

El papel de la inteligencia artificial en el Upstream de la Industria Petrolera: una revisión

The role of artificial intelligence in the Upstream of the Oil Industry: a review

Jerry Meza

Universidad del Atlántico, Colombia

RESUMEN

Este artículo de revisión aborda la integración y aplicación de la Inteligencia Artificial (IA) en la industria de los hidrocarburos, destacando su papel transformador en la optimización de procesos, la sostenibilidad y la toma de decisiones. Profundiza en múltiples aspectos de la IA, desde el aprendizaje automático hasta las redes neuronales convolucionales, utilizadas en el 'upstream' del petróleo, que abarca la exploración, la perforación y la producción. Se examinan técnicas de aprendizaje automático como SVM y ANN, aplicadas para predecir las propiedades de los yacimientos con el objetivo de mejorar la eficiencia en la exploración petrolera. Se discuten perspectivas futuras, incluido el aprendizaje profundo en operaciones sísmicas y la identificación y mitigación de la contaminación. Se enfatiza el potencial de la IA en la ingeniería de yacimientos para agilizar los cálculos, mejorar los procesos de escalado y optimizar la producción. A pesar de los avances, se reconocen desafíos como la gestión de datos a gran escala y la inversión tecnológica. El artículo concluye que la colaboración entre expertos en hidrocarburos y tecnólogos de IA será fundamental para superar los desafíos y aprovechar plenamente las oportunidades en la convergencia de estos campos, allanando el camino hacia una industria de hidrocarburos más eficiente y sostenible.

Palabras claves: Upstream, hidrocarburos, Inteligencia Artificial (IA), Depósitos, Predicción.

ABSTRACT

This review article addresses the integration and application of Artificial Intelligence (AI) in the hydrocarbon industry, highlighting its transformative role in process optimization, sustainability, and decision-making. It delves into multiple aspects of AI, from machine learning to convolutional neural networks, used in the petroleum 'upstream,' covering exploration, drilling, and production. Techniques of machine learning such as SVM and ANN are examined, applied to predict reservoir properties with the aim of enhancing efficiency in oil exploration. Future perspectives are discussed, including deep learning in seismic operations and the identification and mitigation of pollution. The potential of AI in reservoir engineering to streamline calculations, enhance scaling processes, and optimize production is emphasized. Despite advancements, challenges such as large-scale data management and technological investment are acknowledged. The article concludes that collaboration between hydrocarbon experts and AI technologists will be pivotal in overcoming challenges and fully leveraging opportunities in the convergence of these fields, paving the way towards a more efficient and sustainable hydrocarbon industry.

Keywords: Upstream, hydrocarbon, Artificial Intelligence (IA), Deposits, Prediction.

INTRODUCCIÓN

El uso de la inteligencia artificial está experimentando un crecimiento significativo en diversas áreas, ya que ha demostrado su capacidad para realizar y mejorar tareas que a menudo resultan desafiantes o incluso inaccesibles para los seres humanos. La aplicación de la inteligencia artificial varía según la industria y el interés en cuestión. Se han demostrado sus aplicaciones en una amplia gama de campos, que incluyen la agricultura, las finanzas, el transporte, el control de procesos, la atención médica, la informática, entre otros [1].

Por otro lado, en lo que respecta a la industria de los hidrocarburos ha sido durante mucho tiempo uno de los pilares fundamentales de la economía global y una fuente esencial de energía para la

humanidad. Sin embargo, en un mundo cada vez más enfocado en la sostenibilidad, consciente de los impactos ambientales y creciente demanda de consumo, se plantea un desafío crítico tal como continuar aprovechando los recursos de los hidrocarburos de manera eficiente y responsable [2].

Diversas complicaciones han surgido al intentar anticipar las características operativas mediante métodos convencionales en esta industria, lo que impulsó a todos los implicados encaminar sus investigaciones hacia la aplicación de inteligencia artificial y sus distintas técnicas con enfoques basados en datos en las operaciones de exploración y producción [3] lo que se conoce como el “upstream” cuyas etapas se describen en la figura 1.

