

Estimaciones de porosidad empleando métodos basados en geoestadística y redes neuronales

Yessika Blunda, Universidad Simón Bolívar, Luz Camacho, Universidad Simón Bolívar, Robert Porjesz, PDVSA Intevep, Rafael Banchs, PDVSA Intevep.*

Resumen

En los últimos años, el uso de los atributos sísmicos ha ayudado en la extrapolación e interpolación de propiedades de rocas de yacimientos. Existen varias metodologías para tal fin, entre las que se encuentran aquellas que usan un enfoque lineal para la estimación de las propiedades (geoestadística) y aquellos métodos que tratan de conseguir relaciones no lineales entre las propiedades y la información sísmica (redes neuronales). En este sentido, el presente trabajo busca unificar las bondades de los métodos de estimación basados en geoestadística y redes neuronales.

Los métodos usados para la estimación de propiedades, en este caso la porosidad, fueron las redes neuronales, kriging, co-kriging y kriging con deriva externa.

Para tal fin, se generaron tres modelos sintéticos que representaban valores de porosidad y atributos sísmicos. Estos modelos mostraban una relación lineal y cuadrática (modelo no lineal) entre los datos (porosidad y atributos). Luego, las distintas técnicas de estimación fueron aplicadas sobre estos modelos a fin de determinar con cual método se obtenían los mejores resultados.

Los resultados obtenidos a partir de los métodos de estimación indican que la técnica de deriva externa, utilizando como variable secundaria la estimación por redes neuronales, aporta mejores resultados en comparación con los métodos basados en redes neuronales, kriging ordinario y co-kriging.

Introducción

En el área de caracterización de yacimientos se le ha dado gran importancia al uso de las técnicas geoestadísticas, no sólo por su ventaja de integrar información proveniente de diversas fuentes, tales como petrofísica, geofísica, geología, entre otras, sino que también permiten cuantificar la incertidumbre en los resultados obtenidos. Por otro lado, el empleo de las redes neuronales como método de estimación también ha tomado gran auge en la industria petrolera, ya que son capaces de estimar propiedades a partir de atributos encontrando relaciones no lineales entre ellos.

Las técnicas geoestadísticas toman en cuenta de cierta manera la variabilidad espacial de los atributos en un yacimiento. Éstas, mediante la integración de datos duros (pozos) con datos secundarios, como los atributos sísmicos,

son capaces de estimar propiedades petrofísicas en todo el volumen de un yacimiento y proveer una medición de la incertidumbre en los resultados obtenidos.

Los métodos de estimación kriging, co-kriging y kriging con deriva externa arrojan un único resultado, impidiendo obtener una medida de la incertidumbre. Por otra parte, esta única solución generalmente se caracteriza por ser “suave”, lo que hace que estas técnicas no capten la heterogeneidad del medio.

Otra desventaja de estas técnicas es el difícil uso de varios atributos al mismo tiempo, además de los valores de la propiedad petrofísica en los pozos, durante la estimación. Esto se debe a que la construcción del variograma cruzado resulta ser un proceso muy complejo. Por esta razón, se utilizó un solo atributo, además de los valores de porosidad en los pozos, en la estimación por co-kriging.

Por otro lado, las redes neuronales pueden ser entrenadas de forma tal que encuentren relaciones existentes (lineales o no lineales) entre las distintas variables y, seguidamente, puedan estimar las propiedades en un volumen¹.

Al igual que las técnicas de estimación geoestadísticas, una red entrenada arroja un único resultado, lo cual limita la posibilidad de conocer la incertidumbre, y por lo general, también se caracteriza por ser “suave”.

A diferencia del método geoestadístico co-kriging, las redes neuronales permiten estimar propiedades petrofísicas utilizando múltiples atributos, sin inconvenientes durante el proceso de estimación.

