PetroRenova
REVISTA CIENTÍFICA DE LA ENERGÍA
INDEXED
Vol. 2 núm. 4
Octubre-Diciembre, 2026
Zulia-Venezuela
ISSN-e: 3080-6666

Gestión eficiente de yacimientos mediante inteligencia artificial

Efficient reservoir management using artificial intelligence

DOI: https://doi.org/10.5281/zenodo.23302643

Recibido: 2026-07-17 **Aceptado**: 2026-08-18

Fuenmayor Molero, Lenisbeth Paola[1]
Correo: lenisbethfuenmayoor32@gmail.com
Orcid: https://orcid.org/0009-0002-3712-6128

Resumen

El documento aborda la transición hacia la Ingeniería de Yacimientos 4.0, un paradigma que integra la Inteligencia Artificial (IA) y el procesamiento de Big Data para optimizar la gestión de reservorios de hidrocarburos. Frente a las limitaciones de tiempo y resolución de la simulación numérica tradicional, la IA propone el uso de modelos basados en datos (Data-Driven) y modelos híbridos, como las Redes Neuronales Informadas por la Física (PINNs), garantizando predicciones dinámicas, precisas y técnicamente viables. A través de cinco capítulos, el texto examina áreas críticas como la interpretación automatizada de sísmica mediante visión artificial, uso de algoritmos de agrupamiento y redes neuronales para predecir propiedades petrofísicas, creación de modelos sustitutos (Proxy Models) y desarrollo de Gemelos Digitales en tiempo real. Este ecosistema inteligente reduce la incertidumbre geológica, optimiza los procesos de recuperación adicional (EOR) y mejora la toma de decisiones bajo criterios de gobernanza del dato e interpretabilidad (XAI).

Palabras clave: Inteligencia artificial, gestión de yacimientos, gemelos digitales, redes neuronales informadas.

Abstract

The document addresses the transition to Reservoir Engineering 4.0, a paradigm that integrates Artificial Intelligence (AI) and Big Data processing to optimize hydrocarbon reservoir management. Faced with the time and resolution limitations of traditional numerical simulation, AI proposes the use of data-driven models and hybrid models, such as Physics-Informed Neural Networks (PINNs), guaranteeing dynamic, accurate, and technically feasible predictions. Through five chapters, the text examines critical areas such as the automated interpretation of seismic data using computer vision, the use of clustering algorithms and neural networks to predict petrophysical properties, the creation of proxy models, and the development of real-time digital twins. This intelligent ecosystem reduces geological uncertainty, optimizes enhanced oil recovery (EOR) processes, and improves decision-making based on data governance and interpretability (XAI) criteria.

Keywords: Artificial intelligence, reservoir management, digital twins, informed neural networks.

[1] Ingeniera en Petróleo. Petróleos & Renovables S. A. Maracaibo, Venezuela.

Artículo de acceso abierto bajo **Licencia Internacional Creative Commons Attribucion-NoComercial-CompartirIgual 4.0**

Introducción

La gestión eficiente de yacimientos ha evolucionado de métodos puramente empíricos y analíticos a un enfoque de Ingeniería de Yacimientos 4.0. La integración de la Inteligencia Artificial (IA) permite procesar volúmenes masivos de datos (Big Data) provenientes de sensores de fondo, registros y pruebas de producción para optimizar la recuperación de hidrocarburos en tiempo real**.**

Un cambio de paradigma en la Ingeniería de Yacimientos se define como una transformación fundamental e irreversible en los métodos, suposiciones teóricas y tecnologías utilizadas para caracterizar, simular y optimizar la extracción de hidrocarburos del subsuelo. Ocurre cuando los modelos convencionales resultan insuficientes para resolver los desafíos operativos o económicos actuales.

De acuerdo con Bora y Gupta (2021), la definición establece que un cambio de paradigma responde a una insuficiencia de los métodos actuales, lo que valida el punto 1 (contexto de la industria energética 4.0), al señalar que la simulación numérica tradicional enfrenta cuellos de botella críticos (altos tiempos de cómputo y falta de integración en tiempo real) en un escenario de campos maduros y volatilidad de precios. La necesidad económica y técnica actúa como el detonante del cambio.