FIGURA 1. ETAPAS QUE COMPONEN EL UPSTREAM DE LA INDUSTRIA PETROLERA [8]



La IA ha demostrado ser una tecnología transformadora en una amplia gama de industrias, y la industria de los hidrocarburos no es una excepción [4]. Su aplicación en esta área va mucho más allá de la automatización de tareas rutinarias; se ha convertido en un habilitador clave para la optimización de la exploración y producción. A medida que la demanda de energía continúa

aumentando y la necesidad de proteger nuestro planeta se vuelve más urgente, la IA emerge como una herramienta esencial para encontrar un equilibrio [5]. Incluye ramas como el algoritmo genético (GA), la máquina de vectores de soporte (SVM), el aprendizaje profundo (deep learning), el aprendizaje automático extremo (EML), la red neuronal artificial (ANN) y los modelos híbridos [6].

Una de las ramas de la IA son los métodos de Machine Learning tienen como objetivo la creación de modelos predictivos o la identificación de patrones en las variables de un sistema [7]. Estos métodos se dividen en tres categorías principales: aprendizaje supervisado, donde se infiere una función a partir de datos de entrada y salida; aprendizaje no supervisado, donde se busca la correlación entre variables sin información de salida; y aprendizaje por refuerzo, que implica un proceso interactivo de prueba y error para aprender el comportamiento de un sistema dinámico. El aprendizaje supervisado se utiliza para predecir resultados basados en datos de entrenamiento, el aprendizaje no supervisado busca entender correlaciones entre variables, y el aprendizaje por refuerzo se aplica a tareas de control.

Este artículo destaca cómo la tecnología y en particular la inteligencia artificial está contribuyendo a la eficiencia, la sostenibilidad y la responsabilidad en la industria de los hidrocarburos, al tiempo que plantea cuestiones importantes sobre su implementación y las implicaciones a largo plazo. Su aplicación práctica y adecuada conduce al desarrollo de sistemas integrales y valiosos con mejores rendimientos o diferentes funcionalidades que no son posibles con los métodos tradicionales del upstream.

OBJETIVO

Este artículo de revisión tiene como objetivo proporcionar una visión integral de la evolución y el estado actual del uso de la inteligencia artificial en la industria de los hidrocarburos. Para ello, se formularon los siguientes objetivos de investigación para cumplir con el propósito principal del estudio:

- » Realizar una amplia investigación bibliográfica sobre las aplicaciones de la IA en la industria de los hidrocarburos.
- » Examinar cuáles son las técnicas de IA más utilizadas en el upstream.
- » Evaluar el impacto de las técnicas de IA en la industria.
- » Exponer las perspectivas de la IA en la industria petrolera.

METODOLOGÍA

La metodología constó de tres etapas. Un filtro que abarcó artículos publicados entre 2018 y 2023 se utilizó para llevar a cabo esta investigación. En la primera etapa, se efectuó una recopilación general de la información de los artículos encontrados en SCOPUS y SCIENCE DIRECT, utilizando las palabras clave "inteligencia artificial" e "hidrocarburos" con el propósito de reunir una cantidad suficiente de artículos para la siguiente fase. En total, se recopiló una cantidad suficiente de 423 documentos relacionados con la temática.

En la segunda etapa, se realizó un análisis de los artículos relacionados con el tema mediante la herramienta VOSviewer. Este análisis permitió la identificación de las palabras clave más relevantes relacionadas con la IA, lo que a su vez resultó en la reducción del número de artículos considerados. En la figura 2 se muestra el mapa de co-ocurrencia con los términos generales encontrados.

