

Obtención de mapas de similitud sísmica 2D mediante redes neuronales

Oscar Rondón*, PDVSA-Intevep, y Rafael Banchs, PDVSA -Intevep

Resumen

El desarrollo de metodologías para obtener e integrar información de múltiples atributos es de vital importancia para la caracterización de yacimientos. En particular durante la fase exploratoria, cuando no se cuenta con suficiente información de pozos, la información sísmica es una fuente de información valiosa para la toma de decisiones. En este artículo se presenta una metodología basada en el estudio de patrones mediante redes neuronales de Kohonen, para obtener mapas de similitud utilizando múltiples atributos sísmicos que permiten detectar zonas sísmicamente similares a un punto de referencia o de control, que puede ser, por ejemplo, un pozo con buena producción de petróleo

Summary

The development of methodologies for obtaining and integrating information of multiple seismic attributes constitutes an issue of great importance in reservoir characterization and for exploration geophysicists, who do not have enough well information. Then, seismic information becomes very valuable. This work presents a methodology for computing similarity maps, from multiple seismic attributes, based on pattern recognition by using Kohonen neural networks. This methodology allows to identify regions with similar seismic properties to a pre-defined reference location of interest, as for example, a good producer well.

Introducción

La extracción de información de los datos sísmicos para ser utilizada en la caracterización y explotación de yacimientos se ha convertido en un área muy activa durante los últimos años. En particular, se ha observado un incremento sustancial en la aplicación y generación de diversos atributos sísmicos, los cuales combinados con información de alta resolución, como los registros de pozos e información de núcleos, contribuyen a mejorar la caracterización del yacimiento bajo estudio (Brown, 1996), (Gastaldi *et al.*, 1997), (Lawrence, 1998), (Pennington, 1997), (Russel *et al.*, 1997). Cuando no se dispone de una cantidad suficiente de información de pozos, como por ejemplo durante la fase exploratoria, la información sísmica puede ser utilizada para detectar zonas con respuesta sísmica similar a un punto de control o punto de referencia, que puede ser un pozo seco o buen productor. Esta es la

idea fundamental que radica en el análisis de similitud desarrollado por Michelena *et al.* (1998). En este artículo se presenta una breve revisión del análisis de similitud propuesto por Michelena *et al.* (1998), indicando ciertas desventajas de la metodología y se propone una metodología análoga, basada en el uso de redes neuronales de Kohonen (Haykin, 1994; Kohonen, 1988), que no presenta las desventajas de la metodología original.

Mapas de similitud

El resultado final del análisis de similitud propuesto por Michelena *et al.* (1998) es un mapa donde a cada coordenada (x, y) se le asigna el valor de similitud con respecto al punto de control. A partir de N mapas de atributos sísmicos independientes, la metodología para obtener dicho valor de similitud se puede resumir en 3 pasos, que se describen a continuación:

- a) *Obtención de la respuesta sísmica en el punto de referencia P .* Esta consiste en el cálculo de la media y la varianza de cada atributo en una vecindad del punto de control o punto de referencia P . De esta forma, al contar con N atributos se obtendrán N valores $m_i(P)$ que representan las medias de cada uno de los atributos en una vecindad del punto de referencia, a partir de las cuales se obtienen los N valores $\sigma_i(P)$ que corresponden a la desviación estándar de cada uno de los atributos en dicha vecindad. Este proceso se muestra en la figura 1. Los valores $m_i(P)$ y $\sigma_i(P)$ con $i = 1, 2, K, N$ se consideran como la respuesta sísmica en el punto de referencia P .
- b) *Obtención de la respuesta sísmica en el punto objetivo P' .* Cada punto $P' = (x', y')$ de cada uno de los mapas de atributos se considera un punto objetivo, al cual se le asociará un valor de similitud respecto al punto de control P de acuerdo a la respuesta sísmica obtenida en él. La respuesta sísmica en cada punto objetivo se obtiene como se indicó para el caso del punto de control. De esta forma se obtienen los valores $m_i(P')$ $i = 1, 2, K, N$ que representan el valor promedio de cada uno de los atributos en una vecindad del punto objetivo.