Contexto de la Industria Energética 4.0

La industria de los hidrocarburos se encuentra en un punto de inflexión definido a la madurez de los campos petroleros y a la necesidad de optimizar costos operativos en un entorno de precios volátiles. Históricamente, la gestión de yacimientos ha dependido de la simulación numérica de flujos, la cual, aunque físicamente rigurosa, enfrenta desafíos críticos: altos tiempos de cómputo, dificultad para integrar datos en tiempo real y la incertidumbre inherente a la caracterización del subsuelo.

En este escenario, la Inteligencia Artificial (IA) no surge como un reemplazo, sino como un catalizador que permite la transición hacia campos inteligentes (Smart Fields). La capacidad de procesar grandes volúmenes de datos (Big Data) provenientes de sensores de fondo, cabezales de pozo y registros geofísicos ha abierto la puerta a modelos que pueden predecir el comportamiento del yacimiento con una velocidad y precisión sin precedentes.

El cambio de paradigma modifica las suposiciones teóricas. Se pasa de asumir que el comportamiento del yacimiento puede explicarse únicamente mediante ecuaciones diferenciales ideales (como la Ley de Darcy) a incorporar patrones complejos no lineales extraídos directamente de los datos (Big Data), lo cual se explica en el punto 2 (De los modelos mecanisticos a los basados en datos)

De los modelos mecanísticos a los basados en datos

La gestión tradicional se basa en ecuaciones diferenciales que describen el flujo en medios porosos (Ley de Darcy, balances de materia). Sin embargo, la heterogeneidad de los reservorios a menudo supera la capacidad de resolución de estos modelos. La IA, mediante el Aprendizaje Automático (Machine Learning) y el Aprendizaje Profundo (Deep Learning), permite identificar patrones no lineales y correlaciones ocultas en los datos que los métodos convencionales suelen ignorar.

Una de las innovaciones más prometedoras es el uso de Redes Neuronales Informadas por la Física (PINNs). Estas arquitecturas integran las leyes físicas fundamentales directamente en el proceso de entrenamiento de la IA, garantizando que las predicciones no solo sean estadísticamente coherentes, sino físicamente posibles.

Áreas críticas de impacto

Según Oliver y Chen (2011), las áreas críticas de impacto se definen como los frentes, procesos o dominios específicos dentro de un sistema, proyecto o disciplina donde la introducción de cambios, innovaciones o perturbaciones genera los resultados más significativos, determinantes y de mayor alcance en el desempeño global.

La investigación en este campo se centra en tres pilares fundamentales para la eficiencia operativa:

- Cotejo de históricos automatizado (Assisted History Matching): Reducción de semanas a horas en el ajuste de modelos de simulación mediante algoritmos de optimización.
- Caracterización dinámica: Uso de redes neuronales convolucionales (CNN) para interpretar sísmica y registros de pozos con mayor detalle.
- Optimización de la recuperación mejorada (EOR): Predicción del avance de frentes de invasión y selección óptima de patrones de inyección para maximizar el factor de recobro.

La adopción de la Inteligencia Artificial en la gestión de yacimientos responde a la necesidad crítica de maximizar la rentabilidad económica y reducir la huella ambiental mediante descarbonización, eficiencia energética y reducción de intervenciones fallidas en pozos. En este contexto, este documento busca desarrollar un marco conceptual que explique el uso de Machine Learning y Big Data para optimizar la caracterización, predicción y toma de decisiones en el subsuelo, evaluando las arquitecturas tecnológicas más sólidas, su integración en los flujos de trabajo tradicionales y los desafíos técnicos y éticos que implica la automatización operativa.

1. Fundamentos teóricos

En línea con lo discutido antes, esta investigación se dividió en 5 capítulos para su mejor comprensión:

1.1. Epistemología de la Ingeniería de Yacimientos 4.0

La epistemología de la ingeniería de yacimientos 4.0 se define como el estudio crítico de cómo se genera, valida y aplica el conocimiento sobre el comportamiento de los fluidos en el subsuelo, mediante la integración de la física tradicional de yacimientos con las herramientas de la cuarta revolución industrial, como el internet de las cosas, la inteligencia artificial y los gemelos digitales.

En este nuevo entorno tecnológico, el conocimiento ya no se construye únicamente a partir de interpretaciones estáticas de modelos geológicos y simulaciones numéricas convencionales, sino que evoluciona hacia un flujo continuo de aprendizaje automatizado y análisis de datos en tiempo real. Esto transforma radicalmente la forma en que los ingenieros toman decisiones, permitiendo que el entendimiento del yacimiento sea dinámico, predictivo y mucho más preciso.