FIGURA 2. MAPA DE CO-OCURENCIA (TODAS LAS PALABRAS CLAVES)

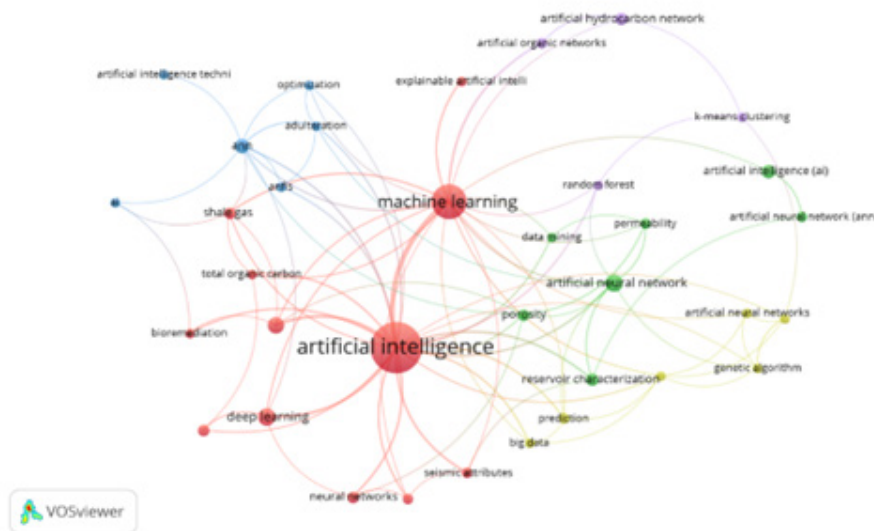
- 6 claustrs
- Claustro 1 (rojo)
- Claustro 2 (verde)
- Claustro 3 (azul oscuro)
- Claustro 4 (amarillo)
- Claustro 5 (violeta)
- Claustro 6 (azul claro)
- 421 documentos



En la tercera etapa, se llevó a cabo una búsqueda filtrada utilizando las palabras clave más pertinentes previamente identificadas en la etapa anterior, tales como “artificial itelligence” “neural networks” “prediction” “artificial hydrocarbons networks” “artificial organic networks” “machine learning” “reservoir characterization” “Deep learning” “convolucional neural networks” “drilling” “fuzzy” “aplication” “data” “porosity”, Esta búsqueda

refinada fue fundamental para la elaboración del artículo de revisión. La figura 3 muestra los resultados de esta fase de la investigación, La selección cuidadosa de estas palabras clave refleja la focalización de la investigación en aspectos críticos relacionados con la inteligencia artificial y la industria de los hidrocarburos.

FIGURA 3. PALABRAS CLAVES DE MAYOR RELEVANCIA



APLICACIONES DE LA IA EN LAS ETAPAS DEL UPSTREAM

En la gran mayoría de los casos la exploración de los pozos representa el principal desafío, de ella depende el hallazgo de hidrocarburos líquidos en

el subsuelo. La exploración petrolera generalmente involucra tres fases principales. En primer lugar, se lleva a cabo un proceso de investigación geológica, que incluye la utilización de fotografías satelitales y la elaboración de mapas geológicos para evaluar las condiciones que podrían dar

lugar a un sistema petrolífero. En la segunda, se identifican áreas de interés donde las condiciones parecen ser propicias para la exploración y la detección de posibles yacimientos petroleros. Luego, se avanza a la fase final, que consiste en la perforación de un pozo exploratorio, que servirá para confirmar definitivamente la presencia o ausencia de hidrocarburos comercialmente extraíbles en el subsuelo [9]. Esta etapa representa grandes cantidades de almacenamientos de datos y muchas horas de estudio, para ello se han llevado a cabo diversas técnicas con ayuda de inteligencia artificial que hagan toda esta labor de manera eficiente y confiable; una de ellas es mediante imágenes sísmicas, con las llamadas Redes Neuronales Convolucionales (CNN) [10]. Estas redes neuronales son entrenadas con un gran conjunto de datos de imágenes sísmicas y etiquetas de interpretación para aprender patrones y características importantes en las imágenes. Luego, se utilizan estas redes neuronales para predecir la presencia de hidrocarburos en nuevas imágenes sísmicas. Además, se utiliza una técnica de segmentación para identificar y separar las áreas de interés en las imágenes sísmicas. En otro de los casos, de manera muy similar se utilizan algoritmos de aprendizaje automático en la modelación petrofísica [4], [11] y geomecánica para identificar zonas de yacimiento y predecir propiedades geomecánicas críticas durante la fracturación hidráulica, como la fracabilidad [12].