El objetivo principal de este trabajo es el uso de una metodología híbrida que incluya las ventajas de las técnicas basadas en redes neuronales (no linealidad, no estacionaridad e integración de múltiples atributos) y las técnicas geoestadísticas (manejo de correlación espacial).

Para lograr este objetivo se generó una serie de modelos sintéticos representando los datos de pozos y atributos sísmicos, a los cuales fueron aplicados los métodos de estimación antes mencionados.

Estimación de porosidad

Fundamentos Teóricos

Redes Neuronales. Hoy en día, el problema de estimación de propiedades puede ser tratado por métodos nuevos y avanzados que incorporan elementos de análisis no lineal; uno de esos métodos es el de las redes neuronales. Ellas pueden ser entrenadas de forma tal que se puedan encontrar relaciones existentes entre los datos de pozos y los datos sísmicos en las cercanías de dichos pozos².

Las redes neuronales artificiales tratan de imitar el comportamiento funcional de las redes biológicas, es decir, reciben y procesan señales provenientes de otras neuronas, generan y conducen pulsos nerviosos y posteriormente los transmiten a otras neuronas. En este caso, una red neuronal puede ser definida como un ensamblaje de elementos de procesamiento llamados neuronas³. Visto como un proceso matemático, en una red neuronal se debe introducir un conjunto de N atributos (señal de entrada), a la cual se le realiza una suma pesada. Seguidamente, a dicha suma se le aplica una función de activación, (por ejemplo Ec. 1), que dará como resultado una señal de salida¹.

$$\Gamma(x) = \frac{1}{1 + e^{-x}} \quad (\text{Ec. 1})$$

Las redes neuronales aportan un único resultado que por lo general, se caracteriza por ser “suave”, lo cual impide que mediante esta técnica se cuantifique la incertidumbre y que se tome en cuenta la heterogeneidad del medio.

Geostatística- Los métodos de estimación utilizados en este estudio fueron kriging, co-kriging y kriging con deriva externa.

Al igual que la red neuronal, cada uno de estos métodos de estimación arrojan una única imagen que generalmente también se caracteriza por ser “suave”, por lo que no necesariamente reproducen la variabilidad (heterogeneidad) de la propiedad estudiada⁴ (la varianza de los datos es mayor que la varianza de la estimación), y tampoco proporcionan una medición de la incertidumbre.

Sin embargo, si se utilizan las técnicas de simulación, es posible obtener varias realizaciones o imágenes equiprobables del yacimiento que respetan factores como la heterogeneidad, direcciones preferenciales, entre otras, y además permiten cuantificar la incertidumbre del modelo. Por esta razón, estas técnicas serán aplicadas a estos mismos modelos en trabajos futuros, de manera de obtener una perspectiva más amplia para determinar las ventajas y desventajas de todas estas técnicas en general.

El método de estimación por kriging considera la correlación espacial entre los datos mediante funciones de variograma o de covarianza, lo que permite describir y

respetar de cierta manera la continuidad de los cuerpos, tales como canales.

Por otro lado, los métodos co-kriging y kriging con deriva externa, permiten integrar datos secundarios, como por ejemplo atributos sísmicos.⁵

Una de las desventajas de estas técnicas, específicamente co-kriging, es que al utilizar más de un atributo, además de los datos de pozos de la propiedad, el proceso para la integración de las diferentes variables mediante variogramas cruzados resulta bastante complejo.

Metodología y resultados

En el desarrollo de este estudio se generó una serie de modelos de datos sintéticos, los cuales incluyen un mapa de porosidad y un cierto número de atributos sísmicos, a los cuales se le aplicaron diferentes técnicas de estimación basadas en geoestadística y redes neuronales. Los modelos sintéticos permiten validar los métodos de estimación.

Generación de datos sintéticos. A objeto de estudiar las posibles ventajas y desventajas de los distintos métodos de estimación se generaron tres modelos diferentes. En el primer modelo, la relación entre la porosidad (ϕ) y los atributos es lineal con un coeficiente de correlación (ρ) relativamente alto (mayor a 0.6 aproximadamente)⁶. Este modelo se generó por simulación no condicional por el método de bandas rotantes.