Al respecto, autores como Bratvold y Begg (2020) señalan que, en la era digital, la verdadera evolución de la ingeniería no radica solo en adoptar nuevas tecnologías, sino en cambiar la forma en que procesamos la incertidumbre y tomamos decisiones basadas en datos, lo que obliga a redefinir el valor de la información y la manera en que estructuramos el conocimiento técnico para maximizar la recuperación de los hidrocarburos de forma eficiente y sostenible.

El objetivo es estructurar un marco conceptual que vincule la fenomenología de la dinámica de fluidos en yacimientos con las capacidades de aprendizaje computacional, examinando cómo

los algoritmos de IA redefinen los principios de caracterización y predicción en la ingeniería de reservorios contemporánea.

A continuación, se muestra un esquema que estructura, planifica y detalla los temas, objetivos, metodologías y criterios de evaluación de la investigación:

a) Del modelo analógico a la digital: Evolución de la gestión de activos desde métodos convencionales hasta la analítica avanzada.

La evolución desde el modelo analógico hacia el digital representa una transformación profunda en la gestión de activos petroleros, marcando el paso de una metodología basada en el análisis manual, reportes en papel y simulaciones estáticas aisladas, hacia un ecosistema interconectado gobernado por la analítica avanzada. En los métodos convencionales, la toma de decisiones solía ser reactiva, ya que los ingenieros dependían de datos históricos que se recolectaban de forma periódica y se procesaban con días o semanas de retraso.

Hoy en día, la digitalización ha permitido que la gestión de activos se convierta en un proceso dinámico y en tiempo real, donde algoritmos de aprendizaje automático e inteligencia artificial procesan instantáneamente miles de variables provenientes de sensores en los pozos e instalaciones de superficie. Esta transición no solo optimiza la producción y reduce los costos operativos al predecir fallas antes de que ocurran, sino que cambia por completo la forma en que se entiende la vida útil del yacimiento.

Al respecto, Satter y Iqbal (2016) explican que la gestión moderna de activos integrados requiere fusionar la ingeniería tradicional con las tecnologías de la información y el análisis de datos masivos, permitiendo que un equipo multidisciplinario evalúe escenarios complejos de manera inmediata y maximice el valor económico del campo a lo largo de todo su ciclo de explotación.

b) Big Data en el Upstream: Las 5 V; del dato (Volumen, Velocidad, Variedad, Veracidad, Valor) aplicadas a la caracterización de reservorios.

La aplicación del Big Data en el sector *Upstream*, específicamente a través de las cinco uves (Volumen, Velocidad, Variedad, Veracidad y Valor), ha transformado por completo la caracterización de reservorios al permitir procesar e interpretar la inmensa cantidad de información que genera un campo petrolero:

- Volumen, se refleja en los terabytes de datos que provienen de estudios sísmicos 3D y 4D o de registros de pozos históricos.

- Velocidad, representa la rapidez con la que los sensores de fondo de pozo y de superficie transmiten datos de presión y temperatura en tiempo real, exigiendo respuestas inmediatas.

- Variedad, se observa en la diversidad de formatos que los ingenieros deben unificar, combinando datos estructurados como tablas de producción con datos no estructurados como informes geológicos en texto o imágenes de núcleos.

- Veracidad, es el desafío crítico de limpiar y validar esa información para asegurar que los ruidos o fallas en los sensores no alteren los resultados del modelo.

- Valor, consiste en convertir esos datos crudos en conocimiento útil para tomar decisiones estratégicas, como ubicar con precisión el próximo pozo productor o predecir el avance del frente de agua.

Al respecto, Holdaway (2014) señala que la verdadera ventaja competitiva en la caracterización moderna de yacimientos no está en la simple acumulación de datos, sino en la capacidad de integrar estas dimensiones para reducir la incertidumbre geológica y optimizar las estrategias de recuperación de hidrocarburos a través de flujos de trabajo automatizados.

c) Paradigma de los modelos Data-Driven: Diferencias teóricas entre la modelización basada en la física y la modelización basada en datos.

El paradigma de los modelos basados en datos (*Data-Driven*) marca una evolución fundamental en la ingeniería de petróleo al cambiar la forma en que predecimos el comportamiento del subsuelo, diferenciándose conceptualmente de la modelización clásica basada en la física.