De manera general en la fase de exploración, se emplean diversas estrategias, entre las que destacan la utilización de teledetección a distancia y la aplicación del algoritmo SVM (Support Vector Machine) para la clasificación de imágenes. Adicionalmente, se han implementado técnicas como el análisis de registros de rayos gamma con el fin de identificar pozos que presenten elevada fraccionalidad [13]. También se han mejorado la resolución y la claridad de los datos sísmicos mediante enfoques como PNN (Probabilistic Neural Network) y ANN (Artificial Neural Network). Las anteriores técnicas de exploración son centradas más que todo en imágenes sísmica, donde también se puede explorar el

uso de métodos estudio rocoso con técnicas de agrupamientos de datos (GMDH) [14], todo esto con la finalidad de determinar la porosidad de los yacimientos. Estas estrategias han demostrado un desempeño superior en comparación con los métodos convencionales en cuanto a precisión y eficacia en el proceso de exploración.

El paso siguiente a la exploración petrolera es conocido como **Perforación**, con los datos ya obtenidos de la anterior etapa de exploración para así garantizar la *Producción o Extracción*, fase durante la cual se busca extraer el hidrocarburo desde un yacimiento hasta el pozo y de allí a la superficie; donde se separan, tratan, almacenan, miden y transportan para su posterior utilización, la producción forma parte de la cadena de actividades que realiza la industria petrolera [15].

TABLA 1. TÉCNICAS DE "MACHINE LEARNING" PARA LA DETERMINACIÓN DE PARÁMETROS

MI Algoritmo	Parámetro Previsto / Predicción	Referencia
Ann	Porosidad, Permeabilidad Y El Módulo De Young	[16]
Ls-Svr	Porosidad Y Permeabilidad	
Eml	Módulo De Young Y La Relación De Poisson	
Ann	Porosidad	[14]
Svm		
Gmdh		
Ann	Riesgos De Obstrucción De Hidratos	[5]
Svm	Presión Diferencial En La Perforación De Pozos	
Análisis De Datos En Tiempo Real	Producción En Campos Petroleros Digitales	
Mlfn	Porosidad Y Saturación De Agua	[17]
Pnn		

Entre los parámetros más importantes en la producción de hidrocarburos está mantener una tasa de rendimiento alta y la recuperación última estimada. La tasa de producción se refiere a la cantidad de hidrocarburos que se produce por unidad de tiempo. La recuperación última estimada se refiere a la cantidad total de hidrocarburos que se espera recuperar de un yacimiento de gas de

esquisto durante toda su vida útil [18]. En este orden de ideas, se han empleado técnicas para el control y evaluación de estos parámetros, tal como, en el estudio acerca de la producción de gas de esquisto [19] con técnicas de ANN, agrupamiento y SVM. En este estudio en particular, usó SVM para análisis de clasificación y regresión, y ANN para relacionar la producción del primer año con las características básicas del yacimiento.

