


Revista Latinoamericana de Difusión Científica



Volumen 8 - Número 15
Julio – Diciembre 2026
Maracaibo – Venezuela

Red neuronal híbrida integrada para la determinación de propiedades petrofísicas de hidrocarburos en exploración sísmica

DOI: <https://doi.org/10.5281/zenodo.21494905>

Jhonny William Capquique Choque*

RESUMEN

La inteligencia artificial está avanzando de manera progresiva, solucionando problemas en base al aprendizaje de datos, siendo uno de sus modelos evolucionados las redes neuronales, que son aplicadas en la exploración sísmica de hidrocarburos, para generar resultados confiables, en la determinación de propiedades petrofísicas de la roca reservorio. Pero, la cuantificación de estas propiedades, debe ser más precisa, para evitar la perforación de pozos secos, los cuales generan grandes pérdidas económicas. El presente artículo, tiene los siguientes objetivos: 1) Generar las bases teóricas para el diseño arquitectónico de una red neuronal híbrida integrada, constituida por una red neuronal convolucional (CNN), un modelo mamba y las redes neuronales informadas por la física (PINNs); 2) Establecer la metodología de entrenamiento de la red neuronal, para posteriormente realizar predicciones de propiedades petrofísicas, que son evaluadas mediante la validación y control. Esta red neuronal, procesa la información de la parte más relevante de los datos sísmicos, genera resultados con un sentido físico y geológico, además si existiese falta de datos, se obtendrían aplicando leyes físicas.

PALABRAS CLAVE: Propiedades petrofísicas, Red neuronal híbrida integrada, Red neuronal convolucional, Mamba, Red neuronal informada por la Física.

*Profesor. Unidad de Postgrado Industrial, Carrera de Ingeniería Industrial, Facultad de Ingeniería, Universidad Mayor de San Andrés, Bolivia. ORCID: <https://orcid.org/0009-0002-7480-715X>. E-mail: fromyesterday.jhon@gmail.com

Integrated Hybrid Neural Network for Determining Petrophysical Properties of Hydrocarbons in Seismic Exploration

ABSTRACT

Artificial intelligence is advancing progressively, solving problems based on data learning, one of its evolved models being neural networks, which are applied in the seismic exploration of hydrocarbons, to generate reliable results in the determination of petrophysical properties of the reservoir rock. However, the quantification of these properties must be more precise to avoid drilling dry wells, which result in significant economic losses. This article has the following objectives: 1) To generate the theoretical foundations for the architectural design of an integrated hybrid neural network, consisting of a convolutional neural network (CNN), a mamba model, and physics-informed neural networks (PINNs); 2) To establish the training methodology for the neural network, in order to subsequently make predictions of petrophysical properties, which are evaluated through validation and control. This neural network processes the most relevant information from seismic data, generating results with physical and geological significance. Furthermore, if data is missing, it can be obtained by applying physical laws.

KEYWORDS: Petrophysical properties, Integrated hybrid neural network, Convolutional neural network, Mamba, Physics-informed neural network.

Introducción

La exploración sísmica, contempla tres etapas: la adquisición de datos, procesamiento e interpretación de resultados (Yilmaz, 2001). En esta última etapa, la determinación de propiedades petrofísicas, juega un papel importante en el desarrollo de un campo (Veeken, 2007). Por consiguiente, la precisión de la determinación petrofísica de las rocas, constituyen la base para la planificación eficiente de un campo petrolero.

Con respecto a los datos sísmicos, los cuales son obtenidos por operaciones en campo y posteriormente pasan a procesamiento, donde se atenúa el ruido para la mejora del mapa sísmico (Sheriff & Geldart, 1995). Así mismo, esta base de datos sísmica, representa el elemento principal para inferir sobre las propiedades petrofísicas de los hidrocarburos. (Vashisth & Mukerji, 2022).

Por el contrario, el proceso de conversión de datos, en modelos sísmicos y petrofísicos, generan resultados confiables, existiendo vacíos y resultados imprecisos, los cuales son uno de los desafíos para las geociencias (Taufik et al., 2025). La metodología

tradicional utilizada para la determinación de propiedades petrofísicas, utiliza los procesos de inversión sísmica a partir de las propiedades elásticas (Muller et al., 2023). A su vez, este proceso contiene, buena base teórica, generando resultados relativamente satisfactorios, aunque la metodología es no lineal, obteniendo múltiples soluciones para una cantidad de datos observados (Tarantola, 2005).

