

Con la misma arquitectura de IA que usa ChatGPT, el modelo predijo resistividad e impedancias a partir de la sísmica con menos error que la inversión tradicional y señaló nuevas locaciones en un campo maduro.

Caracterización sísmica de arenas de baja permeabilidad en Cuenca Austral mediante la aplicación de modelos *deep learning* tipo generative transformer. **Caso de estudio: Cuenca Austral**

Por ***Nicolás Bufaliza*** (CGC), ***Marcos Victoria*** (consultor independiente; CGC al momento del trabajo), ***Juan Cruz Sosa, Enmanuel Santana e Iván Sánchez*** (Machine Learning 4 DATA)

Este trabajo fue seleccionado del 12º Congreso de Exploración y Desarrollo de Hidrocarburos, *Simposio: Geofísica.*

El uso de inversiones elásticas es una pieza fundamental para la caracterización sísmica de reservorios. Este tipo de caracterización permite calcular propiedades elásticas de las rocas y correlacionarlas con propiedades petrofísicas para cuantificar y caracterizar los reservorios de interés. Algunas de las técnicas más utilizadas son enfoques determinísticos dependientes de la ondícula o de un modelo de reflectividad del subsuelo como son la inversión simultánea (Hampson et al. 2005), la inversión sparse-spike (Oldenburg et al. 1983) y la coloured inversion (Lancaster and Whitcombe 2000), procesos ampliamente aplicados en la industria.

Además, se han desarrollado métodos probabilísticos que dependen de un marco estadístico sustentado por modelos estructurales y restricciones espaciales y verticales dadas por variogramas, como la inversión sísmica estocástica. Esta técnica permite evaluar la incertidumbre del modelo mediante procesos iterativos con múltiples realizaciones. Como principal limitación, la inversión estocástica está fuertemente condicionada por el modelo estructural, la calidad de las estadísticas empleadas y de la correcta representación de las correlaciones espaciales. Métodos más avanzados, como la Full Waveform Inversion (FWI), buscan ajustar la ecuación de onda completa para obtener modelos con mayor contenido de frecuencias y captar fenómenos complejos como anisotropía y atenuación. Sin embargo, su aplicación está condicionada por la necesidad de un modelo inicial robusto y por un costo computacional alto.

Todos los métodos de caracterización sísmica mencionados anteriormente dependen del modelo de propagación de ondas del subsuelo utilizado para resolver el problema inverso, estos modelos son denominados "model-driven" (basado en modelos). Asumiendo que las propiedades de las rocas son una función de uno o varios atributos sísmicos, se pueden generar modelos "data-driven" (basados en datos), independientes de un modelo convolucional basado en la ondícula, a partir de regresiones que permitan minimizar el error entre el dato de pozo (label) y el dato sísmico (feature). La incorporación de redes neuronales y técnicas de aprendizaje automático (deep-learning) permitió la posibilidad de desarrollar de manera extensa estos modelos con la capacidad de captar relaciones no-lineales en el dato sísmico. Algunas de las redes neuronales incluidas en los flujos de trabajos de caracterización sísmicas en la industria y en softwares comerciales son FeedForward Neural Network (FFNN), Probabilistic Neural Network (PNN) y Convolutional Neural Network (CNN). Sin embargo, estas arquitecturas presentan limitaciones para capturar relaciones de largo alcance y dependencias complejas en datos sísmicos, lo que motiva la exploración de enfoques más avanzados como los modelos tipo Transformer.

En el caso de estudio propuesto, la caracterización sísmica de reservorios de baja permeabilidad en la Formación Magallanes presenta desafíos adicionales debido a la limitada resolución intrínseca del dato sísmico y a la complejidad de las relaciones entre atributos sísmicos y propiedades petrofísicas. En particular, los reservorios saturados con gas pueden presentar respuestas elásticas similares tanto para condiciones de baja como alta saturación, dificultando su discriminación mediante metodologías convencionales de interpretación sísmica e inversión elástica. Por lo tanto, en este trabajo se presenta un desarrollo de deep learning empleando una arquitectura de redes neuronales tipo Transformer. Este tipo de redes se popularizó a partir de la publicación "Attention Is All You Need" (Vaswani et al. 2017), que inicialmente fue aplicado para la traducción automática de texto, y que luego se extendió su aplicación a modelos de lenguaje natural. Su rasgo distintivo es el mecanismo de self-attention, que evalúa de manera simultánea todas las entradas del modelo para identificar y seleccionar la información más relevante, mejorando la eficiencia y la capacidad de predicción. En el contexto de datos sísmicos, esta capacidad permite capturar dependencias espaciales y verticales complejas entre atributos, superando las limitaciones de arquitecturas más locales como las redes convolucionales.

La aplicación de un modelo Transformer en este estudio tiene dos ventajas principales. Por un lado, permitió generar directamente volúmenes de propiedades de roca, como por ejemplo un volumen 3D de resistividades, asociado al comportamiento del reservorio analizado. Por otro lado, se lograron mejoras cualitativas y cuantitativas respecto a inversiones de trazas previas realizadas en el área. Esto se atribuye a la optimización de hiper-parámetros dentro de la arquitectura de la red neuronal y a su capacidad para capturar relaciones complejas entre la sísmica y los logs de pozos usados como etiquetas. Así, la metodología propuesta combina fundamentos geofísicos con técnicas avanzadas de aprendizaje automático, permitiendo una caracterización más robusta del reservorio en escenarios donde los métodos tradicionales presentan limitaciones.

Complementariamente, los volúmenes de propiedades de rocas obtenidos fueron integrados mediante técnicas no supervisadas de clasificación y segmentación basadas en Self-Organizing Maps (SOM), permitiendo discriminar facies sísmicas y definir geocuerpos asociados a los intervalos de interés.

Ubicación del área de estudio y reservorio

El área de estudio corresponde al yacimiento El Cerrito Oeste (ECO), operado por Compañía General de Combustibles (CGC), ubicado 70 km al sureste de la ciudad de El Calafate en la provincia de Santa Cruz. Este yacimiento se encuentra en el bloque El Cerrito (EC) (Fig. 1), que junto a los bloques Cañadón Deus y El Campamento totalizan un área de más de 700 km^2 cubierta por sísmica 3D adquirida entre los años 2007 y 2008 y reprocesada en 2019.

Los reservorios estudiados son las areniscas de la Fm. Magallanes correspondientes a clinoformas progradantes hacia el SE comprendidos entre la discordancia D3-Maastrichtiano basal y D4-Post Daniana. De base a tope de dichas discordancias, las unidades correspondientes a los reservorios principales se nombran informalmente M3-M2-M1-M0, siendo M2 el principal reservorio descripto en el presente trabajo. Esta prolífica unidad productora de gas se caracteriza por areniscas y areniscas arcillosas gris verdosa con granulometría de grano medio

a muy fina y con permeabilidad entre 0,1 a 1,3mD (Jait et al. 2018).

El yacimiento ECO, productor de gas de las arenas de M2 fue descubierto con la perforación de un pozo de avanzada hacia el noroeste del yacimiento El Cerrito (productor de M0) en el año 2017. Desde ese momento a diciembre de 2025, se perforaron 52 pozos (9 de ellos pozos horizontales con ramas de 1600 m en promedio). Al día de la fecha, el yacimiento cuenta con 44 pozos en producción y una acumulada de gas de más de 60 BCF. La delineación y desarrollo del yacimiento se llevó a cabo en gran medida a partir de anomalías sísmicas de AVO Clase III. Además, se realizaron inversiones sísmicas y procesos especiales para caracterizar cualitativa y cuantitativamente los reservorios (ver Victoria et al. 2022).

Metodología. Modelo transformer

Las principales motivaciones del estudio en un campo maduro como lo es ECO fueron dos. Por un lado, la validación de la metodología propuesta y la inmediata comparación de resultados con pozos ya perforados, pero no incluidos en las predicciones (pozos blind), así como con inversiones elásticas previas y caracterizaciones sísmicas basadas en anomalías de AVO. Por otro lado, la mejora en la ubicación de las locaciones marginales del área de estudio, y la identificación de nuevas zonas prospectivas mediante la caracterización sísmica propuesta.

El flujo de trabajo propuesto consiste en tres etapas principales: generación de atributos sísmicos (features), entrenamiento del modelo Transformer en una etapa auto-supervisada usando los features seguida de una etapa supervisada con datos de pozo, y generación de volúmenes 3D de propiedades de roca para su posterior análisis e interpretación.

Transformer Generative AI

Las redes neuronales tipo transformer fueron desarrolladas por Vaswani et al. 2017 con el objetivo de mejorar la performance en modelos de traducción automática. Debido a su alto poder predictivo desde su desarrollo se extendió su uso a incontables cantidades de aplicaciones incluyendo los modelos de lenguaje generativos como ChatGPT (generative pre-trained transformer). Su uso se hizo tan extenso que la publicación original "Attention is all you need" (Vaswani et al. 2017) tiene, a diciembre de 2025, más de 200.000 citas formales. Su principal característica y a lo cual debe su capacidad predictiva es el uso de capas de atención que tienen la posibilidad de escanear simultáneamente la información y mantener lo que realmente es importante (el dato útil). La figura 2 resume la arquitectura de un modelo Transformer.

Para el desarrollo de este tipo de redes neuronales aplicadas a datos sísmicos y de pozo, se estableció un flujo de trabajo que consta de 3 etapas.