Los modelos tradicionales fundamentados en la física se basan en leyes universales y ecuaciones matemáticas conocidas —como la ley de Darcy o las ecuaciones de balance de materia— para describir el flujo de fluidos; sin embargo, requieren simplificar la compleja realidad geológica y consumen mucho tiempo de cómputo en yacimientos heterogéneos.

Por el contrario, la modelización *Data-Driven* no necesita asumir de antemano todas las leyes físicas del sistema, sino que utiliza algoritmos de aprendizaje automático para identificar patrones matemáticos ocultos directamente desde los datos históricos de producción, registros y presiones. Mientras que el enfoque físico va desde la teoría general hacia el caso específico del

pozo, el enfoque de datos va desde las observaciones reales hacia la construcción de una función predictiva. Esto permite realizar simulaciones en fracciones de segundo y actualizar los modelos de forma continua a medida que ingresa nueva información del campo.

Al respecto, Mohaghegh (2017) explica que la modelización basada en datos no busca reemplazar el entendimiento físico del yacimiento, sino capturar la complejidad empírica que las ecuaciones simplificadas no logran resolver, ofreciendo una herramienta complementaria de alta velocidad que transforma los datos operativos en decisiones comerciales y técnicas inmediatas.

1.2. Algoritmos y modelos de aprendizaje para Yacimientos

La transición operativa hacia la Ingeniería de Yacimientos 4.0 exige abandonar la presunción de que las técnicas de Inteligencia Artificial pueden aplicarse de forma genérica o como herramientas de automatización periférica. Por el contrario, la gestión moderna de activos sub-superficiales demanda una comprensión profunda de la arquitectura matemática y computacional de los algoritmos de aprendizaje. El diseño, entrenamiento y despliegue de estos modelos no solo deben responder a criterios de eficiencia estadística, sino que deben alinearse con la naturaleza estocástica, heterogénea y dinámica de los sistemas porosos**.**

Este capítulo tiene como propósito fundamental desglosar el ecosistema algorítmico que hace posible la transición desde la caracterización estática tradicional hasta la predicción dinámica en tiempo real. A lo largo de las siguientes secciones, se sistematizan las metodologías de aprendizaje automatizado, evaluando su capacidad de adaptación a las variables petrofísicas y termodinámicas que rigen el comportamiento de los fluidos en el subsuelo.

El objetivo es evaluar teóricamente la evolución de los paradigmas de modelado en la ingeniería de yacimientos, analizando la transición desde la simulación numérica convencional (Black Oil y Composicional) hacia arquitecturas basadas en datos y modelos híbridos (PINNs), determinando su eficacia en la representación de fenómenos complejos de flujo.

A continuación, se presenta la estructura metodológica que planifica, organiza y detalla los ejes temáticos, los objetivos, la estrategia de trabajo y los criterios de evaluación del estudio:

a) Aprendizaje supervisado:

- Regresiones avanzadas para la predicción de tasas de producción.
- Clasificación (Random Forest, SVM) para la identificación de facies litológicas.

El aprendizaje supervisado se ha consolidado en la ingeniería de yacimientos como una herramienta fundamental para resolver problemas de predicción y caracterización mediante algoritmos que aprenden a partir de datos históricos previamente etiquetados.

Dentro de esta rama de la inteligencia artificial, las regresiones avanzadas juegan un papel clave al analizar variables dinámicas como presiones de fondo, aperturas de estrangulador y propiedades de los fluidos para predecir, con alta precisión, las tasas de producción futuras, superando las limitaciones de los métodos tradicionales de curvas de declinación que suelen ignorar cambios abruptos en la operación del campo.

Por otro lado, las técnicas de clasificación como máquinas de vectores de soporte y bosques aleatorios, se aplican con gran éxito en la identificación de facies litológicas; estos algoritmos procesan datos heterogéneos provenientes de registros de pozos como rayos gamma, resistividad y porosidad neutrón para agrupar y reconocer automáticamente los diferentes tipos de roca en el subsuelo, reduciendo significativamente el tiempo que los geo-científicos dedican a la interpretación manual.