Cabe aclarar que son muchas técnicas las utilizadas para la producción, un ejemplo claro se presenta para la producción petrolera es una metodología que se centra en el uso de red neuronal de memoria a largo plazo (LSTM) para modelar datos de series temporales y la combinación innovadora de modelos de análisis de curvas de declives (DCA) junto con datos para mejorar la capacidad predictiva y la interpretación de los modelos de redes neuronales para predecir el rendimiento de los pozos de gas [20]. Además, sucede que los yacimientos naturalmente fracturados, presentan una complejidad adicional debido a los movimientos tectónicos que aumentan la permeabilidad y conductividad de las fracturas, lo que a su vez afecta la estabilidad de la permeabilidad y la conductividad, y esto tiene un impacto en la ruta del flujo de fluidos, causando problemas durante la transferencia de los fluidos desde la matriz a las fracturas y pérdidas de fluidos durante la producción de la predicción del comportamiento de flujos con técnicas de ML [21]. En cuanto al factor de recuperación se han implementado modelos para conseguir mejorar las herramientas de cálculo ya presentes [22], [23], ensayando procedimientos de ejecución de árboles de decisión (DT), y distintas regresiones como la de Ridge (RR) Y LASSO.

PERSPECTIVAS DE LA IA EN LA INDUSTRIA PETROLERA

Recientemente, han surgido métodos novedosos de identificación de patrones basados en el aprendizaje profundo que han ganado reconocimiento en las operaciones sísmicas. Estos métodos han acelerado el proceso de

interpretación en una magnitud asombrosa [24]. Es importante señalar que, aunque la inteligencia artificial (IA) tiene limitaciones en cuanto a manejar aspectos físicos como la cantidad y ubicación de sensores en el proceso sísmico, ofrece beneficios significativos en la optimización de los procesos secundarios.

En cuanto a la contaminación derivada de derrames de hidrocarburos, ofrece una perspectiva innovadora. Estas tecnologías permiten medir con mayor precisión la cantidad de hidrocarburos en el suelo a través del aprendizaje profundo y el análisis de datos hiperespectrales que es una técnica que combina información espectral (espectros) y espacial (imágenes), lo que facilita la identificación de las propiedades de absorción de los hidrocarburos [25]. Además, el uso de las IA no solo se limita a la cuantificación sino a la mitigación del contaminante, la bioremediación es un ejemplo, la cual, mediante el empleo de herramientas de inteligencia artificial, como las redes neuronales artificiales (ANN) y técnicas de simulación de Monte Carlo (MCS), permite anticipar la concentración y la distribución espacial de contaminantes en un lugar específico. Asimismo, el uso de algoritmos mejorados de árbol de regresión (BRT) permite prever la efectividad de los procesos de biodegradación [26].

En esta perspectiva, los enfoques basados en la IA se erigen como un método eficaz para acelerar y, lo que es aún más crucial, eliminar la subjetividad inherente al proceso de interpretación [27]. Además de su aplicación futura en procesos sísmicos, la IA también promete una notable influencia en la generación eficiente de datos de registro de pozos. Esto, a su vez, abrirá la puerta al empleo de la IA en operaciones de registro de pozos, permitiendo a las compañías petroleras asignar menos recursos a esta tarea operativa. Además, se destaca que, a pesar de los avances en la predicción de producción con redes neuronales, estos métodos tienden a ser puramente basados en datos y pueden no tener en cuenta las leyes físicas que rigen el flujo de petróleo o gas a través de medios porosos [20].

Existen tres áreas principales de aplicación de la IA en la ingeniería de petróleo. En primer lugar, la IA puede revolucionar el proceso de cálculos realizado con simuladores de yacimientos convencionales [28]. Estos simuladores llevan a cabo cálculos numéricos complejos relacionados con la física de los flujos en yacimientos, lo que puede ser un proceso extremadamente lento. Sin embargo, los métodos de IA están demostrando ser capaces de acelerar significativamente estos cálculos sin comprometer su precisión.

La segunda área de aplicación se refiere a la escalación, un proceso que conlleva cierto grado de subjetividad. Los ingenieros de yacimientos a menudo recurren a trucos y técnicas diversas para llevar a cabo la escalación, lo que puede introducir sesgos en los modelos de simulación. Aquí, la IA puede brindar objetividad y aceleración al proceso, especialmente cuando se entrena con ejemplos manuales de escalación [29].