El desarrollo de los sistemas computacionales, especialmente de inteligencia artificial, han logrado mejorar grandes interrogantes de la ingeniería (Wang et al., 2025). De esta forma el aprendizaje profundo, mediante redes neuronales, es una herramienta alternativa que puede aprender la geología compleja, a partir de un gran conjunto de datos (Okpo, 2026). Sin embargo, un aspecto muy importante, es el etiquetado de datos, por esta razón, se presentan dificultades, en la identificación de ambientes geológicos, los cuales son distintos, al entrenamiento aplicado en el modelo de red neuronal (Taufik et al., 2025).

Sin embargo, estas dificultades son mejoradas mediante, la inserción de una red neuronal híbrida compuesta por una red neuronal convolucional (CNN) y una red neuronal recurrente (RNN), las cuales han demostrado gran capacidad, para extraer parámetros espaciales y temporales de los datos sísmicos (Zhao et al., 2024). Luego, arquitecturas emergentes como mamba y graph neural networks, ofrecen ventajas para el manejo de grandes volúmenes de datos, superando las limitaciones generadas por la arquitectura transformer (Wang et al., 2025).

Por con siguiente, una red neuronal híbrida, mejora grandemente la identificación de ambientes geológicos y por tanto una mayor aproximación a las propiedades petrofísicas reales. Por otra parte, la inserción de las leyes de la física con respecto a los viajes de la onda en las formaciones rocosas, producen aspectos reales de propagación sísmica (Raissi et al., 2019). Este modelo evolucionado es conocido con el nombre de red neuronal informada por la física (Physics-Informed Neural Networks (PINNs)) (Wang et al., 2025).

Al integrar la física mediante ecuaciones matemáticas, se desarrolla resultados más confiables, generando predicciones, de acuerdo a los principios de propagación de ondas sísmicas, cuando se presenten datos escasos y ruidosos (Muller et al., 2023). Mas aun, cuando se hace una determinación de propiedades petrofísicas, se producen redes neuronales híbridas integradas por la física de la onda y rocas, las cuales permitirán obtener,

a partir de los datos sísmicos: permeabilidad, porosidad y saturación, disminuyendo la incertidumbre entre los atributos elásticos y la petrofísica del reservorio (Wang et al., 2025).

Esta investigación tiene como objetivo analizar teóricamente, la utilización de una red neuronal integrada, orientada a la determinación de las propiedades petrofísicas de hidrocarburos en la exploración sísmica. También, busca proponer una teoría conceptual que combine la arquitectura neuronal híbrida con la física de las ondas, reduciendo la incertidumbre cuantitativa de la petrofísica de hidrocarburos, superando las limitaciones únicamente establecidas por los datos.

1. Red neuronal informada por la Física

La red neuronal informada por la física (PINNs), es una técnica, que une a la inteligencia artificial y las leyes físicas, con el objetivo de analizar el comportamiento de la naturaleza (Karniadakis et al., 2021). Así mismo, las PINNs aprenden relaciones matemáticas de entradas y salidas, siendo aproximadores universales de funciones, las cuales combinan leyes físicas, basadas mediante ecuaciones diferenciales parciales (PDEs), todos estos aspectos son aplicados en el entrenamiento (Trahan et al., 2024).

Por el contrario, las redes neuronales convencionales, solo generan resultados, no explican cómo fueron obtenidos esos resultados, lo cual genera mucha incertidumbre. No obstante, las PINNs ponen filtros de acuerdo a las leyes físicas, para que los resultados sean de acuerdo a estas leyes (Raissi et al., 2019).

Además, el principio matemático de las PINNs es la aplicación de la derivada automática (Waheed et al., 2021). En contraste con métodos convencionales que utilizan, métodos numéricos, para la solución, la diferenciación automática, realiza un procedimiento de solución mediante la derivación de tiempo y coordenadas espaciales, más aún con la aplicación de gradientes para optimizar parámetros requeridos (Li et al., 2024).

Por otra parte, se debe hacer un enfoque a la combinación de las PINNs, con respecto a los datos observados y las leyes físicas durante el entrenamiento. Este procedimiento está gobernado por la denominada función de pérdida multiobjetivo (Raissi et al., 2019). Generalmente, la función de pérdida de una red neuronal común, está definida por la diferencia entre la predicción y los datos reales, esta diferencia será el error (Trahan et al., 2024). La estructura de esta función de pérdida es:

- Pérdida por desajuste de datos: Controla el entrenamiento utilizando registro de pozos conocidos (Raissi et al., 2019).
- Pérdida residual de la ecuación diferencial parcial: Evalúa la calidad de la salida de la red neuronal, con respecto a la ecuación gobernante, en un conjunto de puntos de entrenamiento (Waheed et al., 2020).
- Pérdida por condiciones de frontera e iniciales: Garantiza que la solución este dentro el intervalo del límite físico y el estado inicial del sistema (Trahan et al., 2024).