1. Generación de features sísmicos

Para alimentar el modelo predictivo se generaron features sísmicos a partir de volúmenes procesados. El dato sísmico de entrada corresponde a la unificación de tres survey sísmicos adquiridos en los años 2005 (Cañadón Deus), 2006 (El Cerrito) y 2007 (El Campamento), y reprocesados en conjunto en el año 2019 cubriendo un área total de aproximadamente 878 km^2. Se utilizaron volúmenes sísmicos en dominio del tiempo migrado pre-stack (PSTM), incluyendo tanto el volumen full stack como la de sumas de ángulos parciales (features primarios):

- PSTM_FullStack
- 0-12°: PSTM_Near
- 12-24°: PSTM_Mid
- 24-36°: PSTM_Far
- 36-45°: PSTM_UFar

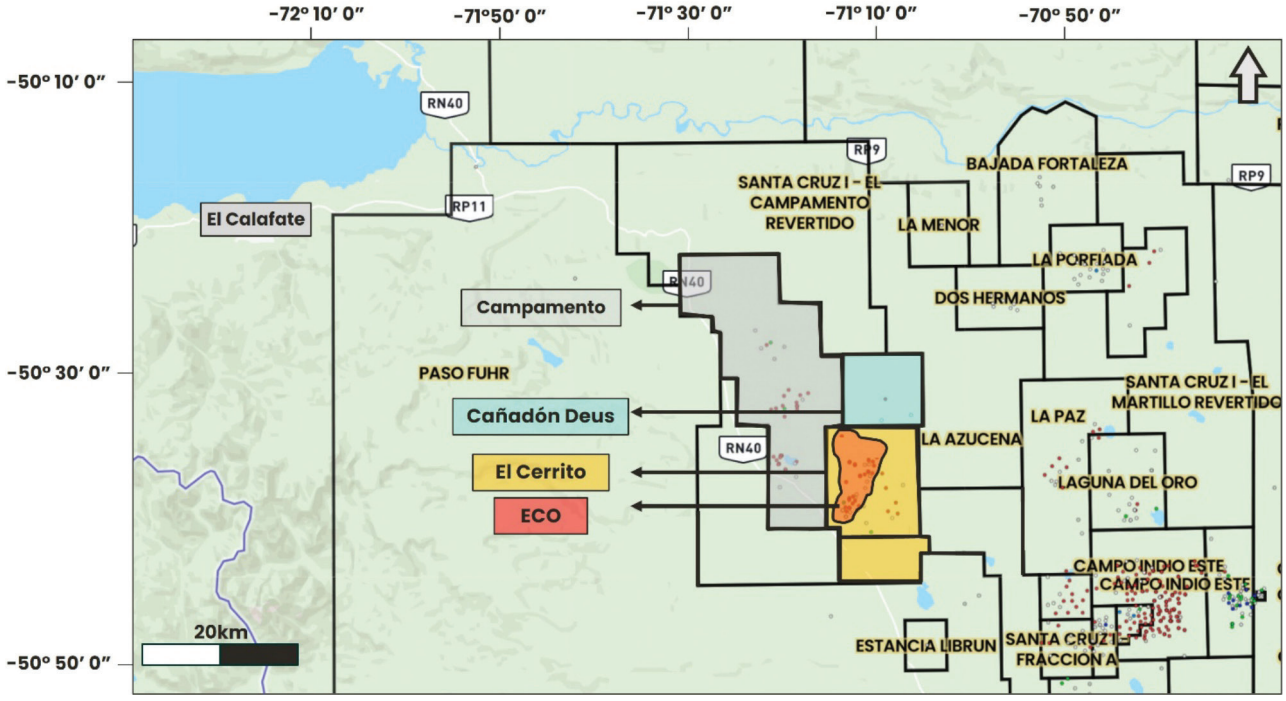


Figura 1. **Ubicación del yacimiento ECO.**

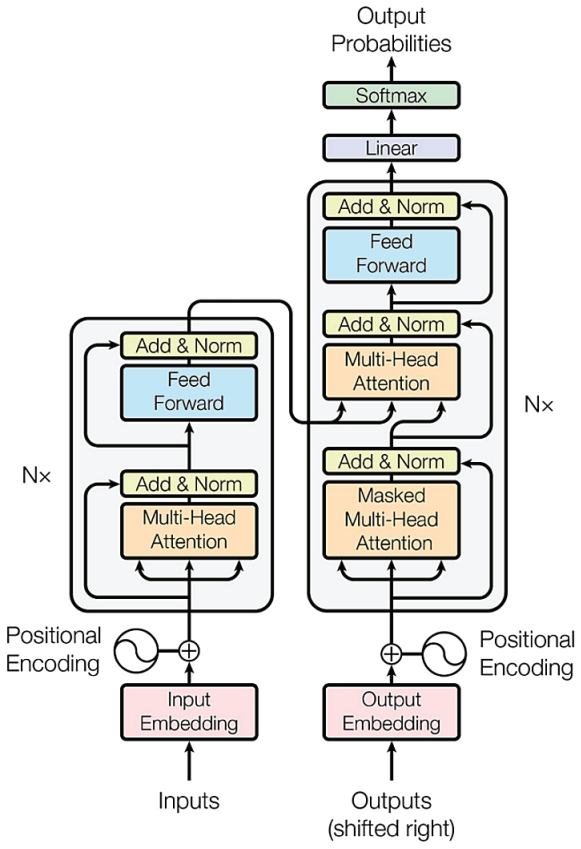


Figura 2. **Esquema de la arquitectura de un modelo Transformer (Vaswani et al. 2017).**

El propósito detrás de la generación de features sísmicos es la posibilidad de maximizar la información relevante contenida en el dato y permitir a las redes neuronales encontrar relaciones complejas, y de esta manera, recuperar información de las amplitudes y geometrías de cada volumen de entrada.

Los volúmenes sísmicos se acotaron vertical y espacialmente para contener el área de interés. En el dominio temporal: 900-1300 ms con un muestreo de 1 ms; y espacialmente se recortó a un área de aproximadamente 270 $km^{2.}$

A partir de los cinco features primarios se generaron features adicionales, entre ellos:

- Descomposición espectral usando Basis Pursuit Decomposition con frecuencias entre 8 y 64Hz y con incrementos de banda de 10Hz.
- Detección de geometrías secundarias del dato sísmico de entrada mediante la aplicación de la suma ponderada de componentes espectrales, Seismic Geometric Decomposition (SGD, Victoria et al. 2022).
- Relative Acoustic Impedance (RAI) preservando la baja frecuencia;
- Extended Elastic Impedance (EEI) reflectivities
- Modelos de baja frecuencia para Impedancia P, S, y densidad

Los criterios utilizados para la selección de los features mencionados se basaron tanto en fundamentos teóricos como en antecedentes documentados en la literatura. A continuación, se detalla el por qué de la inclusión de cada uno de los ítems mencionados.

La suma de ángulos parciales (angle stacks) y sus variaciones relativas son sensibles, de acuerdo con las ecuaciones de Zoeppritz (Zoeppritz, 1919), a contrastes de impedancia de onda P, S, y Densidad. Por lo tanto, estos volúmenes sísmicos aportan información útil para recuperar dichos parámetros.

Las descomposiciones espectrales han sido utilizadas para la caracterización de reservorios y como potencial indicador de hidrocarburos (por ejemplo, Castagna et al. 2003; Partyka et al. 1999), incluyendo atributos derivados de descomposiciones espectrales como la variación de amplitud con la frecuencia (AVF) (Wihardy and Khairy 2021; Mandong et al. 2021).

Se incluyeron también atributos orientados a mejorar la resolución vertical, preservando la geometría del dato sísmico (SGD). De esta manera se mantienen las geometrías espaciales del dato sin depender de interpretaciones subjetivas de horizontes guías.

Los atributos de RAI y EEI se usaron como features de entrada ya que constituyen una representación directa de los parámetros relevantes a predecir. Estos atributos, además de las variaciones de reflectividades proporcionada por la sísmica, incorporan variaciones de propiedades elásticas de roca y de propiedades calibradas a partir de dato de pozo, como es el caso de la EEI (Whitcombe et al. 2002).

Finalmente, se utilizaron modelos de bajas frecuencias como features de entrada debido a que el dato sísmico es intrínsecamente banda limitada y los modelos de aprendizaje con redes neuronales tienden a sobreajustar (overfitting) el dato sin una tendencia de baja frecuencia. El sobreajuste corresponde a un ajuste excesivo durante el entrenamiento, pero con una pobre capacidad de generalización sobre datos no utilizados en esta etapa. De esta manera, un modelo con overfitting va a producir un resultado deficiente desde el punto de vista predictivo. Así, la incorporación de tendencias de baja frecuencia permite restringir las predicciones y estabilizar la respuesta del modelo. Los features de baja frecuencia se construyeron a partir de 15 pozos distribuidos de manera uniforme en el área de interés, horizontes regionales suavizados espacialmente promediado cada 11 trazas, un filtro pasabajos con un corte de alta frecuencia de 8-12Hz y usando una interpolación inversa al cuadrado de la distancia entre pozos.