Obtención de mapas de similitud sísmica mediante redes neuronales

c) *Determinación y asignación del valor de similitud respecto al punto de referencia.* Si en el punto objetivo P' del atributo i se verifica que:

$$m_i(P) - \sigma_i(P) < m_i(P') < m_i(P) + \sigma_i(P) \quad (1)$$

entonces al punto objetivo P' del atributo i se le asigna el valor 1, en caso contrario se le asigna el valor 0. Este procedimiento se realiza en cada uno de los puntos de cada uno de los mapas de atributos. De esta forma se obtienen N mapas con valores binarios 0 ó 1. Estos reflejan si la respuesta sísmica en el punto objetivo es similar a la respuesta sísmica en el punto de control (valor igual a 1) o no (valor igual a 0) con base en el criterio determinado por la ecuación (1).

Concluidos los pasos anteriores, el mapa de similitud se obtiene simplemente sumando cada uno de los N mapas generados en el paso c). La figura 2 muestra un ejemplo de un mapa de similitud. En este los puntos con valores iguales a N indican que en todos los N mapas de atributos dichos puntos resultaron similares al punto de referencia según el criterio dado por la ecuación (1). Análogamente, puntos con valores iguales a cero indican que en ninguno de los N mapas dichos puntos resultaron similares al punto de control. Es así como el mapa de similitud es un resumen de la similitud sísmica respecto a un punto de referencia tomando en cuenta N atributos sísmicos.

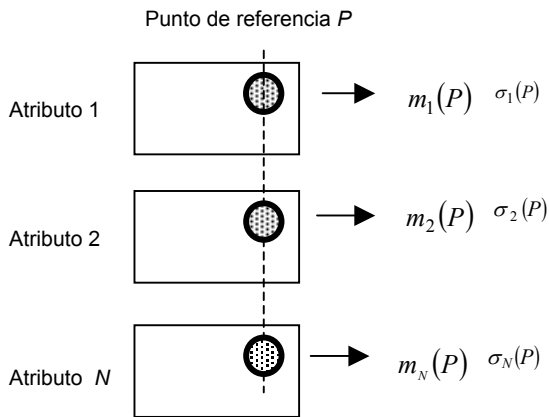


Fig. 1 Cálculo de la respuesta sísmica en el punto de referencia para la obtención del mapa de similitud

Cuando cada valor en el mapa de similitud es dividido por N , se obtiene una escala de valores entre 0 y 1, donde el valor cero indica que el punto es completamente disímil respecto al punto de referencia o control y el valor 1 indica completa similitud. En lo sucesivo se utilizará esta forma del mapa de similitud.

La principal limitación del método descrito es quizás el criterio de asignación del valor de similitud con respecto al punto de referencia o control dado por la ecuación (1), debido a la rigidez del mismo. Con éste, un punto objetivo se clasifica simplemente como similar o no respecto al punto de control. En consecuencia es posible obtener en un mapa de similitud puntos próximos con valores de similitud completamente opuestos, lo que contrasta por ejemplo con la continuidad geológica. De igual manera, puede ocurrir que valores de la respuesta sísmica en el punto objetivo que difieran por una cantidad despreciable del criterio dado por (1), sean asignados como completamente disímiles cuando en realidad no lo son.