Todavía cabe señalar que, la PINNs, debe minimizar la función de pérdida multiobjetivo, desde los datos observados y la física de las ondas. Según Raissi et al. (2019), las ecuaciones diferenciales parciales de la física, son reguladores suaves que filtran aquellas soluciones que no cumplen con los fenómenos del sistema. Por otro lado, Karniadakis et al. (2021), describe que este proceso disminuye la generación de resultados físicamente incoherentes y mejoran con la capacidad de construcción de un modelo más real. A causa de estos factores, es posible incorporar leyes físicas como por ejemplo la conservación de energía, permitiendo obtener resultados más adecuados.

En relación, a los datos utilizados por las PINNs, se observa que aprenden con muy poca cantidad de datos, no dependiendo de datos etiquetados, las cuales son valores conocidos de entrada y salida en aprendizaje automático (Stanier et al., 2020). Como resultado de la falta de datos etiquetados, las PINNs hacen uso de la ecuación de diferenciales parciales, para aliviar la falta de datos etiquetados (Raissi et al., 2019). Además, las PINNs, no requieren de una generación de mallas, únicamente aproximan las soluciones mediante el dominio físico (Taufik et al., 2025).

Se debe agregar que, una red neuronal convencional genera resultados correctos, desde un punto de vista matemático, pero, por el contrario, estos resultados son incoherentes desde el punto de vista físico. De esta forma las PINNs evitan este problema durante el entrenamiento, incorporando leyes físicas donde las predicciones geológicas son plausibles (Okpo, 2026). Por otro lado, las PINNs, hacen una convergencia adecuada en el proceso de inversión sísmica, la cual es la técnica aplicada para la determinación de propiedades petrofísicas, considerando que las variables desconocidas, son determinadas por las ecuaciones de onda, para que posteriormente puedan mejorar el modelo (Taufik et al., 2025).

También, se establece que las arquitecturas de redes neuronales, están en constante evolución, así se establecen PINNs más evolucionadas como las PINNs 2.0, utilizada para labores específicas, como, por ejemplo, en la detección de reflectores relevantes, fallas y horizontes estratigráficas (Allo et al., 2021). Así mismo una variante es la XPINNs (Extended Physics-Informed Neural Networks) cuyo objetivo es dividir el análisis, en problemas más pequeños (Jagtap & Karniadakis, 2020). A causa de lo anterior, se pueden combinar varias arquitecturas, para generar resultados más eficientes (Okpo, 2026).

2. Arquitectura de Red Neuronal Híbrida Integrada

El siguiente punto trata acerca de la propuesta de un modelo de red neuronal híbrida integrada, capaz de determinar las propiedades petrofísicas, reflejando el comportamiento de las formaciones rocosas, mediante los datos sísmicos. Según Zhao et al. (2024), las redes neuronales convolucionales (CNN) pueden extraer parámetros sísmicos, para representar las características geológicas. (Lecun et al., 1998)

Además, según Gu & Dao (2024) utiliza la arquitectura Mamba, la cual permite obtener un modelo de red neuronal, que pueda manejar gran cantidad de datos, pero a diferencia de las Redes Neuronales Recurrentes (RNN) y las transformer, el uso computacional disminuye para el procesamiento de datos. Por otra parte Karniadakis et al. (2021), realiza la aplicación de leyes físicas en un modelo de red neuronal, obteniendo predicciones que encuentran la naturaleza real del sistema geológico. Como resultado, se propone un modelo de red neuronal híbrida integrada por los siguientes actores: red neuronal convolucional, arquitectura mamba y la red neuronal informada por la Física.

2.1. Red neuronal convolucional (CNN)

Con respecto a las formaciones geológicas, existen marcos referenciales, como la evolución de las facies sedimentarias, así como la geología estructural, enfocada desde las fallas, anticlinales, dorsales, etc., estos elementos constituyen la base para la cuantificación de hidrocarburos (Posamentier & Walker, 2014). Así mismo, para leer toda esta información, se utiliza un modelo híbrido, cuya base son los operadores convolucionales bidimensionales (CNN 2D), identificando la estructura geológica mediante su forma, sin importar la ubicación (Goodfellow et al., 2017).