Al respecto, Anifowose y Abdulraheem (2011) demuestran que el uso combinado de estas técnicas avanzadas de aprendizaje supervisado permite modelar de forma óptima propiedades complejas del yacimiento como la porosidad y la permeabilidad, logrando que las predicciones operativas sean mucho más confiables incluso en formaciones geológicas altamente heterogéneas donde los métodos estadísticos convencionales fallan.

b) Aprendizaje no supervisado: Clustering (K-means) para la zonificación de yacimientos y definición de unidades de flujo.

El aprendizaje no supervisado se ha convertido en una herramienta clave para la caracterización de reservorios, destacando el uso de algoritmos de agrupamiento como *K-means* para la zonificación de yacimientos y la definición de unidades de flujo de manera puramente estadística y objetiva.

A diferencia de los métodos supervisados, esta técnica no requiere de datos previamente etiquetados o interpretados por el ingeniero, sino que analiza directamente los patrones ocultos y las similitudes matemáticas dentro de los datos de registros de pozos, tales como porosidad, permeabilidad, saturación de agua y presiones.

El algoritmo *K-means* funciona agrupando estos datos heterogéneos en conjuntos o clústeres específicos, donde cada grupo representa una roca con características hidráulicas y de almacenamiento similares; esto permite identificar de forma automática las distintas unidades de flujo en el subsuelo y delimitar zonas con comportamientos de producción homogéneos. Esta metodología elimina la subjetividad humana en las interpretaciones geológicas tradicionales y optimiza los modelos de simulación numérica al dividir el yacimiento en bloques de comportamiento predecible.

Al respecto, Al-Mudhafer (2017) señala que el uso de agrupamientos por *K-means* e inteligencia artificial no supervisada facilita la integración masiva de propiedades petrofísicas complejas, permitiendo clasificar de manera eficiente las unidades de flujo de los yacimientos y mejorar sustancialmente las estrategias de inyección de agua y recuperación mejorada en campos maduros.

c) Redes Neuronales Artificiales: Arquitecturas para la síntesis de registros de pozos y estimación de permeabilidad.

Las Redes Neuronales Artificiales (ANN) representan una de las tecnologías de inteligencia artificial más potentes en la ingeniería de yacimientos, siendo utilizadas con gran éxito en la síntesis de registros de pozos y en la estimación precisa de la permeabilidad. Estas redes imitan el comportamiento del cerebro humano al interconectar nodos o neuronas digitales en diferentes capas para procesar información compleja y encontrar relaciones ocultas entre variables que no siguen una lógica lineal.

En la práctica, cuando en un pozo nuevo faltan registros geofísicos clave debido a problemas operativos o altos costos de adquisición, una arquitectura de red neuronal puede entrenarse con datos de pozos vecinos para rellenar esos vacíos y reconstruir o sintetizar las curvas faltantes de forma automática.

De igual manera, las redes neuronales resuelven el histórico desafío de calcular la permeabilidad en formaciones heterogéneas; el algoritmo analiza registros convencionales de fácil acceso, como los de rayos gamma, densidad y porosidad, y los cruza con los datos reales de los núcleos tomados en el laboratorio, aprendiendo a predecir la permeabilidad a lo largo de todo el pozo con un margen de error mínimo.

Al respecto, Aminian y Ameri (2005) explican que las ANN constituyen una herramienta revolucionaria para la caracterización de reservorios, ya que tienen la capacidad única de aprender de ejemplos previos y correlacionar de forma eficiente múltiples propiedades petrofísicas, ofreciendo estimaciones de permeabilidad altamente confiables incluso en yacimientos complejos donde las ecuaciones matemáticas tradicionales fallan.

d) Redes Neuronales Informadas por la Física (Physics-Informed Neural Networks): Integración de las ecuaciones diferenciales de flujo (Ley de Darcy) en el entrenamiento de redes neuronales.

Las Redes Neuronales Informadas por la Física (PINNs) representan uno de los avances más importantes en la ingeniería de yacimientos moderna, ya que, logran unir el poder predictivo del análisis de datos con las leyes físicas fundamentales que gobiernan el subsuelo.

A diferencia de las redes neuronales comunes que solo aprenden observando datos históricos y que a veces pueden dar resultados matemáticos que no tienen sentido en la realidad, las PINNs integran, directamente, las ecuaciones diferenciales de flujo, como la Ley de Darcy y el principio de conservación de la masa, dentro del mismo proceso de entrenamiento del algoritmo.