4	2	3	5	4	6	8	9	4	5	N	N	N
2	3	7	1	0	0	2	3	1	2	N	N	N
0	5	3	2	1	1	0	0	2	4	N	N	N
N	5	N	1	0	0	1	1	2	2	1	7	7
4	1	3	0	0	0	1	1	6	6	3	3	1

Fig. 2 Ejemplo de un mapa de similitud

Al estudiar los pasos requeridos para la generación del mapa de similitud, se observa que al punto de control o referencia P se le asocia un patrón dado por los valores $m_i(P)$ con $i = 1, 2, K, N$, el cual se compara con el patrón en el punto objetivo P' dado por los valores $m_i(P')$ con $i = 1, 2, K, N$, utilizando la ecuación (1) para determinar el valor de similitud. En consecuencia, el patrón en el punto objetivo se considera similar al patrón en el punto de referencia si verifica la ecuación (1) y disímil en caso contrario. Desde este punto de vista de comparación y estudio de patrones, el uso de redes neuronales puede mejorar significativamente la obtención del valor de similitud entre el punto objetivo y el punto de referencia, al cambiar el criterio dado por la ecuación (1) por un criterio de distancia adaptado al estudio de patrones. La metodología que se propone en este artículo se basa en el uso de redes neuronales de Kohonen (Haykin, 1994), (Kohonen, 1988), las cuales se describen a continuación, para posteriormente mostrar su aplicación a la obtención de mapas de similitud.

Obtención de mapas de similitud sísmica mediante redes neuronales

Redes neuronales de Kohonen

Las redes neuronales de Kohonen son un caso particular de redes neuronales auto-organizadas (Haykin, 1994). Estas están formadas por una serie de neuronas, generalmente dispuestas en un arreglo de una dimensión o dos dimensiones, que reciben cada una la información de un patrón de entrada N dimensional $V = (V_1, V_2, \dots, V_N)$. A su vez, cada neurona posee un vector $W_j = (W_{1j}, W_{2j}, \dots, W_{Nj})$, denominado vector de pesos sinápticos, que durante la fase de entrenamiento de la red se actualizan según la regla de aprendizaje desarrollada por Kohonen (Haykin, 1994). Esta consiste básicamente en los pasos siguientes:

- Determinar la neurona para la cual la distancia entre el vector de pesos sinápticos y el patrón de entrada es mínima.

Esta neurona se denomina la neurona ganadora y se denota por i^* . En consecuencia el vector de pesos sinápticos W_{i^*} satisface $d(W_{i^*}, V) \leq d(W_j, V)$ para todo j , donde $d(\cdot, \cdot)$ es el operador de distancia, el cual usualmente corresponde a la distancia euclídea.

Al inicio de la fase de entrenamiento, los vectores de pesos sinápticos se inicializan con valores aleatorios, generalmente en $[-1,1]$, y luego se van actualizando como se indica en el paso siguiente.

- Actualización del vector de pesos sinápticos de la neurona ganadora y sus vecinas.

Para proceder a la actualización de los vectores de pesos sinápticos se define previamente una vecindad Λ_{i^*} alrededor de la neurona ganadora y se procede a actualizar el vector de pesos sinápticos de todas las neuronas en dicha vecindad, asignando como nuevo valor $W_j + \eta[V - W_j]$ donde η es la tasa de aprendizaje.

Esta regla de actualización simplemente establece que la neurona ganadora junto con sus vecinas son recompensadas haciendo que sus vectores de pesos sinápticos se parezcan a V . Es esta característica la que convierte a las redes de Kohonen en una herramienta ideal para detectar patrones en los datos objeto de estudio.

Los pasos anteriores se repiten iterativamente utilizando todos los patrones de entrada V hasta que no se observe un cambio sustancial en la actualización de los vectores de pesos sinápticos, lo que indica la finalización de la etapa de entrenamiento de la red. En este momento la red, a través

de sus vectores de pesos sinápticos, ha capturado aquellos patrones más significativos presentes en los datos de entrada.

La figura 3 muestra una red de Kohonen unidimensional con 3 neuronas que reciben la información de un patrón de entrada con $N = 2$.