2. Arquitectura neuronal Transformer-Autoencoder

La arquitectura del modelo se puede resumir en dos etapas principales, una etapa de aprendizaje no supervisado (o auto-supervisado) basada sólo en el dato sísmico, y una etapa de entrenamiento supervisado que incluye el dato de pozo como etiqueta (label). Tanto el dato sísmico como los logs de pozo ingresan al modelo como secuencias temporales asociadas a una posición espacial definida por inline (IL), crossline (XL) y tiempo doble de tránsito (TWT). El dato sísmico fue remuestreado a 1ms y los logs de pozos son previamente filtrados a 150 Hz para aproximar su contenido de frecuencias al dato

sísmico sin perder demasiado detalle vertical. Los pozos son vinculados al dominio sísmico mediante una tabla tiempo profundidad previamente calibrada usando sismogramas sintéticos. Dado que los pozos utilizados fueron verticales, a la traza del pozo se le asigna una única posición espacial IL-XL, mientras que cada posición TWT del dato sísmico se le corresponde la muestra de pozo más cercana. De esta manera, cada traza sísmica y sus correspondientes etiquetas de pozo son tratadas por el modelo como secuencias temporales alineadas espacial y temporalmente.

a. Aprendizaje auto-supervisado

Durante el aprendizaje no supervisado o auto-supervisado, cada traza sísmica es tratada como una secuencia temporal y procesada mediante una arquitectura tipo encoder-decoder (Fig. 3). Previamente al ingresar a la capa de encoder, las trazas sísmicas correspondientes a los atributos de entrada son normalizados para homogenizar sus rangos dinámicos. Se favorece así la convergencia del modelo durante el entrenamiento y una mejor capacidad de generalización. El aprendizaje se realiza de manera auto-supervisada, sin utilizar etiquetas externas, mediante la definición de tareas específicas que permiten maximizar la información intrínseca del dato. Conceptualmente, este enfoque es análogo a modelos utilizados en procesamiento de lenguaje, donde una red neuronal aprende representaciones internas a partir de la estructura del propio dato de entrada.

Los features de entrada son modificados y llevados a un espacio latente multidimensional donde el modelo captura características relevantes y generales del dato sísmico mientras aprende a reconstruir la señal sísmica original. Las tareas que se implementaron para que el modelo reconstruya el dato original incluyeron: I) "Fill gaps": se ocultan segmentos de la traza sísmica, obligando al modelo a reconstruir la señal a partir del contexto (muestras y trazas vecinas); II) "Up-sampling": la traza es remuestreada a una resolución temporal mayor y posteriormente reconstruida a su resolución original; III) "Remove noise": se introduce ruido aleatorio en la señal de entrada y el modelo debe recuperar la traza original.

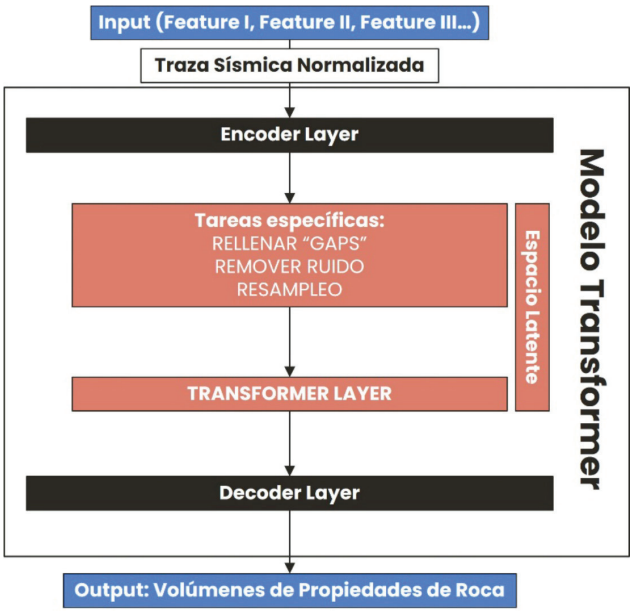


Figura 3. **Representación esquemática simplificada de la arquitectura utilizada en este trabajo. El modelo, basado en una arquitectura tipo encoder–decoder con un bloque Transformer, utiliza como entrada datos sísmicos y los proyecta en un espacio latente. Durante la etapa autosupervisada, la salida es optimizada para reconstruir la señal sísmica original, mientras que en la etapa supervisada el modelo es ajustado para predecir logs de pozo. El modelo final es aplicado sobre todo el volumen sísmico y genera como salida archivos .sgy de cada propiedad de roca objetivo.**

Estas tareas auto-supervisadas se implementan mediante la generación de entradas modificadas (features extras), mientras que la traza sísmica original se utiliza como target y se reconstruye a través de la capa de salida (decoder). El resultado de esta etapa es la generación de un modelo intermedio que es luego utilizado como punto de partida en la etapa supervisada. En esta nueva etapa este modelo va a ser modificado para ajustarse a etiquetas reales y deseadas (logs de pozos) para predecir una propiedad de roca específica.

Esta etapa permite al modelo aprender representaciones internas robustas del dato sísmico, reduciendo la dependencia directa de los datos de pozo y mejorando la capacidad de generalización durante el posterior entrenamiento supervisado.

b. Entrenamiento supervisado con dato de pozo

Para la etapa de entrenamiento supervisado con logs de pozos se utilizaron registros filtrados a 150 Hz. En esta etapa, el modelo previamente entrenado en la etapa no-supervisada es utilizado como punto de partida y ajustado utilizando el dato sísmico como entrada y logs de pozos como variables objetivo. Así, la representación aprendida previamente es refinada para mapear el dato sísmico hacia propiedades elásticas y de roca.

La capa final de salida (decoder) es redefinida para adaptarse al conjunto de logs objetivo. De esta manera, se obtiene un nuevo modelo capaz de predecir los logs de pozos deseados. Una vez el modelo es entrenado, se aplica a todas las trazas para generar un volumen 3D exportado en formato .sgy de cualquier propiedad de roca dado como label.

El ajuste de los pozos al dato sísmico se llevó a cabo con el uso de sismogramas sintéticos ajustando una tabla tiempo-profundidad para cada pozo. Se utilizó una ondícula extraída del dato sísmico con fase cero para "atar" todos los pozos involucrados en el proyecto.

Dado que las redes neuronales son mecanismos data-driven, la predicción de cualquier tipo de log de pozos es conceptualmente posible. Aunque el dato sísmico contiene información elástica de la roca, se realizó un análisis de correlación mediante el coeficiente de Spearman entre los principales logs de propiedades de rocas (Fig. 4) para definir qué propiedades son favorables para predecir. La selección de las propiedades objetivo se basó en el grado de correlación con los atributos elásticos, priorizando aquellos parámetros con mayor capacidad de ser inferidos a partir de la respuesta sísmica. Basados en las correlaciones entre los perfiles eléctricos y las propiedades elásticas de rocas, se predijeron volúmenes de resistividad, impedancia P, impedancia S y Densidad. Cabe

	Zp	Zs	DeepR	Den	GR	NPHI	SP
Zp	1	0,88	0,35	0,45	0,13	0,35	0,03
Zs	0,88	1	0,59	0,3	0,19	0,55	0,01
DeepR	0,35	0,59	1	0,36	0,41	0,59	0,16
Den	0,45	0,3	0,36	1	0,29	0,15	0,25
GR	0,13	0,19	0,41	0,29	1	0,25	0,15
NPHI	0,35	0,55	0,59	0,15	0,25	1	0,05
SP	0,03	0,01	0,16	0,25	0,15	0,05	1
Total	0,92	0,94	0,83	0,76	0,46	0,66	0,28

Correlación
Alta
Buena
Media
Baja
Mala

Figura 4. **Correlación de principales registros eléctricos elásticos y de propiedades de roca. Zp: Impedancia de onda P; Zs: Impedancia de onda S; DeepR: Resistividad profunda; Den: Densidad; GR: Gamma Ray; NPHI: porosidad Neutrón (matriz caliza); SP: Potencial espontáneo.**

destacar que la predicción directa de resistividad representa un avance significativo, al tratarse de una propiedad no directamente derivable de la sísmica mediante métodos tradicionales.

3. Método no supervisado

Los resultados del entrenamiento supervisado fueron volúmenes de DeepR, Zp, Zs y Den. Además, estos cubos sísmicos resultantes fueron usados para calcular volúmenes elásticos derivados como Mu-rho, Lambda-Rho y Poisson Impedance (Quakenbush et al. 2006) calculados a partir de las siguientes ecuaciones:

$$MuRho = Zs^2 \qquad (eq.1)$$
$$LambdaRho = Zp^2 - 2 * Zs^2 \qquad (eq.2)$$
$$PI = Zp - 1.41 * Zs \qquad (eq.3)$$

Con el objetivo de caracterizar el reservorio y capturar variaciones internas, se utilizaron dos enfoques de clasificación no supervisada. Por un lado, a partir de los volúmenes 3D obtenidos por el modelo transformer, y el otro a partir de mapas de atributos del reservorio. En ambos casos se utilizaron redes neuronales del tipo self-organizing maps (SOM) o redes de Kohonen.

- Creación de volúmenes de facies: Se utilizaron como variables de los volúmenes de propiedades obtenidos del modelo (DeepR, Zp, Zs, Den) junto con los atributos elásticos derivados (Mu-rho, Lambda-Rho y PI) para generar volúmenes tridimensionales de facies. El número de clases que mejor caracterice el sistema depende de la complejidad geológica, así como del nivel de detalle requerido para la discriminación interna del reservorio. El número de facies que permitió una adecuada discriminación del reservorio de interés fue de 11 facies dentro de una ventana de 400ms. Esta cantidad de facies fue validada mediante clasificaciones independientes a escala de pozos asegurando consistencia entre las clases sísmicas y facies litológicas. La creación de los volúmenes de facies permitió la extracción de geocuerpos restringidos a tope y base del reservorio de interés y su posterior uso para cálculo de atributos sobre ellos. Esto permitió identificar variaciones internas dentro del reservorio.
- Mapas de facies a partir de multi-atributos sísmicos: se generaron mapas de atributos sísmicos y de propiedades de roca a partir de horizontes guías interpretados. Estos mapas se combinaron en un método de clasificación no supervisado para obtener mapas de facies que permitan entender la distribución lateral de propiedades.