Figura 1. Arquitectura de la red neuronal híbrida integrada

Además, la CNN es establecida como un identificador directo de atributos sísmicos, cuya determinación es mediante el aprendizaje (Pintea et al., 2022) Por otra parte, la CNN analiza la sección sísmica, mediante operaciones de convolución matemática, repetidas veces, para posteriormente encontrar patrones, que en principio, son datos básicos, como ser: cambios de amplitud (relacionadas con la amplitud versus offset AVO), reflectores; posteriormente mediante el aprendizaje obtiene, continuidad de capas; finalmente en un nivel avanzado, genera fallas, anticlinales y discontinuidades estratigráficas (Das & Mukerji, 2019).

Por el contrario, según Alwon (2018), las CNN pueden reconocer patrones que se encuentran muy cerca entre dos puntos, pero cuando estos se encuentran muy alejados, tiene dificultades y no puede relacionar intervalos de profundidad muy equidistantes. De ahí que es necesario integrar una red neuronal más avanzada.

2.2. Arquitectura mamba

Con respecto a la traza sísmica, que tiene un sistema de secuencia de datos ordenados en tiempo en forma vertical, procesados de forma secuencial por una red neuronal recurrente de tipo LSTM (Long Short-Term Memory) (Das & Mukerji, 2019). No obstante, cuando se tienen gran cantidad de datos sísmicos, la LSTM presenta dificultades, porque debe procesar los datos de manera secuencial, cuya memoria debe analizar paso por paso estos datos, por esta situación se tiene un entrenamiento más lento y un consumo computacional alto (LeCun et al., 2015).

Por otra parte, se realiza una mejora con el uso de una red neuronal transformer implementada con un sistema denominado autoatención (Vaswani et al., 2017). También se debe agregar que la red transformer, no necesita leer datos de manera secuencial para hacer una comparación, compara directamente esos datos, registrando la relación entre datos que se encuentran muy alejados (Vaswani et al., 2017)

No obstante, el sistema de autoatención compara todos los elementos con todos, generando un proceso cuadrático ($O(N^2)$), que aumenta de manera abrupta, cuando las muestras son grandes, considerando que los procesos de inversión sísmica, no se utiliza miles de datos, más por el contrario, se utiliza millones de datos, generando un costo muy alto para los procesos de entrenamiento y rendimiento computacional (Kitaev et al., 2020).

De ahí que, se tiene limitantes en las redes neuronales transformer y en las LSTM, por esta situación, se aplica una arquitectura de red neuronal denominada mamba, cuyo principio está basado en los modelos de espacio de estado selectivos (Selective State Space Models-S6), existiendo una selección de lo más importante (Gu & Dao, 2024). Por otra parte, según Gu & Dao (2024), mamba mantiene una alta eficiencia computacional igual que la LSTM y comprende las relaciones de largo alcance como las transformers, además genera un proceso lineal ($O(N)$), entre datos y esfuerzo computacional. También, la arquitectura mamba cambia su forma de procesamiento, de acuerdo a lo que está analizando en ese momento, por tanto, se adapta de manera continua a una entrada de datos (Gu & Dao, 2024).

En cuanto a la exploración sísmica de hidrocarburos, mamba realiza el procesamiento de datos sísmicos, identificando solamente los datos más importantes, como: secuencias estratigráficas, cambios litológicos, propiedades petrofísicas de

reservorio; y no procesa datos erróneos, como ruido y datos irrelevantes. Por otro lado, mamba realiza una comprensión selectiva de la traza sísmica, procesa lugares donde existe altas reflexiones sísmicas (cambio litológico), aislando zonas de baja reflexión sísmica (Zhao et al., 2024).

2.3. Decodificador PINNs de propiedades petrofísicas

Acerca de este punto, que es la parte final de la red neuronal híbrida integrada, que consiste en: aprendizaje de las formaciones geológicas por parte de la CNN, aprendizaje de la información vertical y temporal por parte de mamba y el decodificador PINNs que combina la información de CNN y mamba, para generar las propiedades de petrofísicas: porosidad, permeabilidad y saturación. Todo este sistema de trabajo está interconectado por capas neuronales, para que el flujo de trabajo sea eficiente (Goodfellow et al., 2017).

