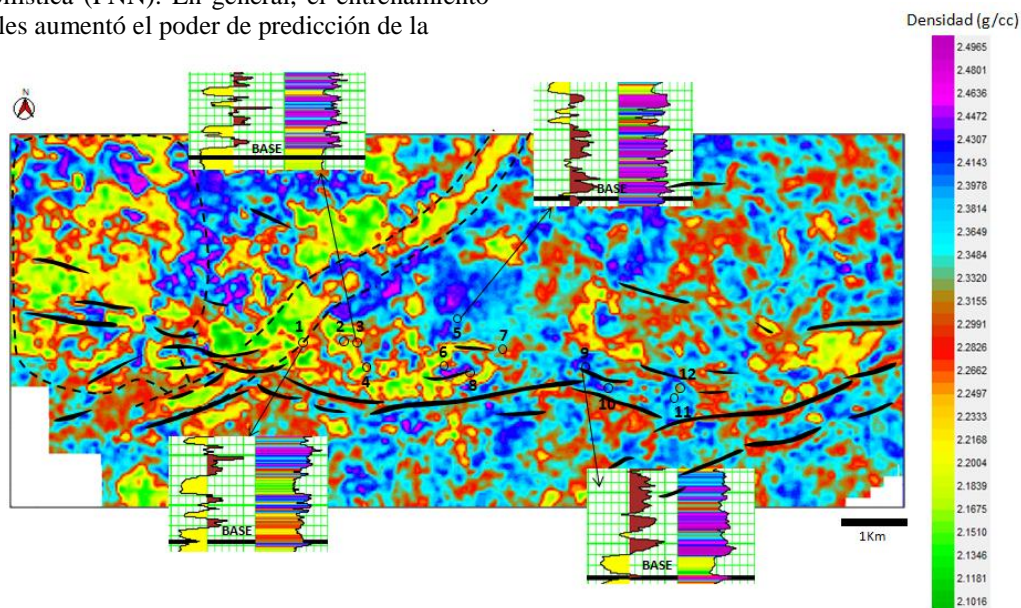


Figura 10. Mapa de pseudo-densidad generado en la base, tomando una ventana de 20ms hacia el tope del yacimiento, con registros gamma ray y densidad de los pozos 1, 3, 5 y 9 en el intervalo de estudio.