La tercera área de aplicación de la IA se encuentra en los yacimientos en producción [30]. La recopilación de datos de pozos en producción, a través de diversos métodos de tratamiento, puede reducir significativamente los costos de inversión y los riesgos asociados. Además, la IA puede contribuir a la eficiencia en la fracturación hidráulica y la resolución de problemas de inyectividad [31].

CONCLUSIONES

La convergencia de la inteligencia artificial (IA) con la industria de los hidrocarburos ha generado avances significativos que redefinen el panorama de esta industria. En especial en el upstream del petróleo, En este proceso, la IA ha demostrado su capacidad para impulsar la eficiencia y la sostenibilidad. La optimización de procesos, la toma de decisiones más precisa, así como mejorar la exploración y producción de hidrocarburos, a través de técnicas como Convolutional Neural Networks (CNN) y algoritmos de aprendizaje supervisado como Support Vector Machine (SVM) y redes neuronales artificiales (ANN), No obstante,

el uso de la IA en la industria de los hidrocarburos no está exento de desafíos, como la necesidad de una inversión significativa en tecnología y la gestión de datos a gran escala.

Además, con respecto al uso de la IA en esta gran industria aún se presentan desafíos de implementación de las técnicas, debido a que muchas en su mayoría requieren un conjunto de datos históricos de gran magnitud, lo que limita el hecho en su implementación. Sin embargo, se discuten las posibles aplicaciones futuras de la IA, como su uso para medir y reducir la contaminación de suelos contaminados de petróleo, optimizar cálculos complejos y mejorar los procesos de simulación en la industria. En conclusión, se prevé que la colaboración continua entre expertos en hidrocarburos y tecnólogos de la IA será fundamental para superar estos desafíos y aprovechar plenamente las oportunidades que esta convergencia ofrece.

REFERENCIAS

- [1] A. Saranya y R. Subhashini, "A systematic review of Explainable Artificial Intelligence models and applications: Recent developments and future trends", *Decision Analytics Journal*, vol. 7. Elsevier Inc., el 1 de junio de 2023. doi: 10.1016/j.dajour.2023.100230.
- [2] Z. Jin, "Hydrocarbon accumulation and resources evaluation: Recent advances and current challenges", *Advances in Geo-Energy Research*, vol. 8, núm. 1, pp. 1–4, 2023, doi:10.46690/ager.2023.04.01.
- [3] S. Bahaloo, M. Mehrizadeh, y A. Najafi-Marghmaleki, "Review of application of artificial intelligence techniques in petroleum operations", *Petroleum Research*, vol. 8, núm. 2. KeAi Publishing Communications Ltd., pp. 167–182, el 1 de junio de 2023. doi: 10.1016/j.ptlrs.2022.07.002.
- [4] S. Choubey y G. P. Karmakar, "Artificial intelligence techniques and their application in oil and gas industry", *Artif Intell Rev*, vol. 54, núm. 5,

pp. 3665–3683, jun. 2021, doi: 10.1007/s10462-020-09935-1.

[5] A. L. D'Almeida, N. C. R. Bergiante, G. de Souza Ferreira, F. R. Leta, C. B. de Campos Lima, y G. B. A. Lima, “Digital transformation: a review on artificial intelligence techniques in drilling and production applications”, *International Journal of Advanced Manufacturing Technology*, vol. 119, núm. 9–10. Springer Science and Business Media Deutschland GmbH, pp. 5553–5582, el 1 de abril de 2022. doi: 10.1007/s00170-021-08631-w.

[6] L. Zhang, J. Ling, y M. Lin, “Artificial intelligence in renewable energy: A comprehensive bibliometric analysis”, *Energy Reports*, vol. 8. Elsevier Ltd, pp. 14072–14088, el 1 de noviembre de 2022. doi: 10.1016/j.egy.2022.10.347.