En contraste con las metodologías de determinación tradicionales, donde se determina cada propiedad por separado, existiendo resultados matemáticos, y no así una correlación entre resultados, por tanto, se tendrá inconsistencia de resultados petrofísicos (Bosch et al., 2010). Ahora bien, este modelo, genera resultados de manera simultánea, permitiendo establecer una validación entre los mismos, siendo el decodificador un controlador que obliga a que exista la correlación física-geológica entre propiedades (Mukerji et al., 2001).

Por consiguiente, el resultado generado por la CNN y mamba, estará controlado por la PINNs, porque las predicciones pueden ser físicamente imposibles, esto mediante las leyes físicas, obteniéndose errores, que son absorbidos por las PINNs, mediante el gradiente, que reajusta esos errores, para nuevamente realizar el entrenamiento, con CNN y mamba para producir, resultados más coherentes con la física de las rocas.

3. Funciones de pérdida de PINNs

Por lo que se refiere a una red neuronal híbrida Integrada con PINNs, genera los resultados, comprueba con datos reales y verifica si cumple leyes físicas (Raissi et al., 2019). Por consiguiente, para establecer esta verificación, se utilizan las funciones de pérdida, para conocer, si la red neuronal está aprendiendo de manera adecuada o inadecuada (Raissi et al., 2019).

Las funciones de pérdida están concentradas en la denominada función de pérdida total para una PINNs, la cual es establecida, como la suma de: la pérdida por error de datos, la pérdida por error físico, la pérdida por error de condiciones iniciales y de frontera; todo este sistema controla las diferentes etapas del modelo (Trahan et al., 2024). Además, esta función contiene coeficientes que indican a la red, el nivel de significancia para cada tipo de error, estos son ajustados constantemente para minimizar la pérdida total (Raissi et al., 2019).

4. Metodología de entrenamiento y predicción propiedades petrofísicas

Sobre la metodología de entrenamiento y predicción de propiedades petrofísicas, se hace necesario conocer el flujo de trabajo, donde se hace la combinación de los datos sísmicos y las leyes físicas que gobiernan dentro la geología, todo este trabajo permite la determinación de propiedades petrofísicas, por tanto, la física ayuda a que los resultados sean geológicamente más plausibles.




Figura 1. Esquema de flujo de entrenamiento y predicción de propiedades petrofísicas.

Por otra parte, para que el entrenamiento de la red neuronal pueda ser de manera eficiente, se debe generar datos sintéticos, porque en la mayoría de los casos se tiene muy poca información de registro de pozos, estos datos sintéticos, son establecidos mediante los siguientes aspectos (Allo et al., 2021):

- Escenarios geológicos: Se crean múltiples escenarios geológicos de acuerdo a las propiedades petrofísicas de las rocas, con el objetivo de que la red aumente el proceso de aprendizaje, de esta forma se garantiza resultados geológicos (Malik & Dixit, 2022).
- Sintetización sísmica: Las propiedades petrofísicas obtenidas, se transforman en respuestas sísmicas sintéticas, obtenidas por la reflexión y por un proceso de convolución matemática, a través una ondícula real, todo este proceso sirve para el adiestramiento de la red neuronal (Vashisth & Mukerji, 2022).
- Aplicación de ruido artificial: Este aspecto consiste en introducir, un ruido artificial, a los datos sintéticos, para que la red neuronal se entrene de acuerdo a condiciones reales establecidas por datos sísmicos de campo, asegurando que la red aprenda patrones geológicos (Trahan et al., 2024).

4.1. Entrenamiento híbrido

Sobre este aspecto, en una etapa inicial el entrenamiento es controlado mediante el aprendizaje por transferencia, el cual consiste en el aprendizaje de los datos sintéticos, las relaciones entre: velocidad, porosidad; impedancia, litología; saturación, amplitud sísmica; posteriormente se obtienen pesos, que son ajustados, con datos reales de registro de pozos, esto se realiza por la escasa cantidad de datos, mejorando la capacidad de entrenamiento de la red neuronal (Malik & Dixit, 2022).

Generalmente el aprendizaje de una red neuronal es supervisado, pero en exploración sísmica, se introduce el concepto de aprendizaje por supervisión débil, que consiste en procesar poca información (registros de pozos) y complementarla con restricciones físicas, para disminuir el problema de no unicidad de solución (Vashisth & Mukerji, 2022).