La integración de métodos supervisados y no supervisados permitió una caracterización sísmica robusta del reservorio, mejorando la identificación de zonas prospectivas y la definición de locaciones óptimas para la evaluación del potencial remanente del área (ver sección Interpretación de resultados obtenidos).

Resultados

Caracterización del Reservorio M2 utilizando parámetros elásticos y Resistividad

Elásticamente el reservorio M2 se caracteriza por ser un reservorio con valores relativos bajos de impedancia P (Zp), y una relación Vp/Vs inferior a 1.85 (Fig. 5). Además, es un reservorio con valores bajos de Lambda-Rho, un coeficiente de Poisson (PR) menor a 0.3 y valores bajos de Poisson Impedance (PI) relativos calculados a partir de la ecuación 3 (Eq. 3). La combinación de distintos cutoff para las curvas presentadas en la figura 6 permite discriminar el reservorio de interés. Valores de corte de 8 ohm.m de resistividad, Vp/Vs menor a 1,85 y valores menores a 1500 para PI resaltan el reservorio (valores de cortes sombreados con rojo en la figura). Además, la combinación de los pares de curvas Zp-Zs y LR-MR muestran una respuesta característica para el reservorio en cuestión (cruces sombreados en amarillo). Estas relaciones fueron determinadas a partir del análisis integrado de logs de pozo y utilizadas como referencia para la interpretación y validación de los resultados obtenidos mediante el modelo Transformer.

La configuración de parámetros elásticos descripta para el reservorio genera una respuesta sintética y sísmica de AVO clase III consistente con areniscas cargadas con gas productivo y, en algunos casos, con presencia de fizz water (gas no comercial). Comportamientos elásticos similares han sido documentados en la literatura para reservorios correspondientes a las areniscas de la Fm. Magallanes inferior en distintos yacimientos de la Cuenca Austral (Soldo 2009; Aimar et al. 2018; Jait et al. 2018; Bufaliza 2023).

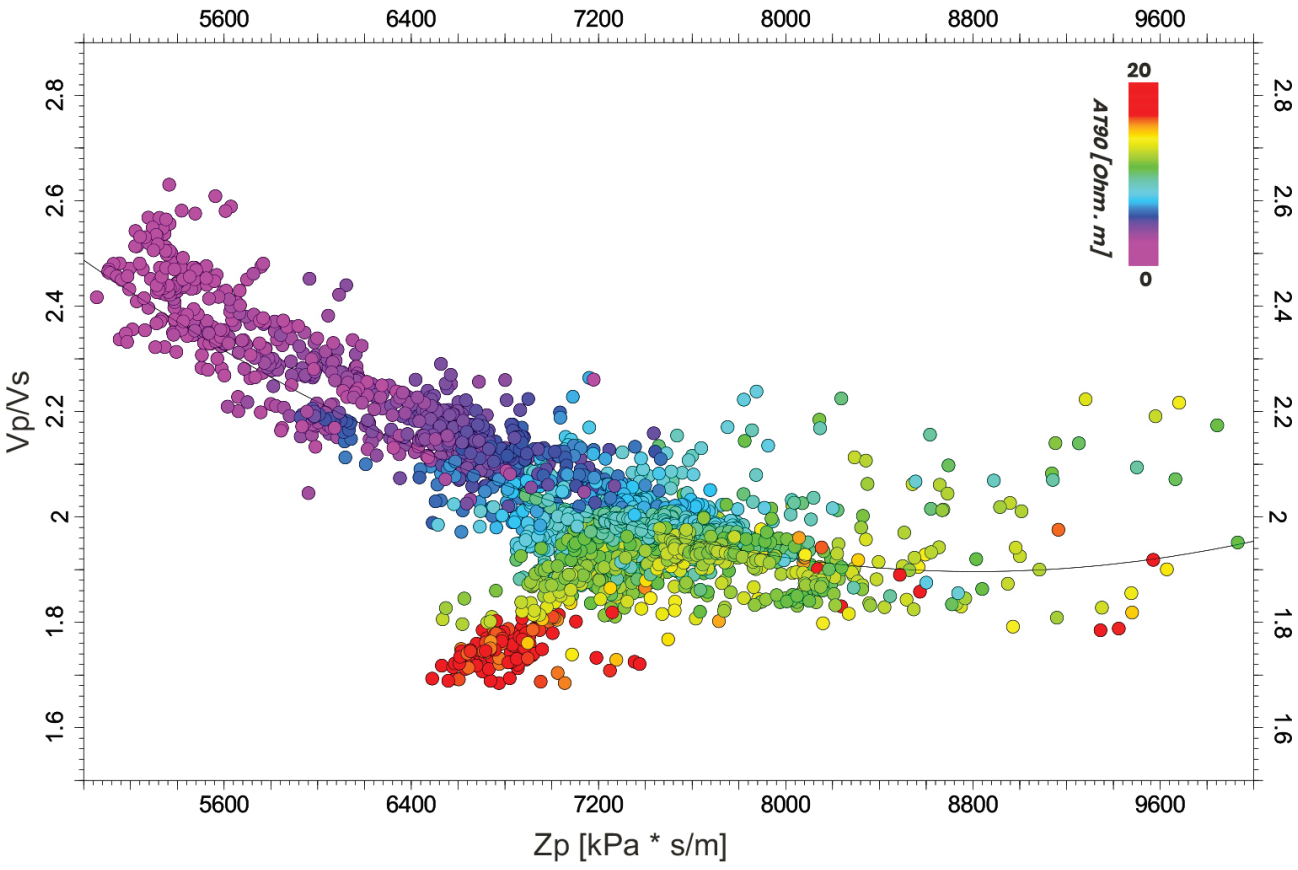


Figura 5. **Comportamiento elástico característico del reservorio M2 en un crossplot Vp/Vs vs. Impedancia P. La relación Vp/Vs cae por debajo de 1,8 asociado a una disminución de Zp alejándose de la tendencia de background marcada con trazo negro continuo. La resistividad aumenta (puntos rojos) conforme con la disminución mencionada.**

Los resultados obtenidos mediante el modelo presentado en este trabajo lograron reproducir de manera consistente las principales respuestas elásticas y resistivas observadas en los datos de pozo, permitiendo discriminar efectivamente el reservorio a partir de datos sísmicos.

Volúmenes sísmicos

Los cubos sísmicos resultantes corresponden a volúmenes de propiedades de rocas en valores absolutos. Los volúmenes de impedancia P, impedancia S y Densidad fueron contrastados contra inversiones de color ("colored inversion") e inversión simultánea, mostrando mejoras visuales y cuantitativas frente a ambos casos. La figura 7 muestra una comparación de los resultados de una inversión simultánea (arriba) para impedancia S y el volumen obtenido con el modelo Transformer (abajo). Cualitativamente, el modelo transformer exhibe un mejor ajuste pozo-sísmica y un rango dinámico de valores más consistentes con los logs de pozos.

Los errores calculados para cada modelo se presentan en la tabla 1 para un pozo no usado en el modelo (blind) y un pozo usado durante el entrenamiento (trainer). Con el objetivo de validar los resultados de manera robusta y consistente, las métricas de error fueron calculadas sobre

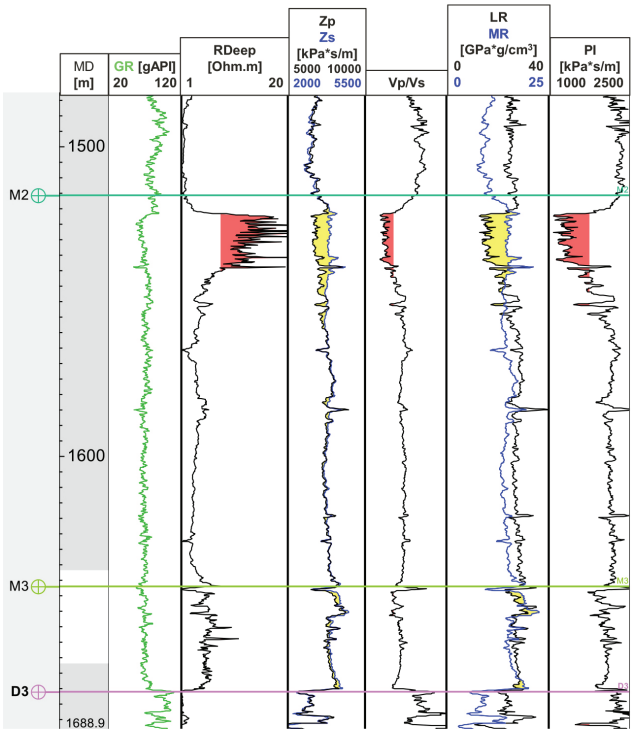


Figura 6. **Respuesta resistiva y elástica para las principales curvas que permiten discriminar el reservorio M2. La combinación de las curvas presentadas es fundamental para la detección sísmica de la anomalía de interés.**

un intervalo de 400m de espesor vertical, muestreado cada 0.5m y no únicamente sobre el intervalo objetivo del reservorio M2. Estos errores se cuantificaron mediante el error porcentual medio (MAPE) para las impedancias y el error absoluto medio (MAE) para la densidad. El MAPE (Eq. 4) expresa el error relativo promedio respecto al valor real, permitiendo comparar propiedades con amplios rangos dinámicos. Por otro lado, el MAE (utilizado para medir el error sobre la predicción de la densidad por su pequeño rango dinámico) representa el desvío absoluto promedio en las mismas unidades físicas de la propiedad evaluada (Eq. 5).