En el segundo modelo se tomaron los datos del modelo 1 y se procedió a suavizar cada una de las variables obtenidas anteriormente mediante un filtro paso bajo⁷.

Finalmente, el tercer modelo presenta una relación no lineal entre la porosidad y los atributos. Se le agregó también ruido en los atributos. Para ello, inicialmente se generó una variable mediante una simulación no condicional empleando el método de bandas rotantes y seguidamente se generaron cinco atributos empleando la ecuación 2:

$$A = a(\phi)^2 + b(\phi) + c + \text{simulated_gaussian}(m, n) \quad (\text{Ec. 2})$$

donde A representa el atributo, ϕ la porosidad, a , b y c constantes elegidas arbitrariamente, m representa la media y n la varianza del ruido. El ruido es aplicado mediante una simulación monte-carlo.

Los mapas de porosidad obtenidos para cada modelo se presentan a continuación en las Figuras 1, 2 y 3:

Estimación de porosidad




Fig. 1: Mapa de porosidad para el modelo 1. Los asteriscos representan las localizaciones de los pozos.




Fig. 2: Mapa de porosidad para el modelo 2. Los asteriscos representan las localizaciones de los pozos.




Fig. 3: Mapa de porosidad para el modelo 3. Los asteriscos representan las localizaciones de los pozos.

Criterios de comparación. Para determinar las ventajas y desventajas de los métodos de estimación aplicados a los modelos generados, se consideraron los siguientes criterios:

- Comparación de los coeficientes de correlación entre el modelo sintético y la estimación, obtenidos para cada modelo.
- Comparación visual de los mapas resultantes con los mapas originales de cada modelo.

El primero de ellos, permite evaluar cuantitativamente los resultados obtenidos a partir de los distintos métodos aplicados. Con el segundo criterio, es posible verificar subjetivamente, la similitud entre los mapas resultantes y los mapas originales de los tres modelos mediante la visualización de los mismos.

Estimación por kriging. El método de estimación por kriging se aplicó a los tres modelos generados, cuyos resultados se muestran en las Figuras 4, 5 y 6 conjuntamente con el valor del coeficiente de correlación entre la porosidad original y la estimación (ρ).

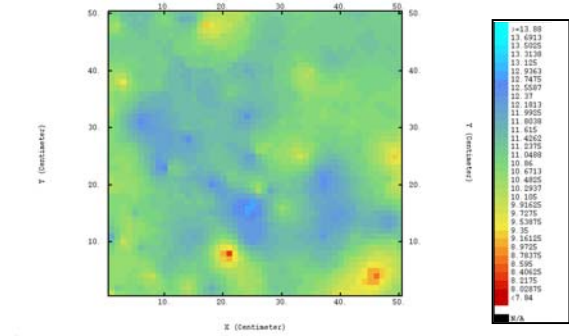


Fig. 4: Mapa de porosidad estimada por kriging para el modelo 1. ($\rho = 0.2174$)




Fig. 5: Mapa de porosidad estimada por kriging para el modelo 2. ($\rho = 0.8065$)

Estimación de porosidad




Fig. 6: Mapa de porosidad estimado por kriging para el modelo 3. ($\rho=0.9818$)




Fig. 7: Mapa de porosidad estimado por cokriging para el modelo 1. ($\rho=0,8085$)

A partir de estos resultados, se observa que el coeficiente de correlación para los modelos 2 y 3 es cercano a 1, por lo que es posible considerar una estimación aceptable para estos modelos. Por otro lado, el coeficiente de correlación para el modelo 1 es bastante bajo, resultado que era de esperarse, ya que el modelo sintético es producto de una simulación estocástica sin suavizado, mientras que la estimación obtenida es suavizada por el kriging.