[7] M. Wu *et al.*, “An artificial intelligence course for chemical engineers”, *Education for Chemical Engineers*, vol. 45, pp. 141–150, oct. 2023, doi: 10.1016/j.ece.2023.09.004.

[8] F. Flores, “‘Upstream’ de Petróleo”.

[9] PDSVA, “Exploración”, *Cuadernos de Soberanía Petrolera*. 2018.

[10] J. F. L. Souza, G. L. Santana, L. V. Batista, G. P. Oliveira, E. Roemers-Oliveira, y M. D. Santos, “CNN Prediction Enhancement by Post-Processing for Hydrocarbon Detection in Seismic Images”, *IEEE Access*, vol. 8, pp. 120447–120455, 2020, doi: 10.1109/ACCESS.2020.3005916.

[11] M. Stadtmüller y J. A. Jarzyna, “Estimation of Petrophysical Parameters of Carbonates Based on Well Logs and Laboratory Measurements, a Review”, *Energies*, vol. 16, núm. 10. MDPI, el 1 de mayo de 2023. doi: 10.3390/en16104215.

[12] M. Ramkumar, R. Nagarajan, y M. Santosh, “Advances in sediment geochemistry and chemostratigraphy for reservoir characterization”, *Energy Geoscience*, vol. 2, núm. 4, pp. 308–326, oct. 2021, doi: 10.1016/j.engeos.2021.02.001.

[13] P. Solanki, D. Baldaniya, D. Jogani, B. Chaudhary, M. Shah, y A. Kshirsagar, “Artificial intelligence: New age of transformation in petroleum upstream”, *Petroleum Research*, vol. 7, núm. 1. KeAi Publishing Communications Ltd., pp. 106–114, el 1 de febrero de 2022. doi: 10.1016/j.ptlrs.2021.07.002.

[14] S. Elkatatny, Z. Tariq, M. Mahmoud, y A. Abdurraheem, “New insights into porosity determination using artificial intelligence techniques for carbonate reservoirs”, *Petroleum*, vol. 4, núm. 4, pp. 408–418, dic. 2018, doi: 10.1016/j.petlm.2018.04.002.

[15] PDVSA, “Producción”, *Cuadernos de Soberanía Petrolera*. 2018.

[16] F. I. Syed, A. AlShamsi, A. K. Dahaghi, y S. Neghabhan, “Application of ML & AI to model petrophysical and geomechanical properties of shale reservoirs – A systematic literature review”, *Petroleum*, vol. 8, núm. 2. KeAi Communications Co., pp. 158–166, el 1 de junio de 2022. doi: 10.1016/j.petlm.2020.12.001.

[17] A. Ogbamikhumi y J. O. Ebeniro, “Reservoir properties estimation from 3D seismic data in the Alose field using artificial intelligence”, *Journal of Petroleum Exploration and Production*, vol. 11, núm. 3, pp. 1275–1287, mar. 2021, doi: 10.1007/s13202-021-01105-5.

[18] M. Salam, “Data-Driven Hydrocarbon Production Forecasting Using Machine Learning Techniques Spatio-Temporal Data Analysis View project”, *International Journal of Computer Science and Information Security (IJCSIS)*, vol. 18, 2020, [En línea]. Disponible en: <https://www.researchgate.net/publication/342643691>

[19] F. I. Syed, T. Muther, A. K. Dahaghi, y S. Negahban, “AI/ML assisted shale gas production performance evaluation”, *J Pet Explor Prod Technol*, vol. 11, núm. 9, pp. 3509–3519, sep. 2021, doi: 10.1007/s13202-021-01253-8.