$$MAPE = \frac{100}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \quad (eq.4)$$

donde: y_i: valor real; $\hat{y}_i$: valor predicho

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i| \quad (eq.5)$$

donde: y_i: valor real; $\hat{y}_i$: valor predicho

En todos los casos, el modelo propuesto en este trabajo presenta, sistemáticamente, valores de error menores en comparación con la inversión simultánea. Para la impedancia P las diferencias de los errores en el pozo blind son pequeñas. Esto sugiere que la inversión simultánea constituye una aproximación adecuada para la recuperación de Zp, relacionada con incidencia normal. Sin embargo, las mejoras observadas en impedancia S y densidad resultan particularmente relevantes, ya que estos parámetros suelen ser los más sensibles a incertidumbres asociadas a métodos de inversión sísmica convencionales. En particular, reducciones consistentes en los errores sobre pozos blind indican una mejora en la capacidad de generalización del modelo. A diferencia del modelo clásico de inversión, los modelos de redes neuronales permiten capturar relaciones complejas entre múltiples features de entrada (incluyendo no sólo suma de ángulos parciales, sino también atributos que caracterizan el

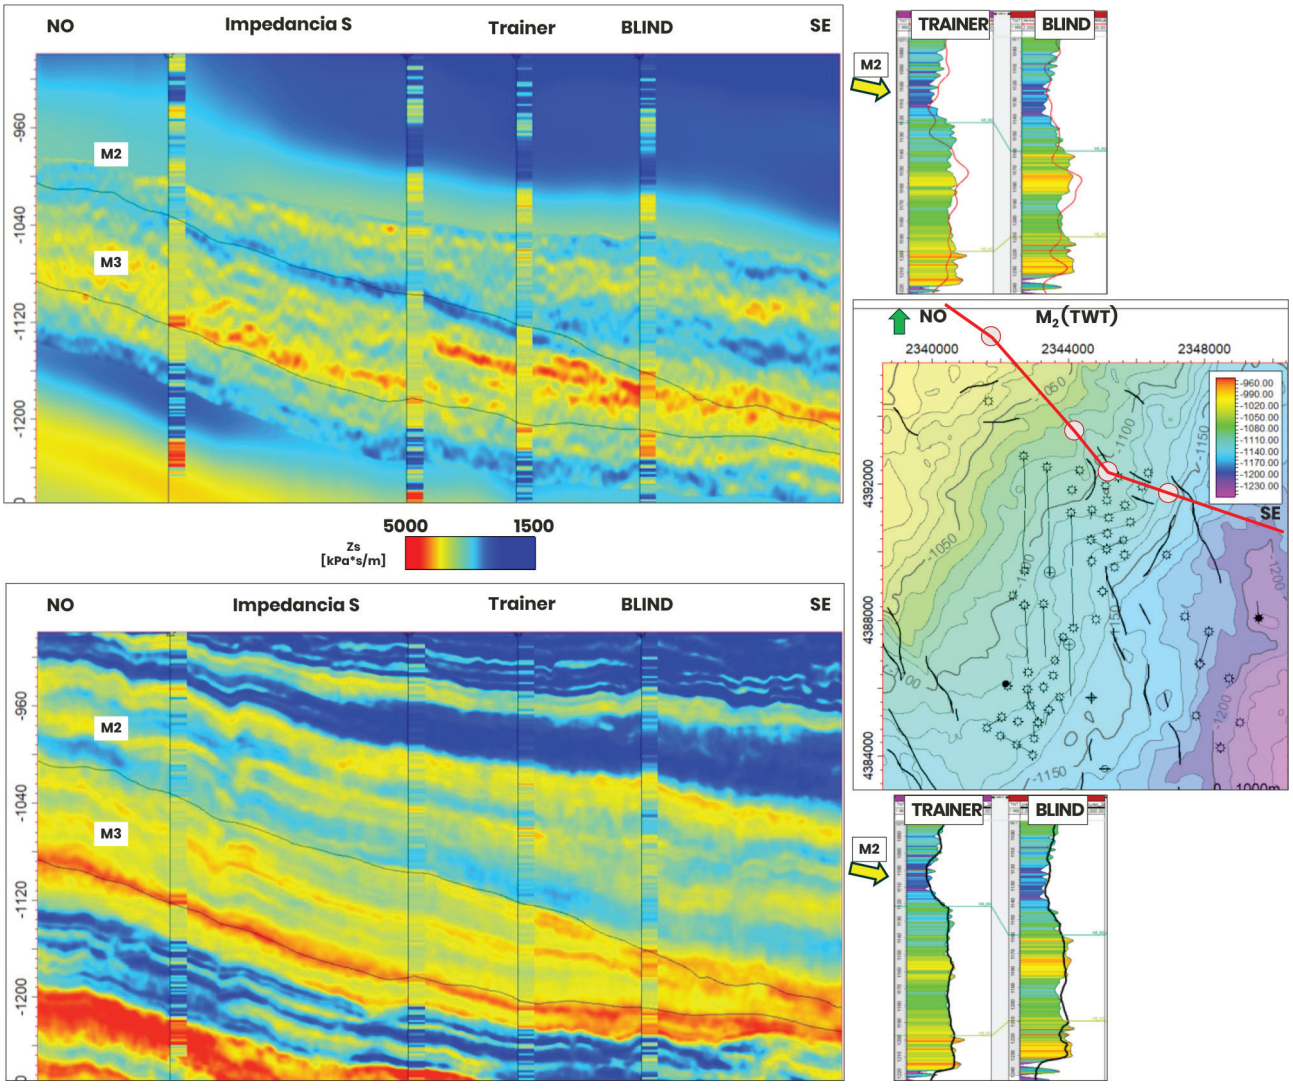


Figura 7. **Sección NO-SE comparando una inversión simultánea (sección superior) contra un cubo de propiedad de roca obtenido con el modelo transformer (sección inferior). Superpuesto sobre la sección se muestran 4 pozos claves en el área con los perfiles de impedancia S filtrados a 300 Hz y la misma escala de color. A la derecha se muestra la extracción de cada volumen sísmico (línea roja arriba y negra abajo) sobre el track del dato predicho (Zs). Se observa un mejor ajuste del modelo transformer versus la inversión simultánea.**

	Error relativo porcentual (MAPE)				Error absolute medio (MAE)	
	P-Impedance		S-Impedande		Densidad (g/cm³)	
	Blind	*Trainer*	*Blind*	*Trainer*	*Blind*	*Trainer*
Transformer	6,19%	4,04%	8,52%	5,61%	0,043	0,032
Simult. *Inversion*	7,81%	7,69%	12,73%	13,12%	0,055	0,049

Tabla 1. **Errores medidos en pozo "blind" y pozo utilizado durante el entrenamiento ("trainer") comparando modelo Transformer vs. Inversión simultánea. En todos los casos el modelo transformer muestra mejores resultados.**

reservorio de interés) resultando en estimaciones más robustas y con menores errores medidos.

Para validar que las mejoras en las métricas de los errores medidos fueron significativas, se calculó adicionalmente el coeficiente de correlación de Pearson (r) entre los logs de pozos y las propiedades predichas tanto por el modelo como por la inversión simultánea. El coeficiente, r, cuantifica la correlación lineal entre los valores observados y predichos, permitiendo evaluar la capacidad predictiva del modelo. En términos generales, para predicción de propiedades y en base a correlaciones entre predicciones a partir del dato sísmico y de pozo, consideramos en este trabajo que un coeficiente mayor a 0,7 es una predicción confiable, mayor a 0,8 es buena y de 0,9 es una predicción precisa. La tabla 2 resume los resultados obtenidos para los parámetros elásticos.

Asimismo, a partir del modelo Transformer se obtuvo directamente un cubo de resistividad a partir de la curva de inducción profunda, ya que esta presenta buena correlación con los parámetros elásticos (Figs. 4, 5 y 6). La curva de resistividad resulta fundamental para el yacimiento ya que el reservorio cargado con gas presenta un alto contraste de valores absolutos comparado con la roca de caja. La figura 8 muestra una sección N-S multi pozos que muestra como el resultado del volumen de resistividad captura variaciones internas dentro del rango dinámico del reservorio. Esta discriminación interna dentro del reservorio permite suponer variaciones de facies dentro del intervalo de interés y no sólo una discriminación discreta entre lo que es reservorio o no. Además, el modelo logra reproducir coherentemente la respuesta de reservorios superiores e inferiores sin haber usado previamente durante el entrenamiento horizontes interpretados que guíen el modelo. Los resultados para el volumen de resistividad fueron también evaluados mediante el error absoluto medio (MAE) y el coeficiente de correlación de Pearson, siendo MAE igual a 0,82 ohm.m y r=0,85. La capacidad del modelo para predecir resistividad resulta particularmente relevante, ya que esta propiedad no puede derivarse directamente del dato sísmico mediante métodos convencionales de inversión.

Interpretación de los resultados obtenidos

Los resultados obtenidos fueron utilizados para generar mapas de propiedades del reservorio. La figura 8 muestra, en la sección inferior derecha, un mapa de valores RMS obtenidos a partir del cubo de resistividad y calculado sobre el geocuerpo perteneciente a M2. El uso del cálculo de la raíz cuadrática media (RMS) permite resaltar variaciones de resistividad dentro del espesor del reservorio, independizándose de efectos locales de alguna muestra individual con valores anómalos. Estas variaciones internas observadas dentro de la progradación se interpretan como el resultado de cambios laterales de facies que impactan en la calidad del reservorio, variaciones en el espesor efectivo de la unidad, o una combinación de ambos factores. En sentido norte-sur, tanto la sección sísmica como el mapa asociado de la figura 8 muestran una zona central con disminución de valores de resistividad, seguida de otro incremento hacia el sur. Las mayores resistividades se correlacionan con el desarrollo principal del campo, mientras que los valores más bajos hacia el sur sugieren una degradación en la calidad del reservorio, consistente con lo observado por pozos.