4.2. Inversión en el Espacio Latente y Optimización

Otro punto importante, es el manejo de datos, para la inversión, por ejemplo, en las formaciones de rocas, se tienen millones de datos, por tanto, un proceso de inversión sísmica genera mucho consumo de GPU computacional, por esta situación, una vez registrada las trazas sísmicas por mamba, estas pasan a ser procesadas por autoencoders, para generar un volumen modelo de pocos datos que servirá para el proceso de inversión (Taufik et al., 2025).

El proceso de inversión es mejorado continuamente, mediante el ajuste de pesos y la disminución del error, utilizando adam (Adaptative Moment Estimation) y L-BFGS (Limited-memory Broyden–Fletcher–Goldfarb–Shanno), como optimizadores de error, el primero disminuye el error de manera general, el segundo, afina el error para tener soluciones más estables para las restricciones físicas (Vashisth & Mukerji, 2022).

4.3. Determinación de propiedades petrofísicas

Acerca de este tema, una de las propiedades petrofísicas es la porosidad, determinada de manera directa por Mamba, mediante la combinación de la traza sísmica y las leyes físicas (Vashisth & Mukerji, 2022). Esta forma de determinación, está en base a la relación entre los datos sísmicos y la porosidad, donde la ecuación gobernante es no lineal, en esta situación, mamba aprende esta ecuación no lineal, posibilitando una solución única (Vashisth & Mukerji, 2022).

Por otra parte, el resultado generado debe tener sentido físico y sísmico, esto se logra mediante la construcción de datos sísmicos a partir de los obtenidos, entonces se obtiene una sísmica sintética, que es comparada con la sísmica real, si existe diferencia entre ambas, se hace un reajuste de pesos para corregir el error, pero si existe correlación con los datos reales, el resultado es válido (Vashisth & Mukerji, 2022).

En relación con la otra propiedad petrofísica, que es la permeabilidad, considerada muy variable, porque cambia constantemente, dependiendo de la conexión de los poros de la roca y las facies geológicas, entonces mamba, integra las características de la roca y la geología del subsuelo, que son representadas por ecuaciones no lineales (Zhang et al., 2026).

Dado que las facies, son un aspecto importante, resulta conveniente describir a las microfacies, que son combinadas con datos sísmicos para controlar el tipo de deposición de roca, cuando mamba hace el entrenamiento, además este proceso puede adicionar información sísmica, en lugares donde exista vacío de información, siendo el resultado la permeabilidad en condiciones geológicas y físicas (Ding & Chen, 2026)

5. Validación y control

Por lo que se refiere a la validación y control, un tema muy importante para comprobar que el modelo de red neuronal hibrida integrada, funciona de manera correcta,

debe pasar a predecir ahora datos, que no conoce, entonces se insertan datos de pozos desconocidos, para que posteriormente se obtenga resultados (Wei et al., 2025). Si el resultado es correcto, entonces la red neuronal está bien entrenada, pero si el resultado esta fuera de la lógica geológica y física, la red esta sobre ajustada (Trahan et al., 2024).

Por otra parte, un resultado único no garantiza que la red neuronal, obtenga un resultado adecuado, se deben construir varias redes neuronales para suministrarles pequeñas variaciones de datos, si todas esa redes generan un mismo resultado, existe confianza en la predicción, pero si no existe semejanza de resultados, habrá incertidumbre, la cual puede ser analizada con un mapa de incertidumbre, mediante la desviación estándar de estos resultados, permitiendo identificar zonas donde la información es insuficiente (Trahan et al., 2024).

Así mismo, otra forma de validar y controlar, es la realización de un proceso de simulación con las propiedades obtenidas, este proceso genera producción de hidrocarburos, siendo comparadas con pruebas de producción reales, si las pruebas de producción predichas y reales son similares, entonces el modelo de red neuronal híbrida Integrada muestra el comportamiento del reservorio (Wei et al., 2025).

Conclusiones

La configuración arquitectónica de la red neuronal híbrida integrada, está de acuerdo a: un identificador de geometrías de imágenes sísmicas y atributos sísmicos (CNN), un selector de partes más importantes (mamba), aislando partes sin mucha información, de esta forma se disminuye el consumo computacional y finalmente, un controlador que determine las propiedades petrofísicas y verifique que las soluciones de CNN y mamba sean físico geológicas (PINNs).

La metodología de entrenamiento está en base a los datos sintéticos, la red neuronal aprende con estos datos, adicionando ruido para que el aprendizaje sea eficiente, adicionalmente se aplican técnicas de discretización de datos y minimización de error durante el entrenamiento. Las propiedades petrofísicas obtenidas son: porosidad, obtenida directamente y la permeabilidad, analizada desde un punto de vista de las facies. Acerca de la validación y control, se insertan pozos desconocidos, donde se obtienen resultados, que son comparados con datos reales, permitiendo probar la eficiencia de la red neuronal híbrida integrada.