Comparando los mapas de las Figuras 4, 5 y 6 con los mapas de las Figuras 1, 2 y 3 respectivamente, se observa que los mapas, original y estimado, para el modelo 3 son muy similares, al igual que para los mapas del modelo 2 pero en menor magnitud. Mientras que para el modelo 1, hay una notable diferencia entre ellos. Esto permite soportar gráficamente, la información aportada por los coeficientes de correlación para cada modelo.




Fig. 8: Mapa de porosidad estimado por cokriging para el modelo 2. ($\rho=0,8416$)

Estimación por co-kriging. Por la complejidad en la elaboración de variogramas cruzados para la integración de datos sísmicos con los datos de pozos, en este estudio solamente se utilizó un atributo, el cual fue escogido por su mayor correlación con la propiedad petrofísica a estimar.

Los resultados obtenidos a través de esta técnica se presentan en las Figuras 7, 8 y 9, al igual que los coeficientes de correlación entre la porosidad original y la estimada, correspondientes a cada modelo.




Fig. 9: Mapa de porosidad estimado por cokriging para el modelo 3. ($\rho=0,9878$)

Estimación de porosidad

Comparando estos resultados con los arrojados por el método kriging, los valores de los coeficientes de correlación para cada modelo son mucho más altos que aquellos valores obtenidos mediante la técnica kriging.

La similitud entre los mapas resultantes por este método para los modelos 2 y 3 (Figuras 8 y 9), con los correspondientes mapas originales es poco menor que la similitud observada en los mapas derivados del kriging (Figuras 5 y 6).

Sin embargo, para el modelo 1, el mapa obtenido por co-kriging es notablemente más similar al mapa de porosidad original en comparación con el mapa de porosidad estimada por kriging (Ver Figuras 1, 4 y 7). Esta diferencia también se ve reflejada en los valores de coeficiente de correlación correspondientes a cada uno de ellos, observando que por kriging este valor es bajo, mientras que por co-kriging, es mucho más alto. Ésto evidencia el aporte significativo que realiza la integración de datos sobre los resultados.

Estimación por redes neuronales. El entrenamiento de la red neuronal se llevó a cabo mediante el algoritmo de “backpropagation”, el cual calcula los pesos necesarios para el proceso de estimación⁴. Antes de comenzar el entrenamiento, se deben tomar todos los datos de pozos disponibles y clasificarlos en dos grupos: set de entrenamiento y set de prueba. Esta clasificación se debe realizar de forma aleatoria, de modo que se garantice que los dos subconjuntos de datos obtenidos no posean datos en común. Después de haber entrenado la red, se comenzó el proceso de estimación. La representación gráfica de una red neuronal se presenta en la Figura 10.




Fig. 10: Representación esquemática de una red neuronal.

Las entradas corresponden a los atributos y la salida a la propiedad (porosidad estimada).

Los parámetros empleados para cada uno de los distintos modelos se muestran en la Tabla 1.

Parámetro	Modelo 1	Modelo 2	Modelo 3
Nº de capas	4	4	4
Neuronas en cada capa*	09 10 10 01	09 10 10 01	05 11 11 01
Set de entrenamiento	1320	1320	1320
Set de prueba	680	680	680

* El primer término representa el número de neuronas (atributos) en la primera capa, los dos términos siguientes el número de neuronas en las capas 2 y 3, y finalmente la propiedad petrofísica estimada en la capa de salida.

Tabla 1: Datos de entrenamiento y estimación por redes neuronales.

Los resultados obtenidos se muestran en las Figuras 11, 12 y 13.




Fig. 11: Estimación por redes neuronales para el modelo 1 ($\rho=0.8731$)




Fig. 12: Estimación por redes neuronales para el modelo 2 ($\rho=0.9291$)

Estimación de porosidad




Fig. 13: Estimación por redes neuronales para el modelo 3 ($\rho = 0.9784$).