Esto significa que la física del yacimiento actúa como un supervisor constante que penaliza a la red si intenta sugerir que el petróleo se mueve de una forma físicamente imposible. Al combinar estos dos mundos, las PINNs no solo necesitan muchísimos menos datos de producción para aprender a modelar el comportamiento del reservorio, sino que garantizan que las predicciones de presión y caudal sean técnicamente lógicas y confiables.

Al respecto, Raissi, Perdikaris y Karniadakis (2019) explican que las PINNs marcan un cambio profundo en la modelización científica al introducir las leyes de la física clásica en las funciones de pérdida de las redes neuronales, permitiendo resolver problemas complejos de dinámica de fluidos de manera ultra rápida, precisa y con una base teórica sólida que las herramientas de datos tradicionales simplemente no pueden ofrecer.

1.3. Caracterización y modelado estático con IA

La caracterización y el modelado estático de yacimientos constituyen la piedra angular sobre la cual se edifica cualquier estrategia de explotación, estimulación o recuperación adicional de hidrocarburos. Tradicionalmente, la construcción de este gemelo geométrico y petrofísico del

subsuelo ha dependido de la integración de datos indirectos (sísmica de superficie), datos puntuales directos (perfiles de pozos y núcleos) y técnicas geoestadísticas clásicas como el Kriging o la simulación estocástica condicional.

Si bien estos enfoques han sido el estándar de la industria, a menudo se enfrentan a severas limitaciones al intentar capturar la heterogeneidad extrema, las discontinuidades estructurales y las relaciones no lineales complejas inherentes a los sistemas geológicos, lo que se traduce en un elevado riesgo financiero y operacional.

La irrupción de la Inteligencia Artificial y el Aprendizaje Automatizado (Machine Learning) ha transformado este panorama de manera radical. El modelado estático asistido por IA no busca sustituir el criterio del geólogo o del petrofísico, sino potenciarlo, permitiendo procesar volúmenes masivos de información multi-escala de manera simultánea. Este enfoque cambia el paradigma predictivo: pasar de la interpolación matemática puramente geométrica a la detección de patrones multidimensionales complejos, logrando una representación del subsuelo significativamente más cercana a la realidad física

El objetivo es categorizar las áreas críticas de impacto de la Inteligencia Artificial en la gestión de yacimientos analizando, teóricamente, aplicación en la caracterización petrofísica, optimización de procesos de recuperación adicional (EOR) y precisión en la predicción de producción estableciendo un mapa de valor tecnológico en el subsuelo.

Seguidamente, se expone el marco metodológico que articula, planifica y especifica los núcleos temáticos, los propósitos, el plan de trabajo y los criterios para la evaluación de la investigación:

a) Geomodelo Inteligente: Uso de algoritmos para la interpolación de propiedades petrofísicas en mallas complejas.

El desarrollo de un geomodelo inteligente representa un salto tecnológico crucial en la caracterización de reservorios, ya que, consiste en el uso de algoritmos avanzados de aprendizaje automático e inteligencia artificial para realizar la interpolación y distribución de propiedades petrofísicas esenciales como porosidad y saturación de fluidos dentro de mallas geológicas tridimensionales altamente complejas.

En la modelización convencional, estimar lo que hay en el espacio entre pozo y pozo suele depender de métodos estadísticos geométricos que no siempre capturan la verdadera

continuidad de los canales de arena o las barreras de arcilla, lo que genera errores en el cálculo de las reservas de hidrocarburos.

Un geomodelo inteligente, en cambio, utiliza algoritmos capaces de procesar, simultáneamente, datos de diferentes fuentes como sísmica de reflexión, registros de pozos y pruebas de producción, aprendiendo a identificar cómo varían las propiedades de la roca en función de la geología local. Esto permite rellenar cada celda de la malla, incluso en zonas con fallas geológicas o geometrías difíciles, garantizando que el modelo digital refleje con alta fidelidad la heterogeneidad real del subsuelo y sirva como una base confiable para las simulaciones numéricas de flujo.

Al respecto, Caers (2011) explica que la integración de la inteligencia artificial y el modelado basado en patrones de datos permite superar las limitaciones de la geoestadística tradicional, ofreciendo una representación del yacimiento mucho más realista y precisa que reduce significativamente la incertidumbre en la toma de decisiones comerciales y de perforación.

b) Interpretación automatizada: Análisis sísmico asistido por visión artificial (Computer Vision) para la detección de fallas y discontinuidades.