Hacia el límite occidental de la progradación, se observa una reducción en la potencia del reservorio. Esta disminución de espesor coincide con la disminución de los valores RMS de resistividad, tanto en el mapa como en la sección de la figura 8 (ver los pozos más occidentales proyectados en la figura).

A pesar de las limitaciones de resolución vertical y del efecto de tuning en los datos sísmicos, los resultados obtenidos sugieren que las redes neuronales logran capturar relaciones complejas de amplitud y frecuencia de manera consistente, generando una respuesta robusta y sin artefactos ni valores inconsistentes con el rango dinámico de la propiedad predicha. Por lo tanto, el enfoque data-driven contribuye a una caracterización cuantitativa y coherente del reservorio con geometrías compatibles con el dato sísmico. En conjunto, los resultados permiten una mejor comprensión de la arquitectura in-

	Coeficiente correlación Pearson (r)					
	P-Impedance		S-Impedande		Densidad	
	Blind	*Trainer*	*Blind*	*Trainer*	*Blind*	*Trainer*
Transformer	0,72%	0,88%	0,77%	0,92%	0,63	0,80
Simult. *Inversion*	0,57%	0,66%	0,56%	0,64%	0,45	0,54

Tabla 2. **Coeficiente de correlación de Pearson para un pozo blind y uno usado durante el entrenamiento para la inversión simultánea y el modelo Transformer. Sistemáticamente el modelo Transformer muestra mejores correlaciones para los valores predichos.**

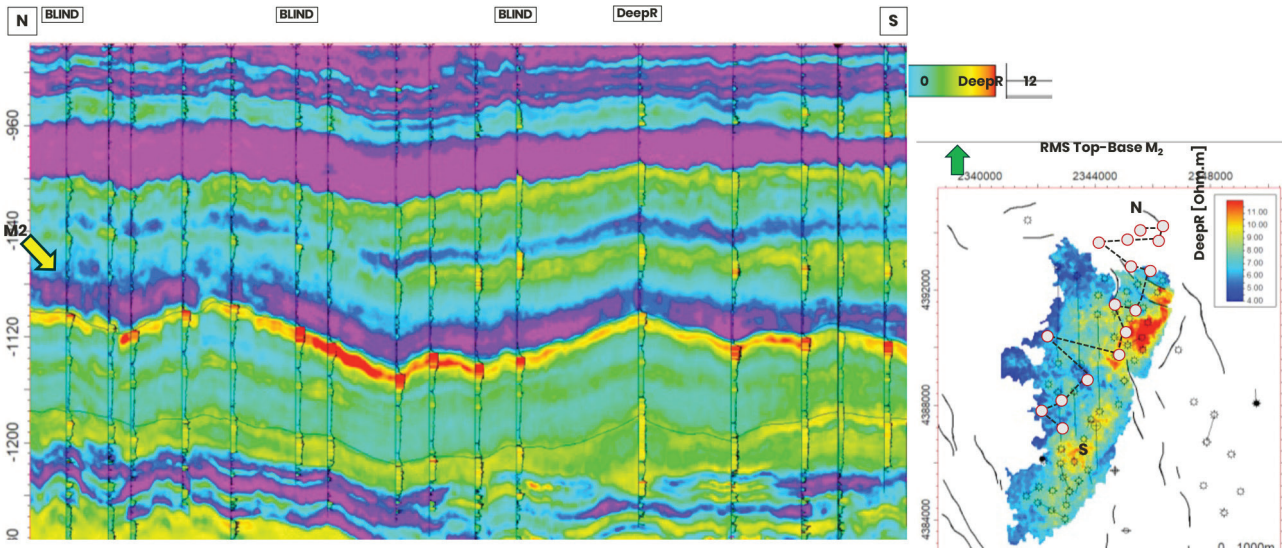


Figura 8. **Cubo de resistividad obtenido a partir del modelo transformer. El modelo obtenido se ajusta al rango dinámico del reservorio permitiendo diferenciar variaciones laterales de resistividad asociada a cambios de facies entre los pozos al norte y al sur del yacimiento. En el mapa de la derecha se muestra el valor RMS del cubo de resistividad calculado para el geocuerpo del reservorio.**

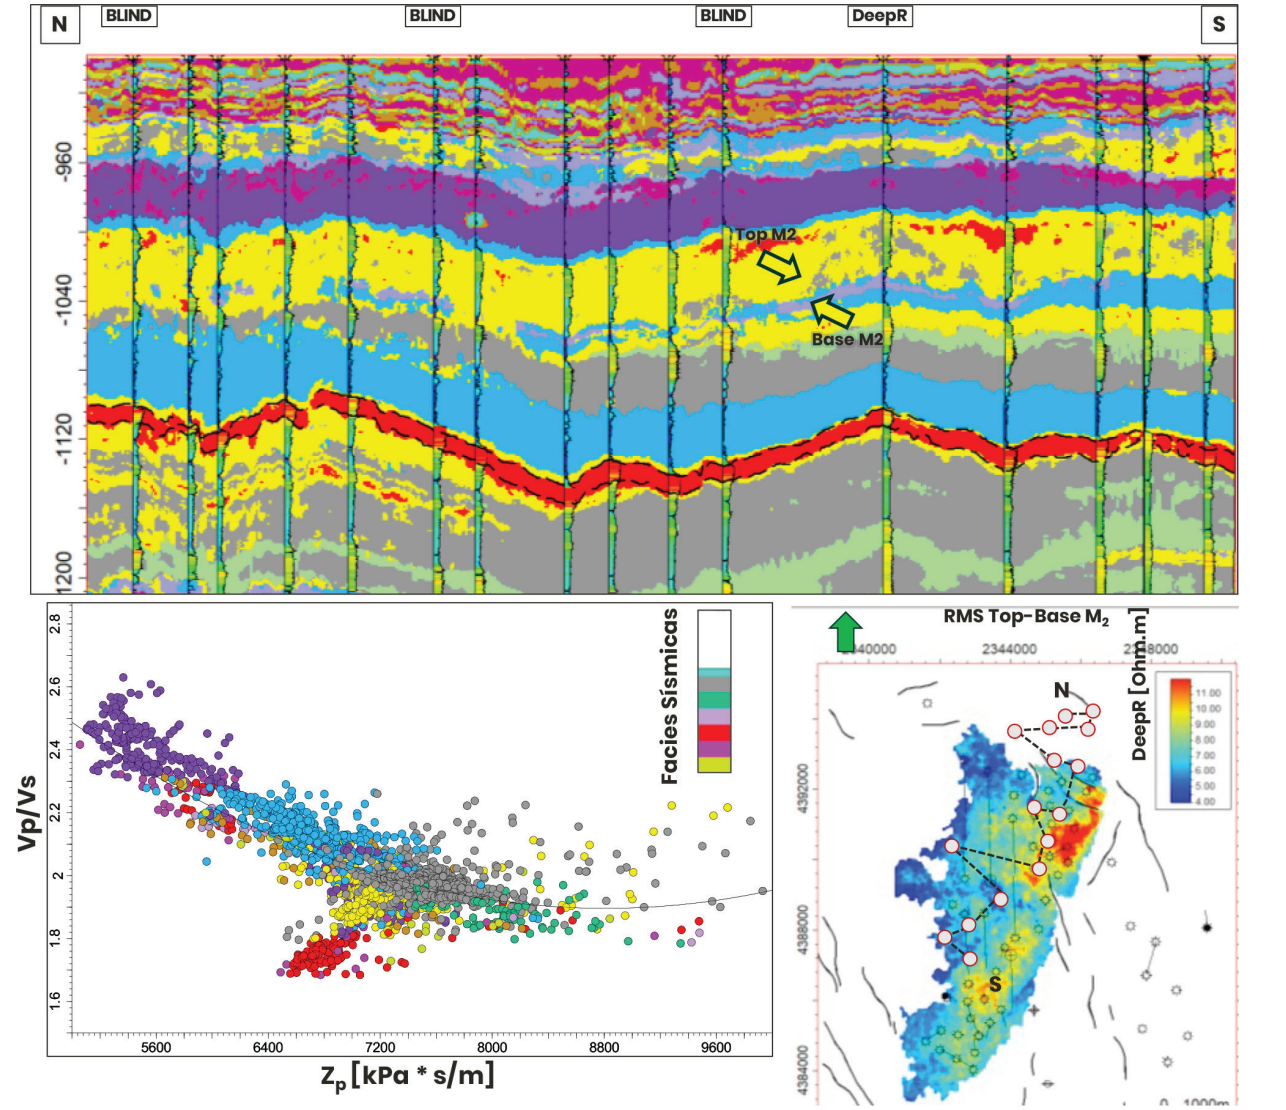


Figura 9. **Resultados del modelo no supervisado para clasificación de facies sísmicas que permitió capturar tope y base del reservorio. Abajo a la izquierda se presenta el crossplot Vp/Vs vs. Zp de la figura 5 pero coloreado por facies sísmicas. Se nota una buena coincidencia de la zona de reservorio cargado con gas con bajos valores de Vp/Vs con facies sísmicas de reservorio (rojas).**

terna del reservorio, evidenciando variaciones laterales de facies y cambios en su calidad o potencia.