Mapas de similitud mediante redes de Kohonen

Considérese N mapas de atributos sísmicos de M puntos cada uno. En cada punto $P_j = (x_j, y_j)$ $j = 1, 2, \dots, K$, M se pueden obtener los valores $m_i(P_j)$ con $i = 1, 2, \dots, K, N$




Fig. 3. Ejemplo de una red de Kohonen con 3 neuronas para estudiar patrones de entrada bidimensionales.

y de esta forma construir M vectores o patrones de entrada $V_j = (m_1(P_j), m_2(P_j), \dots, m_N(P_j))$. Estos son lo que se utilizarán para el entrenamiento de la red. Así, los pasos a seguir para la obtención de mapas de similitud mediante redes neuronales de Kohonen son:

- Definir el número K de neuronas de la red e inicializar los vectores de pesos sinápticos $W_j = (W_{1j}, W_{2j}, \dots, W_{Nj})$ $j = 1, 2, \dots, K, N$.
- Realizar el entrenamiento de la red siguiendo la regla de aprendizaje de Kohonen indicada anteriormente.
- Calcular el patrón de referencia del punto P respecto al cual se quiere obtener el mapa de similitud. Dicho patrón está dado por el vector $V_P = (m_1(P), m_2(P), \dots, m_N(P))$.

Obtención de mapas de similitud sísmica mediante redes neuronales

- d) Presentar el patrón V_p a la red y determinar la neurona ganadora i^* y su vector de pesos sinápticos W_{i^*} . Luego, se asigna el valor de similitud de un punto objetivo P_j $j=1, 2, K, M$ con respecto al punto P como el valor dado por

$$1 - \frac{d(V_j, W_{i^*})}{d(V_j, V_j) + d(W_{i^*}, W_{i^*})} \quad j = 1, 2, K, M$$

respectivamente.

Es importante observar en los pasos descritos anteriormente que el entrenamiento de la red se realiza sólo una vez y únicamente con los patrones V_j . Posterior a esto, se pueden generar diversos mapas de similitud con respecto a distintos puntos de referencia o control, simplemente repitiendo los pasos c) y d) antes indicados. Asimismo, no existe una regla universal para escoger el valor K . Sin embargo, este no debe ser pequeño puesto que está asociado al número de patrones que es capaz de reconocer la red. Cuando este valor es muy grande sólo se incrementa el tiempo de cómputo, pero se garantiza la detección de los patrones, lo cual reviste mayor importancia.

Casos de estudio

A continuación se presentan 2 casos de estudios en los que se generaron mapas de similitud mediante una red neuronal de Kohonen y se comparan con los mapas de similitud obtenidos mediante la metodología original. El primero corresponde a un conjunto de datos sintéticos mientras que el segundo corresponde a un conjunto de datos del Campo Barúa-Motatán, estudiados en (Henríquez *et al.*, 2001).

Ejemplo sintético

Con el objetivo de probar la metodología propuesta, se generó un conjunto de datos sintéticos en el que se pudiera determinar visualmente las zonas que resultan similares a un punto de control o referencia dado. Para ello, se generó un mapa de 10.000 puntos mediante una simulación secuencial gaussiana (Chiles y Delfiner, 1999) y dicho mapa se consideró como la información de un mapa de un atributo. En este se escogieron 3 puntos P1, P2 y P3 que representan 3 puntos de control o referencia. La figura 4a muestra el mapa junto con los 3 puntos antes mencionados. Se observa que las zonas en color rojo son parecidas o similares al punto P1, mientras que las zonas en color azul

son completamente disímiles a éste y parecidas al punto de control P2. De manera análoga, al considerar el punto de referencia P3 se detectan muchas zonas similares a éste en el mapa.

Las figuras 4b y 4c muestran los mapas de similitud respecto al punto de referencia P1 siguiendo la metodología propuesta, en la cual se consideró una red neuronal de Kohonen con $K=1000$ neuronas $N=1$, $M=10000$ y se realizaron 5000 iteraciones, y la metodología original respectivamente.