Gráficamente, los resultados obtenidos con este método para el modelo 1 y, especialmente, para el modelo 2 muestran una mayor similitud con los mapas originales que aquellos resultados provenientes de la estimación por kriging y por co-kriging. Para el modelo 3, comparando los mapas resultantes por los tres métodos aplicados, el más aceptable es aquel obtenido mediante kriging, por su mayor semejanza con el mapa original, seguido del mapa arrojado por co-kriging, y por último, el aportado por redes neuronales.

Estas observaciones también se reflejan en los valores de los coeficientes de correlación para cada uno de los modelos, los cuales son mucho más altos para los modelos 1 y 2, y un poco más bajo para el modelo 3 en comparación con los valores obtenidos por kriging y co-kriging

Estimación por kriging con deriva externa. Con el objetivo de aprovechar las ventajas de los dos enfoques, se aplicó kriging con deriva externa empleando como variable secundaria la estimación por redes neuronales.

Es importante señalar que la variable secundaria siempre influye en la estimación de la variable primaria por kriging con deriva externa, aunque no haya correlación entre ellas. Cabe destacar que la construcción de los modelos sintéticos para este estudio, se realizó tomando en cuenta este problema: se sabe que la correlación entre las variables existe.

Los resultados obtenidos mediante este método de estimación se presentan en las Figuras 14, 15 y 16.




Fig. 14: Estimación por deriva externa para el modelo 1 ($\rho = 0.8318$)




Fig. 15: Estimación por deriva externa para el modelo 2 ($\rho = 0.9298$)




Fig. 16: Estimación por deriva externa para el modelo 3 ($\rho = 0.9942$)

Estimación de porosidad

Los coeficientes de correlación obtenidos por este método híbrido son mucho más cercanos a 1 para los modelos 2 y 3, comparados con los coeficientes obtenidos en los métodos anteriores. Sin embargo, para el modelo 1, el coeficiente de correlación más alto fue aquel arrojado por el método de redes neuronales, seguido del resultado del kriging con deriva externa, co-kriging y finalmente kriging.

Por otro lado, los mapas resultantes en esta aplicación para los modelos 2 y 3, se asemejan más a sus correspondientes mapas originales, que aquellos mapas producto de los otros métodos utilizados. Mientras que, para el modelo 1, el mapa obtenido por este método de estimación es consistente con el valor del coeficiente de correlación, ya que, comparándolos con los resultados obtenidos por el método de redes neuronales, el mapa de porosidad estimada es menos parecido al original.

De acuerdo con todos los resultados, estas técnicas de estimación son una herramienta útil para la estimación de propiedades. Sin embargo, el uso de la técnica de kriging con deriva externa, que combina diferentes ventajas de los dos enfoques, es capaz de aportar resultados más aceptables según los criterios considerados para evaluarlos. En la Tabla 2 se muestran los coeficientes de correlación entre la porosidad estimada y original, arrojada por cada método para los tres modelos.

Modelo	Kriging	Cokriging	R.N.	K.D.E
1	0.2174	0.8085	0.8731	0.8318
2	0.8065	0.8416	0.9291	0.9298
3	0.9818	0.9878	0.9784	0.9942

Tabla 2: Coeficientes de correlación entre porosidad original y estimada por los distintos métodos usados para los tres modelos generados. R.N.: Redes neuronales. K.D.E.: kriging con deriva externa.

Conclusiones y Recomendaciones

Como se mencionó anteriormente, dos criterios fueron tomados en cuenta para la validación de los métodos:

- Comparación de los coeficientes de correlación entre el modelo sintético y la estimación, obtenidos para cada modelo.
- Comparación visual de los mapas resultantes con los mapas originales de cada modelo.