La interpretación automatizada mediante visión artificial representa una revolución en el área exploratoria y de desarrollo de la ingeniería de petróleo, al permitir que algoritmos avanzados analicen imágenes y cubos de datos sísmicos de forma autónoma para identificar fallas y discontinuidades geológicas en el subsuelo.

En los flujos de trabajo tradicionales, los intérpretes deben revisar manualmente cientos de secciones sísmicas para marcar línea por línea dónde se rompen los estratos, un proceso que consume muchísimo tiempo y que está sujeto al cansancio o al criterio personal del profesional. La visión artificial cambia esto al tratar a los datos sísmicos como imágenes digitales complejas; mediante el uso de redes neuronales convolucionales, el sistema aprende a reconocer patrones visuales específicos, cambios abruptos en la continuidad de las amplitudes y sutiles interrupciones en los reflectores que indican la presencia de una falla.

Esta automatización no solo reduce el tiempo de interpretación de meses a solo unas pocas horas, sino que además logra detectar micro fallas y fracturas ocultas que el ojo humano podría pasar por alto, mejorando la precisión al definir los límites del yacimiento y evitando riesgos geológicos durante la planificación de nuevos pozos.

Al respecto, Wu (2019) demuestra que el uso de algoritmos basados en visión artificial y aprendizaje profundo permite extraer e interpretar de manera automática redes complejas de fallas tridimensionales directamente desde los datos sísmicos crudos, proporcionando un marco de trabajo altamente eficiente que optimiza la construcción de los modelos estructurales del subsuelo con un mínimo margen de error.

c) Reducción de incertidumbre: Modelos estocásticos y redes bayesianas para el análisis de riesgos geológicos.

La caracterización de yacimientos petrolíferos es, por naturaleza, un problema de información incompleta. El acceso al subsuelo se limita a observaciones directas extremadamente puntuales como los núcleos de roca y los registros de pozos combinadas con datos indirectos de gran escala como la sísmica de superficie. Esta desconexión de escalas espaciales genera una brecha de conocimiento que se traduce en incertidumbre geológica. Intentar describir de forma exacta la geometría de un reservorio, la continuidad de sus arenas o la distribución espacial de la porosidad y permeabilidad a miles de metros de profundidad introduce un riesgo latente en cada etapa del proyecto.

El impacto de no gestionar adecuadamente esta incertidumbre es tanto técnico como financiero y ambiental. En un enfoque tradicional determinista, ignorar la variabilidad del subsuelo puede conducir a dos escenarios críticos:

- *Subestimación del recurso:* Lleva al diseño de instalaciones de superficie insuficientes o a la pérdida de oportunidades de inversión rentables debido a una percepción exagerada del riesgo.
- *Sobredimensionamiento y predicciones optimistas:* Resulta en inversiones de capital ($CAPEX$) masivas en infraestructura que nunca será utilizada a su máxima capacidad, o peor aún, en la perforación de pozos secos o con altas tasas de corte de agua prematuro.

En la era de la Ingeniería de Yacimientos 4.0, la incertidumbre ya no se trata como un factor de error que debe ignorarse mediante factores de seguridad arbitrarios, sino como una variable cuantificable que debe ser integrada activamente en los flujos de toma de decisiones para maximizar el factor de recobro de forma segura y económicamente viable.

La reducción de la incertidumbre mediante el uso de modelos estocásticos y redes bayesianas constituye un pilar estratégico en la gestión moderna de proyectos petroleros, permitiendo evaluar y cuantificar los riesgos geológicos de una forma mucho más realista y matemática. A diferencia de los métodos deterministas tradicionales, que asumen un único valor fijo para propiedades como el espesor de la arena o la porosidad generando un solo escenario ideal, los modelos estocásticos realizan miles de simulaciones aleatorias combinando todas las variables posibles para entregarnos un rango de resultados con sus respectivas probabilidades de ocurrencia.

Por su parte, las redes bayesianas complementan este enfoque al funcionar como mapas interactivos de causa y efecto que calculan la probabilidad de éxito geológico; la gran ventaja de este sistema es su capacidad para actualizarse dinámicamente a medida que ingresa nueva información al proyecto, como los datos de un nuevo pozo perforado o un análisis de laboratorio reciente. Al integrar ambas herramientas, los ingenieros pueden identificar cuáles son las variables que más afectan la rentabilidad del campo y tomar decisiones basadas en datos concretos, minimizando la probabilidad de perforar pozos secos o de sobredimensionar las instalaciones de superficie.