Referencias

Allo, F., Coulon, J. P., Formento, J. L., Reboul, R., Capar, L., Darnet, M., Issautier, B., Marc, S., & Stopin, A. (2021). Characterization of a carbonate geothermal reservoir using rock-physics-guided deep neural networks. *The Leading Edge*, 40(10), 751–758. <https://doi.org/10.1190/tle40100751.1>

Alwon, S. (2018). Generative adversarial networks in seismic data processing. *SEG Technical Program Expanded Abstracts* 2018, 1991–1995. <https://doi.org/10.1190/segam2018-2996002.1>

Bosch, M., Mukerji, T., & Gonzalez, E. F. (2010). Seismic inversion for reservoir properties combining statistical rock physics and geostatistics: A review. *Geophysics*, 75(5), 75A165–75A176. <https://doi.org/10.1190/1.3478209>

Das, V., & Mukerji, T. (2019). Petrophysical properties prediction from pre-stack seismic data using convolutional neural networks. *SEG Technical Program Expanded Abstracts* 2019, 2328–2332. <https://doi.org/10.1190/segam2019-3215122.1>

Ding, Y., & Chen, G. (2026). Joint Prediction Model of Reservoir Parameters Based on Multimodal Transformer Graph Neural Operator Physical Constraint Network. *International Scientific Technical and Economic Research*, 4(1), 70–89. <https://doi.org/10.71451/ISTAER2604>

Goodfellow, Ian., Bengio, Yoshua., & Courville, Aaron. (2017). *Deep learning*. The MIT Press.

Gu, A., & Dao, T. (2024). Mamba: Linear-Time Sequence Modeling with Selective State Spaces.

Jagtap, A., & Karniadakis, G. (2020). Extended Physics-Informed Neural Networks (XPINNs): A Generalized Space-Time Domain Decomposition Based Deep Learning Framework for Nonlinear Partial Differential Equations. *Communications in Computational Physics*, 28(5), 2002–2041. <https://doi.org/10.4208/cicp.OA-2020-0164>

Karniadakis, G. E., Kevrekidis, I. G., Lu, L., Perdikaris, P., Wang, S., & Yang, L. (2021). Physics-informed machine learning. *Nature Reviews Physics*, 3(6), 422–440. <https://doi.org/10.1038/s42254-021-00314-5>

Kitaev, N., Kaiser, Ł., & Levskaya, A. (2020). Reformer: The Efficient Transformer.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>

Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. <https://doi.org/10.1109/5.726791>

- J. W. Capquique Choque // Red neuronal híbrida integrada para la determinación... 317-333
- Li, Z., He, Q., & Li, J. (2024). A survey of deep learning-driven architecture for predictive maintenance. *Engineering Applications of Artificial Intelligence*, 133, 108285. <https://doi.org/10.1016/j.engappai.2024.108285>
- Malik, J., & Dixit, H. K. (2022). Application of Rock Physics Driven Deep Machine Learning for Hydrocarbon Exploration. *Society of Petroleum Geophysicists (SPG India) Feature Article*, 118–123.
- Mukerji, T., Jørstad, A., Avseth, P., Mavko, G., & Granli, J. R. (2001). Mapping lithofacies and pore-fluid probabilities in a North Sea reservoir: Seismic inversions and statistical rock physics. *Geophysics*, 66(4), 988–1001. <https://doi.org/10.1190/1.1487078>
- Muller, A. P. O., Costa, J. C., Bom, C. R., Klatt, M., Faria, E. L., de Albuquerque, M. P., & de Albuquerque, M. P. (2023). Deep pre-trained FWI: where supervised learning meets the physics-informed neural networks. *Geophysical Journal International*, 235(1), 119–134. <https://doi.org/10.1093/gji/ggad215>
- Okpo, E. (2026). Hybrid Machine Learning Framework for Seismic Velocity Inversion. <https://doi.org/10.22541/essoar.177099432.27567143/v1>
- Pintea, S. L., Sharma, S., Vossepoel, F. C., van Gemert, J. C., Loog, M., & Verschuur, D. J. (2022). Seismic inversion with deep learning: A proposal for litho-type classification. *Computational Geosciences*, 26(2). <https://doi.org/10.1007/s10596-021-10118-2>
- Posamentier, H. W., & Walker, R. G. (2014). *Facies models revisited*. GeoScienceWorld.
- Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686–707. <https://doi.org/10.1016/j.jcp.2018.10.045>
- Sheriff, R. E., & Geldart, L. P. (1995). *Exploration seismology* (2nd Edition). Cambridge University Press.
- Stanier, A., Chacón, L., & Le, A. (2020). A cancellation problem in hybrid particle-in-cell schemes due to finite particle size. *Journal of Computational Physics*, 420, 109705. <https://doi.org/10.1016/j.jcp.2020.109705>
- Tarantola, A. (2005). *Inverse Problem Theory and Methods for Model Parameter Estimation*. Society for Industrial and Applied Mathematics. <https://doi.org/10.1137/1.9780898717921>
- Taufik, M. H., Huang, X., & Alkhalifah, T. (2025). Latent Representation Learning in Physics-Informed Neural Networks for Full Waveform Inversion. *Earth and Space Science*, 12(9). <https://doi.org/10.1029/2024EA004107>
- Trahan, C., Loveland, M., & Dent, S. (2024). Quantum Physics-Informed Neural Networks. *Entropy*, 26(8), 649. <https://doi.org/10.3390/e26080649>