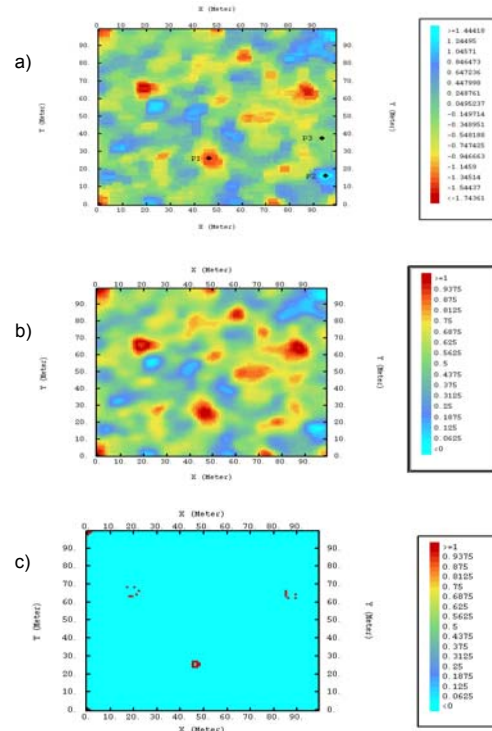


Fig. 4. a) Mapa de datos sintéticos. b) Mapa de similitud respecto a P1 siguiendo la metodología de redes de Kohonen y c) mediante la metodología original.

Se observa como el mapa de similitud siguiendo la metodología propuesta identifica las zonas similares al punto P1 mientras que el mapa de similitud obtenido siguiendo la metodología original obvia algunas zonas, por ejemplo la próxima a las coordenadas (65,85).

Asimismo, el mapa de similitud basado en las redes de Kohonen presenta valores continuos de similitud. Es decir, puntos vecinos poseen valores de similitud próximos, lo

Obtención de mapas de similitud sísmica mediante redes neuronales

cual no ocurre en el mapa de similitud obtenido siguiendo la metodología original.

Puede observarse también en la figura 4b que las zonas similares al punto P2 se muestran como completamente disímiles al punto P1 y que las zonas similares a P3 poseen valores promedios de similitud, lo cual no se observa en el mapa de similitud obtenido mediante la metodología original.

Ejemplo con datos reales

En esta sección se muestra la comparación de un mapa de similitud basado en la metodología original y el obtenido mediante la red neuronal de Kohonen con datos de 4 atributos sísmicos en un campo del occidente de Venezuela. Los atributos corresponden a *Average instantaneous amplitude*, *RMS*, *maximum peak amplitude* y *average vibration energy*, cada uno con un total de 115200 puntos. Dichos atributos fueron estudiados y utilizados por Henríquez *et al.* (2001) para la generación de mapas de similitud siguiendo la metodología original. El interés radica en realizar un análisis de similitud sísmica respecto al pozo A cuyo valor de arena neta petrolífera es muy alto. Para este caso la configuración de la red de Kohonen fue de $K = 5000$ neuronas, $N = 4$, $M = 115200$ y se realizaron 500000 iteraciones.

Las figuras 5a y 5b muestran los mapas de similitud utilizando la metodología propuesta y la metodología original respectivamente.

Se observa en la figura 5 que el mapa de similitud obtenido utilizando la red neuronal de Kohonen identifica las zonas de alta similitud observadas en el mapa de similitud obtenido mediante la metodología original. Más aún, muestra diversas zonas con valores altos de similitud que no se muestran en éste último. De igual manera, es importante observar que zonas clasificadas como completamente disímiles en el mapa de similitud obtenido mediante la metodología original tienen valores intermedios de similitud en el mapa de similitud obtenido mediante la red neuronal. En consecuencia, se pueden detectar zonas que pudieran ser objeto de mayor estudio debido a los valores de similitud conseguidos con el nuevo método que con el anterior quedarían descartadas.