- [20] L. Xue, J. Wang, J. Han, M. Yang, M. S. Mwasmwasa, y F. Nanguka, "Gas well performance prediction using deep learning jointly driven by decline curve analysis model and production data", *Advances in Geo-Energy Research*, vol. 8, núm. 3, pp. 159–169, jun. 2023, doi: 10.46690/ager.2023.06.03.
- [21] M. M. Shawkat, A. R. Bin Risal, N. J. Mahdi, Z. Safari, M. H. Naser, y A. W. Al Zand, "Fluid Flow Behavior Prediction in Naturally Fractured Reservoirs Using Machine Learning Models", *Complexity*, vol. 2023, 2023, doi: 10.1155/2023/7953967.
- [22] A. A. Mahmoud, S. Elkatatny, W. Chen, y A. Abdulraheem, "Estimation of oil recovery factor for water drive sandy reservoirs through applications of artificial intelligence", *Energies (Basel)*, vol. 12, núm. 19, sep. 2019, doi: 10.3390/en12193671.
- [23] P. Kharazi Esfahani, K. Peiro Ahmady Langeroudy, y M. R. Khorsand Movaghar, "Enhanced machine learning—ensemble method for estimation of oil formation volume factor at reservoir conditions", *Sci Rep*, vol. 13, núm. 1, dic. 2023, doi: 10.1038/s41598-023-42469-4.
- [24] A. Cunha, A. Pochet, H. Lopes, y M. Gattass, "Seismic fault detection in real data using transfer learning from a convolutional neural network pre-trained with synthetic seismic data", *Comput Geosci*, vol. 135, feb. 2020, doi: 10.1016/j.cageo.2019.104344.
- [25] R. Ayass, S. Mustapha, y D. Salam, "Quantification of Hydrocarbon Contamination in Soil Using Hyperspectral Data and Deep Learning", en *World Congress on Civil, Structural, and Environmental Engineering*, Avestia Publishing, 2023. doi: 10.11159/iceptp23.192.
- [26] R. Patowary, A. Devi, y A. K. Mukherjee, "Advanced bioremediation by an amalgamation of nanotechnology and modern artificial intelligence for efficient restoration of crude petroleum oil-contaminated sites: a prospective study", *Environmental Science and Pollution Research*, vol. 30, núm. 30. Springer Science and Business Media Deutschland GmbH, pp. 74459–74484, el 1 de junio de 2023. doi: 10.1007/s11356-023-27698-4.
- [27] I. Portugal, P. Alencar, y D. Cowan, "The use of machine learning algorithms in recommender systems: A systematic review", *Expert Systems with Applications*, vol. 97. Elsevier Ltd, pp. 205–227, el 1 de mayo de 2018. doi: 10.1016/j.eswa.2017.12.020.
- [28] E. Kuk, J. Stopa, M. Kuk, D. Janiga, y P. Wojnarowski, "Petroleum reservoir control optimization with the use of the auto-adaptive decision trees", *Energies (Basel)*, vol. 14, núm. 18, sep. 2021, doi: 10.3390/en14185702.
- [29] S. Hu, H. Zhang, R. Zhang, L. Jin, y Y. Liu, "Quantitative interpretation of toc in complicated lithology based on well log data: A case of majiagou formation in the eastern ordos basin, china", *Applied Sciences (Switzerland)*, vol. 11, núm. 18, sep. 2021, doi: 10.3390/app11188724.
- [30] F. I. Syed, S. Alnaqbi, T. Muther, A. K. Dahaghi, y S. Negahban, "Smart shale gas production performance analysis using machine learning applications", *Petroleum Research*, vol. 7, núm. 1. KeAi Publishing Communications Ltd., pp. 21–31, el 1 de febrero de 2022. doi: 10.1016/j.ptlrs.2021.06.003.
- [31] D. Orlov y D. Koroteev, "Advanced analytics of self-colmatation in terrigenous oil reservoirs", *J Pet Sci Eng*, vol. 182, nov. 2019, doi: 10.1016/j.petrol.2019.106306.

Autores

Jerry Meza
 Universidad del Atlántico
 jestebanmeza@mail.uniatlantico.edu.co