Discriminación de facies

Los resultados obtenidos mediante el enfoque supervisado fueron combinados con métodos no supervisados para una caracterización más robusta del reservorio. La discriminación de facies se realizó a partir de los volúmenes de propiedades elásticas y de resistividad predichos por el modelo Transformer, combinados con atributos derivados calculados a partir de dichas propiedades (Eq. 1, 2 y 3). Estos volúmenes fueron utilizados como entrada en un algoritmo de clasificación no supervisada tipo Self-Organizing Maps (SOM). Así, se lograron combinar los resultados del modelo y generar volúmenes 3D de facies sísmicas para discretizar el reservorio.

El número de facies utilizado para la clasificación fue de 11 clases. Si bien la cantidad de facies seleccionadas posee un componente subjetivo asociado al criterio del intérprete, este valor fue validado mediante clasificaciones no supervisadas realizadas directamente sobre logs de pozo en intervalos verticales comparables al rango temporal abarcado por la sísmica. El objetivo fue verificar que la cantidad de clases utilizada permitiera discriminar adecuadamente los principales reservorios de interés. La cantidad óptima de facies no es un valor único y depende de la complejidad litológica y del rango estratigráfico involucrado.

La figura 9 muestra la misma sección presentada en la figura 8 pero con el volumen de facies proyectado sobre esta. En la parte inferior izquierda de la figura se muestra el mismo cross-plot Vp/Vs vs Zp (previamente presentado en la figura 5), coloreado por las facies sísmicas extraídas del volumen 3D de facies a los pozos. Los puntos que se apartan de la línea de tendencia (con valores bajos de Vp/Vs y de Zp) coinciden con las facies rojas que delimitan al reservorio productivo. El mapa presentado en la parte inferior derecha de la figura es el mismo descripto anteriormente en donde se utilizó el tope y base del geocuerpo definido a partir del volumen de facies para extraer los valores de DeepR. La correspondencia entre las facies sísmicas obtenidas y las tendencias observadas en los datos de pozo proporciona una validación cualitativa del modelo de clasificación.

Por otro lado, y de manera independiente a la clasificación de facies en volúmenes 3D, también se aplicó un método no supervisado sobre mapas de atributos y propiedades sísmicas. De esta manera se generaron mapas de facies sísmicas combinando extracciones de amplitudes y propiedades de roca. En este caso, la clasificación estuvo orientada específicamente a capturar variaciones internas dentro del reservorio y no a discriminar litologías presentes en todo el intervalo temporal estudiado. Por este motivo, el número de facies utilizado fue diferente al empleado en los volúmenes 3D y dependió nuevamente del criterio interpretativo y del nivel de detalle buscado en las heterogeneidades internas del reservorio. Se presenta un ejemplo de un mapa discreto de facies con 9 clases para discriminar variaciones en el reservorio (Fig. 10). Para esta clasificación se integraron atributos de AVO y propiedades de roca obtenidas mediante el modelo presentado en este trabajo a partir de extracciones a horizontes interpretados en el dato sísmico. Los resultados muestran variaciones internas asociadas tanto a cambios de facies hacia el sur como a una disminución progresiva del espesor hacia los límites del reservorio. La integración de estos mapas de facies con los resultados previamente presentados permitió realizar una interpretación más integral del sistema y definir los potenciales límites de la progradación M2, representados con línea negra punteada. Los resultados obtenidos sugieren posibles áreas con potencial remanente (locaciones en color azul sobre la figura 10), que podrían ser evaluadas en futuras campañas de perforación.

Caracterización de M3

Con el objetivo de evaluar la generalización y aplicabilidad del modelo en otros intervalos distintos al reservorio principal M2, se analizaron de manera cualitativa los resultados sobre el reservorio M3. Dado que el entrenamiento del modelo durante el entrenamiento auto-supervisado se realiza utilizando trazas sísmicas completas en la ventana temporal analizada (900-1300ms), y ventanas verticales de pozo que abarcan el intervalo sísmico atravesado por el pozo durante el entrenamiento supervisado, el modelo incorpora información correspondien-

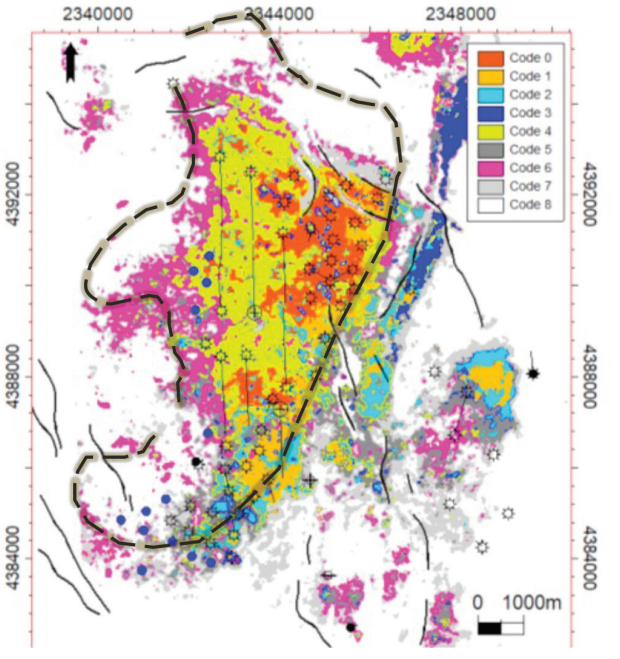


Figura 10. **Clases determinadas con algoritmos no supervisados a partir de mapas de multi-atributos. La combinación de estos mapas con el análisis previamente presentado a nivel sísmico 3D y de pozo, ayudó a interpretar los límites del reservorio, validar los mapas de espesor de arenas y ajustar las posiciones con potencial remanente en el área (locaciones en azul).**

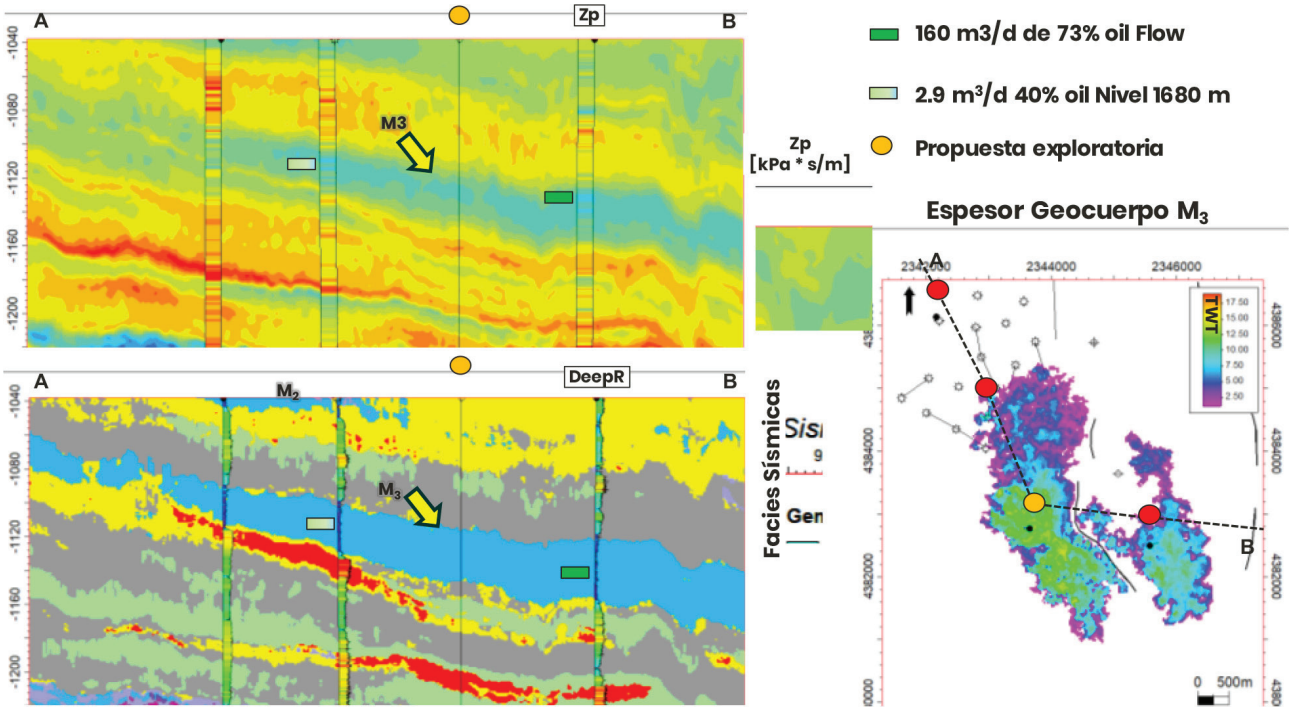


Figura 11. **Sección A-B mostrando el reservorio M3. La sección superior muestra el cubo de impedancia acústica obtenido con el modelo Transformer y la correspondencia observada entre los perfiles de pozo y los volúmenes predichos, constituyendo una evaluación cualitativa del modelo en este intervalo. La progradación M3 corresponde a una disminución de impedancia P. La sección inferior muestra el cubo de facies sísmicas obtenidos a partir del modelo no supervisado en donde se logra mapear tope y base del reservorio y su extensión lateral. El mapa muestra el espesor en tiempo de tránsito doble de tope a base del geocuerpo identificado como M3 sustentando la propuesta exploratoria para este nivel marcada en el mapa y las secciones.**

te a múltiples niveles estratigráficos. La elección del intervalo M3 para su análisis se debió al interés de dicho reservorio en el área estudiada ya que presenta producción de petróleo asociada a esta progradación. El antecedente más fuerte para el reservorio M3 proviene del pozo ECO.x-9(d), ubicado al sur del yacimiento. Dicho pozo ensayó 160 m^3/d de líquido con 73% de petróleo y 27% de agua de formación con una presión en boca de 14 kg/cm^2. El pozo quedó productivo de este intervalo y acumuló a fines del 2025, 50 Mm^3 de petróleo. Este pozo es el único productor de este intervalo, aunque otros pozos han registrado ensayos de petróleo del mismo.