Mientras más alto el valor del coeficiente de correlación y mayor similitud entre los mapas comparados, mayor es la aceptación de los métodos usados. De esta manera, el método de deriva externa (empleando como variable

secundaria el resultado de la estimación por redes neuronales) fue considerado como el método más adecuado bajo los criterios tomados en cuenta. Así, este método híbrido que combina las bondades de las técnicas basadas en redes neuronales (no linealidad, no estacionaridad y soporte de múltiples atributos) y las técnicas geoestadísticas (correlación espacial, entre otras), representa una buena oportunidad para mejorar los resultados de estimaciones de porosidad para diversas estructuras o morfologías del subsuelo.

Los valores obtenidos mediante el método de kriging muestran un coeficiente de correlación menor comparado con los obtenidos para el resto de los métodos aplicados en este estudio. Esto indica que la integración de otros datos influye de manera significativa sobre los resultados finales, proporcionando soluciones más aceptables que aquellos en donde solo se utilizan los datos de pozos.

Los resultados provenientes de la estimación por co-kriging, presentan una mejor estimación de la porosidad que la realizada por kriging, sin embargo, en casos en donde es de interés integrar múltiples atributos, es recomendable usar otra técnica que permita esta integración sin mayores complejidades durante el proceso, por ejemplo, las redes neuronales.

Las estimaciones por redes neuronales también arrojan excelentes resultados a la hora de estimar porosidad, pero se deben tomar muy en cuenta los parámetros para el entrenamiento de la red, así como el número de veces en que es realizado este proceso, pues de esto dependen los resultados que se obtengan. La desventaja de esta técnica es que mediante ella no se cuantifica la incertidumbre, ya que solamente proveen una solución para representar infinitas alternativas.

Las técnicas de estimación usualmente generan modelos suaves, de allí que de acuerdo a los criterios considerados, los resultados obtenidos para el modelo 2 son mucho más aceptables que los correspondientes al modelo 1. Ver Figuras 4, 5, 14 y 15.

Es importante destacar, que en un trabajo futuro se aplicará a estos mismos modelos la técnica de simulación secuencial gaussiana⁷ con el cual se busca describir la incertidumbre. Esto se llevará a cabo mediante la generación de posibles escenarios de porosidad respetando la información disponible. Con este método se podrá cuantificar la incertidumbre y, además, hacer un análisis del riesgo económico mediante el conocimiento de la producción de fluidos, cantidad de petróleo recuperado al término de cierto tiempo, entre otros.

Es recomendable aplicar de nuevo cada una de las distintas estimaciones pero con datos reales de pozos y atributos. Por otra parte, es necesario realizar más pruebas de

Estimación de porosidad

entrenamiento de la red neuronal a fin de obtener los mejores parámetros posibles para cada modelo y, finalmente, usar otros criterios de ranqueo entre las estimaciones obtenidas.

Agradecimientos

Los autores agradecen a Juan Ramón Jiménez por ser parte de la idea inicial de este trabajo.

Referencias

1. Van Der Baan, Mirko y Jutten, Christian, (2000). Neural Networks in geophysical applications. Geophysics, Jul-Ago, Vol 65, N° 4, pp. 1032 – 1047.
2. Banchs, Rafael y Michelena, Reinaldo, (2000). Confidence intervals for petrophysical property estimations. Informe Técnico INT – 7604,2000. PDVSA Intevep.
3. Aguilar, José y Rivas, Francklin, (2001). Introducción a las técnicas de computación inteligente. Universidad de los Andes, Mérida, Venezuela.
4. Samper, F. Javier y Carrera Ramírez, Jesús, (1990). Geoestadística, aplicaciones a la hidrología subterránea. Centro Internacional de Métodos Numéricos en Ingeniería. Gráficas Torres, p. 479. Barcelona, España.
5. Chilès, Jean Paul, y Delfiner, Pierre, (1999). Geostatistics: Modeling Spatial Uncertainty, Wiley Interscience Publication, p. 695.
6. Blunda, Yessika, (2002). Estimaciones de porosidad empleando métodos basados en geoestadística y redes neuronales. Proyecto de Grado, Universidad Simón Bolívar, Venezuela.
7. www.geovariances.fr