Trahan, S., Mosegaard, K., & Jakobsen, M. (2024). Deep Neural Network Application for 4D Seismic Inversion to Changes in Pressure and Saturation.

Vashisth, D., & Mukerji, T. (2022). Direct estimation of porosity from seismic data using rock- and wave-physics-informed neural networks. *The Leading Edge*, 41(12), 840–846. <https://doi.org/10.1190/tle41120840.1>

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention Is All You Need. *Advances in Neural Information Processing Systems*, 5998–6008.

Veeken, P. (2007). *Seismic Stratigraphy, Basin Analysis and Reservoir Characterisation*, vol. 37 (Vol. 37). Pergamon.

Waheed, U. B., Haghighat, E., Alkhalifah, T., Song, C., & Hao, Q. (2020). Eikonal Solution Using Physics-Informed Neural Networks. *EAGE 2020 Annual Conference & Exhibition Online*, 1–5. <https://doi.org/10.3997/2214-4609.202011041>

Waheed, U. bin, Haghighat, E., Alkhalifah, T., Song, C., & Hao, Q. (2021). PINNeik: Eikonal solution using physics-informed neural networks. *Computers & Geosciences*, 155, 104833. <https://doi.org/10.1016/j.cageo.2021.104833>

Wang, N., Chen, Y., & Zhang, D. (2025). A comprehensive review of physics-informed deep learning and its applications in geoenery development. *The Innovation Energy*, 2(2), 100087. <https://doi.org/10.59717/j.xinn-energy.2025.100087>

Wei, L., Gan, L., Yang, H., Li, X., Hao, G., & Jiang, X. (2025). Advances in theoretical and technical approaches for seismic prediction of reservoir permeability. *Journal of Seismic Exploration*, 34(4), 1. <https://doi.org/10.36922/JSE025310050>

Yilmaz, Ö. (2001). *Seismic Data Analysis*. Society of Exploration Geophysicists. <https://doi.org/10.1190/1.9781560801580>

Zhang, M., Cheng, Y., & Lei, Z. (2026). Quantum-enhanced long short-term memory with attention for spatial permeability prediction in oilfield reservoirs. *Engineering Applications of Artificial Intelligence*, 167, 113605. <https://doi.org/10.1016/j.engappai.2025.113605>

Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, 57(4), 99. <https://doi.org/10.1007/s10462-024-10721-6>

Conflicto de interés

El autor de este manuscrito declara no tener ningún conflicto de interés.

Declaración ética

El autor declara que el proceso de investigación que dio lugar al presente manuscrito se desarrolló siguiendo criterios éticos, por lo que fueron empleadas en forma racional y profesional las herramientas tecnológicas asociadas a la generación del conocimiento.

Copyright

La **Revista Latinoamericana de Difusión Científica** declara que reconoce los derechos de los autores de los trabajos originales que en ella se publican; dichos trabajos son propiedad intelectual de sus autores. Los autores preservan sus derechos de autoría y comparten sin propósitos comerciales, según la licencia adoptada por la revista.

Licencia CreativeCommons

Esta obra está bajo una Licencia CreativeCommons Atribución-NoComercial-CompartirIgual 4.0 Internacional