La figura 11 muestra una sección NO-SE que atraviesa dos pozos que ensayaron petróleo de la progradación M3 y una propuesta exploratoria orientada a evaluar un análogo hacia el oeste del pozo ECO.x-9(d). En la sección superior se muestra el cubo de impedancia acústica de onda-P, junto con los perfiles eléctricos utilizando la misma escala de colores, mostrando un buen ajuste sísmica–pozo. En el panel inferior se presenta el volumen de facies obtenido a partir de la integración de los resultados del modelo basado en Transformer y el análisis no supervisado. A partir de este volumen fue posible delimitar el tope y la base de la facies asociada a la progradación M3, permitiendo mapear su extensión lateral. El mapa asociado en la figura muestra dicha anomalía, representada en términos de espesor en tiempo (TWT) entre el tope y la base definidos por el volumen de facies.

La caracterización integrada de propiedades elásticas y facies sísmicas proporciona un marco consistente para la identificación y delimitación de esta anomalía, y da soporte técnico a nuevas oportunidades exploratorias (Fig. 11). Los resultados no solo respaldan la localización propuesta, sino que también contribuyen a definir con mayor precisión la geometría y extensión de la anomalía sísmica.

Conclusiones

El presente trabajo demuestra la factibilidad de utilizar modelos de deep learning tipo Transformer para la generación directa de volúmenes tridimensionales de propiedades elásticas y petrofísicas a partir de datos sísmicos y logs de pozos. De esta manera, se generaron volúmenes 3D de propiedades elásticas de roca – como impedancia P, impedancia S y densidad – y de propiedades no elásticas, como la resistividad. La capacidad de extender el workflow hacia otras propiedades no abordadas en el presente trabajo y obtener resultados geológicamente coherentes es potencialmente posible, aunque debería ser evaluado, para este u otros casos particulares, en trabajos futuros. Este desafío de generar volúmenes tridimensionales de propiedades de roca distintas a las elásticas no puede ser abordado de manera directa mediante metodologías convencionales de inversión sísmica.

Si bien el modelo no pudo ser validado mediante nuevas perforaciones debido a la baja actividad en el período 2024–2025, los resultados obtenidos muestran mejoras sistemáticas respecto de caracterizaciones sísmicas tradicionales. Esta mejora fue validada y cuantificada con pozos blind no utilizados durante el entrenamiento, donde se observaron menores errores de predicción en comparación con inversiones simultáneas.

Aunque el modelo propuesto no está exento de las limitaciones inherentes al dato sísmico, como la resolución vertical y espacial, los resultados sugieren mejoras frente a modelos physics-driven. Así, los enfoques data-driven basados en deep learning demostraron capacidad de representar relaciones complejas entre trazas sísmicas provenientes de múltiples atributos y propiedades de rocas a partir de logs. Las respuestas obtenidas mostraron coherencia geológica y consistencia con lo observado en los pozos. Es importante destacar la importancia de un correcto entendimiento del problema geológico y del yacimiento a caracterizar para la correcta selección del dato de entrada y parámetros a predecir.

Se espera que el potencial del tipo de metodología descripta en el presente trabajo aumente a medida que se incorpore un mayor volumen y diversidad de datos sísmicos y de pozos durante el entrenamiento, así como también se espera una mejora con el desarrollo de redes neuronales específicas para caracterizaciones sísmicas. A su vez, a mayor cantidad de pozos disponibles, la red neuronal incrementa su capacidad de generalización y de captura de relaciones relevantes para el escenario específico a analizar.

La caracterización sísmica realizada sobre los reservorios de la Formación Magallanes (M2) permitió una mejor discriminación de facies sísmicas y la delimitación de áreas con potencial remanente. Como resultado, el modelo contribuyó a optimizar la ubicación de locaciones en un campo maduro, aportando información cualitativa y cuantitativa adicional para la toma de decisiones en el desarrollo del yacimiento.

Aunque en este trabajo se caracterizó el reservorio M2 del miembro inferior de la Fm. Magallanes, los resultados obtenidos no están limitados a este intervalo y mostraron consistencia para la caracterización de otros niveles de interés, como M3. Este reservorio se evaluó de manera cualitativa y los resultados sugieren que el enfoque podría ser aplicable a otros intervalos del sistema, aunque su desempeño debería evaluarse en cada caso. Esta característica es otra de las fortalezas de la metodología propuesta, la cual no está restringida a intervalos estratigráficos o temporales puntuales. Por el contrario, se comprobó que las métricas de los modelos mejoran mientras se incorpora mayores volúmenes de datos, en virtud de la capacidad de las redes neuronales para capturar relaciones temporales y espaciales de largo alcance.

Referencias citadas

Aimar, E., Cevallos, M., Cangini, A., Mas Cattapan, F. and Vega, V, 2018. Extensión y desarrollo de los reservorios de baja permeabilidad del yacimiento. Campo Indio, Formación Magallanes (Maastrichtiano tardío–Daniano), Cuenca Austral Argentina. X Congreso de Exploración y Desarrollo de Hidrocarburos, IAPG, p. 203–220.

Bufaliza, N., 2023. Quantitative Seismic Characterization for Low Saturation Gas Reservoirs: A Case Study in Magallanes Formation, Austral Basin, Argentina.

Castagna, J.P., Sun, S. and Siegfried, R.W., 2003. Instantaneous spectral analysis: Detection of low-frequency shadows associated with hydrocarbons. The leading edge, 22, p. 120–127.

Hampson, D.P., Russell, B.H. and Bankhead, B., 2005. Simultaneous inversion of pre-stack seismic data. In: SEG Technical Program Expanded Abstracts 2005, p. 1633–1637.

Jait, D.M., Cevallos, M., Molinari, M.L., Cangini, A., Cattapan, F.M. and Vega, V., 2018. Exploración y desarrollo de reservorios de baja permeabilidad de la Formación Magallanes en el bloque El Cerrito, Cuenca Austral, Argentina. 10º Congreso de Exploración y Desarrollo de Hidrocarburos. In: Simposio de Desarrollo de Hidrocarburos: Desarrollo Con Pensamiento No Convencional, p. 251.

Lancaster, S. and Whitcombe, D., 2000. Fast-track 'coloured'inversion. In: SEG Technical Program Expanded Abstracts 2000, p 1572–1575.

Mandong, A.F., Bekti, R.P. and Saputra, R.I., 2021. Amplitude Variation with Frequency as Direct Hydrocarbon Indicator for Quick Look and Different Insight of Hydrocarbon Delineation. Jurnal Geofisika, v. 19, no. 2, p. 62–68.

Oldenburg, D., Scheuer, T. and Levy, S., 1983. Recovery of the acoustic impedance from reflection seismograms. Geophysics, v. 48, no.10, p. 1318–1337.

Partyka, G., Gridley, J. and Lopez, J., 1999. Interpretational applications of spectral decomposition in reservoir characterization. The leading edge, v. 18, no. 3, p. 353–360.

Quakenbush, M., Shang, B. and Tuttle, C., 2006. Poisson impedance. The leading edge, v. 25, no. 2, p. 128–138.

Soldo, J., 2009. Fluid to lithology discrimination approach using simultaneous AVO inversion: Puesto Peter Field, Austral Basin, Argentina. The Leading Edge, v. 28,no. 6, p. 698–701.

Vaswani, A., Shazeer, N., et al., 2017. Attention is all you need. Advances in neural information processing systems, v. 30.

Victoria, M., Mas Cattapan, F., Froy, V. and Cangini, A., 2022. Caracterización sísmica de alta resolución en el yacimiento Cerrito Oeste, Cuenca Austral. 11o Congreso de Exploración y Desarrollo de Hidrocarburos.

Whitcombe, D.N., Connolly, P.A., Reagan, R.L. and Redshaw, T.C., 2002. Extended elastic impedance for fluid and lithology prediction. Geophysics, v. 67, p. 63–67.

Wihardy, G.G. and Khairy, H., 2021. Slope of Spectral Amplitude: Simple Yet Effective Hydrocarbon Indicator. Jurnal Geofisika, v. 19, no. 2, p. 57–61.

Zoeppritz, K., 1919. Erdbebenwellen VIII B, Uber reflexion und durchgang seismischer wellen durch unstetigkeisflachen. Gottinger Nachr., v. 1, 66–84

Buscá todo sobre el shale en nuestra web

Shale en ARGENTINA

IAPG INSTITUTO ARGENTINO DEL PETROLEO Y DEL GAS



www.shaleenargentina.org.ar

El sitio del IAPG destinado especialmente a los hidrocarburos de reservorios no convencionales, como *shale gas* y *shale oil*.

Pensada como herramienta útil para toda la comunidad, especializada o no, que quiera conocer con mayor profundidad lo relativo a estos reservorios y al *fracking* o estimulación hidráulica, así como los aspectos que generan mayores cuestionamientos: el uso del agua, la protección de los acuíferos, el uso de químicos, etcétera.

Toda la información de los expertos y las últimas noticias.

¡Y además, la posibilidad de consultar interactivamente a un experto sobre cualquier aspecto relacionado con el shale en la Argentina!

/company/iapg /IAPGinfo /IAPG_Info /iapginfo