Conclusiones

En este artículo se presentó una metodología basada en el uso de redes neuronales de Kohonen para generar mapas de similitud utilizando múltiples atributos sísmicos. Dicha metodología permite obtener una variación continua de los valores de similitud al mejorar la asignación del grado de

similitud, ya que no es de carácter binario como la metodología de mapas de similitud original. Esta nueva metodología fue probada en un ejemplo controlado de datos sintéticos, en el cual el mapa de similitud generado según ésta resultó superior al obtenido mediante la metodología original, al identificar correctamente las zonas similares a un punto de control, mientras que el mapa de similitud obtenido mediante la metodología original presentaba errores en esta clasificación. La metodología propuesta se utilizó también con datos reales de 4 atributos sísmicos del campo estudiado y los resultados se compararon con el mapa de similitud obtenido mediante la metodología original con este conjunto de datos. En este caso la metodología propuesta identifica zonas de alta similitud que no se muestran claramente en el mapa de similitud obtenido mediante la metodología original.

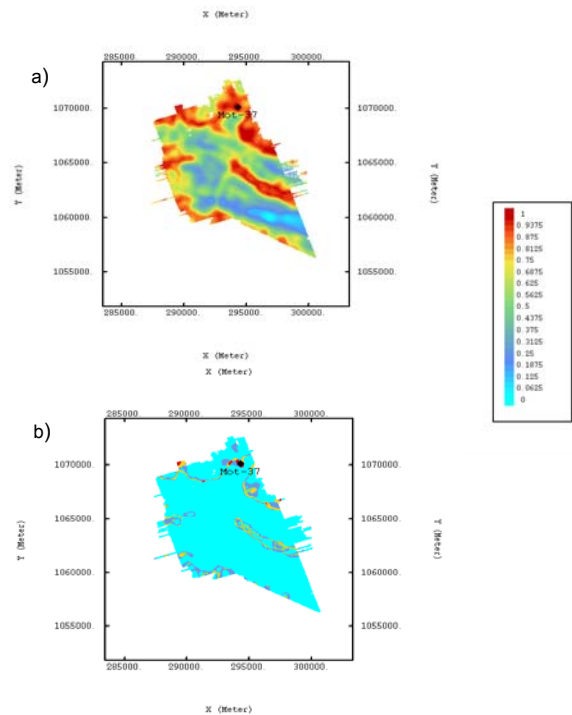


Fig. 5. a) Mapa de similitud respecto al pozo A siguiendo la metodología de redes de Kohonen y b) mediante la metodología original utilizando 4 atributos sísmicos en el campo considerado.

Agradecimientos

Nuestro agradecimiento a Nieves Henríquez de por los datos sísmicos suministrados para el estudio con datos reales; y a PDVSA- Intevp por el permiso para publicar los resultados obtenidos.

Obtención de mapas de similitud sísmica mediante redes neuronales

Referencias

Brown, A. Seismic Attributes and Their Classification. The Leading Edge, October 1996.

Chilès, J. Delfiner, P. Geostatistics. Modeling Spatial Uncertainty. John-Wiley and sons, 1999

Gastaldi, Ch. Biguenet, J. Pazzis, L. Reservoir Characterization from Seismic Attributes .An Example from the Peciko Field (Indonesia). The Leading Edge, March 1997

Haykin, S. Neural Networks. A Comprehensive Foundation. IEEE press, 1994.

Henríquez, N. Castro, S. Pérez, M. Aplicación de Técnicas de Atributos Sísmicos en el Prospecto Horcón. Informe Técnico N° INT-8563, 2001. PDVSA Intevep

Kohonen, T. Self-organization and Associative Memory. Springer Verlag, 1988.

Lawrence, P. Seismic Attributes in the Characterization of Small-Scale Reservoir Faults in Abqaiq Field. The Leading Edge, April 1998.

Michelena, R. González, E. Capello, M. Similarity Analysis: A New Tool to Summarize Seismic Attributes Information. The Leading Edge, April 1998.

Pennington, W. Seismic Petrophysics: An Applied Science for Reservoir Geophysics. The Leading Edge, March 1997.

Russel, B. Hampson, D. Schuelke, J. Quirein, J. Multiattribute Seismic Analysis. The Leading Edge, October, 1997.