Al respecto, Siddiqui y Rahman (2013) explican que la aplicación de modelos estocásticos y redes probabilísticas en el subsuelo transforma la gestión del riesgo, ya que permite estructurar de forma lógica el conocimiento experto y la evidencia técnica para reducir la incertidumbre geológica y optimizar las inversiones económicas en escenarios de exploración y desarrollo de yacimientos.

1.4. Optimización dinámica y simulación predictiva

La optimización dinámica y la simulación predictiva constituyen el motor operacional de la Ingeniería de Yacimientos 4.0, transformando los modelos estáticos en sistemas de gestión activa y en tiempo real. A diferencia de los enfoques convencionales de simulación numérica, que demandan semanas de procesamiento computacional, esta metodología implementa modelos de orden reducido y algoritmos de aprendizaje por refuerzo para proyectar el comportamiento termodinámico del subsuelo instantáneamente. Esto permite ajustar las estrategias de explotación de forma continua y anticipar la declinación de presión en los bloques.

Asimismo, este ecosistema digital integra algoritmos de control óptimo para regular la inyección de fluidos y la apertura de válvulas inteligentes basándose en flujos de datos continuos. Al acoplar la analítica predictiva con la física del reservorio, se logra maximizar el factor de recobro final y mitigar riesgos operacionales como la conificación prematura de agua.

El objetivo es describir la estructura teórica de un ecosistema de gestión inteligente, analizando la integración sinérgica entre la infraestructura de adquisición de datos en tiempo real (SCADA) y los algoritmos predictivos, estableciendo un flujo de trabajo digital que optimice la simulación dinámica del yacimiento**.**

A continuación, se desarrolla el diseño metodológico que integra, planifica y delimita los ejes temáticos, los objetivos de investigación, la ruta de trabajo y los parámetros de evaluación del estudio:

a) Proxy Models (Modelos Sustitutos): Creación de modelos de respuesta rápida que emulan simuladores numéricos de alta demanda computacional.

Los modelos sustitutos, o *Proxy Models*, representan una innovación crucial en la ingeniería de reservorios contemporánea al actuar como réplicas matemáticas de alta velocidad que emulan el comportamiento de los simuladores numéricos convencionales. En la gestión de yacimientos, los simuladores de yacimientos basados en ecuaciones en derivadas parciales (como los modelos *Black Oil* o composicionales) requieren resolver millones de celdas, lo que se traduce en días o semanas de procesamiento computacional para evaluar múltiples escenarios de producción. Los *Proxy Models* solucionan este cuello de botella mediante el uso de algoritmos de Machine Learning y funciones de base radial que aprenden las relaciones de entrada y salida directamente del simulador base.

De esta manera, el modelo sustituto puede predecir perfiles de presión, tasas de flujo y avances del frente de invasión en fracciones de segundo, permitiendo realizar análisis de sensibilidad masivos, optimizaciones en tiempo real y evaluaciones de riesgo probabilístico que de otro modo serían inviables por limitaciones de tiempo y cómputo.

La implementación de modelos sustitutos basados en datos se ha consolidado como la herramienta preferida para acelerar los flujos de trabajo repetitivos, tales como el cotejo de históricos automatizado (*Assisted History Matching*) y la optimización de la ubicación de pozos. Estas arquitecturas no pretenden reemplazar el rigor físico del simulador numérico, sino capturar su respuesta matemática en un entorno simplificado de bajo costo computacional.

Al respecto, Mohaghegh (2011) expone en sus investigaciones sobre modelado de yacimientos mediante inteligencia artificial que los modelos proxy basados en redes neuronales e ingeniería basada en datos (*Data-Driven Reservoir Modeling*) logran aproximar de manera precisa soluciones complejas de flujo multifásico en medios porosos. El autor destaca que, al entrenar adecuadamente la red con una muestra representativa de corridas del simulador numérico, el modelo sustituto hereda la capacidad de predecir el comportamiento dinámico del campo ante cambios en las variables de control, reduciendo los tiempos de ejecución de horas a segundos con márgenes de error estadísticamente insignificantes.

b) Gestión de Inyección de Fluidos: Optimización de patrones de inundación (Waterflooding) y recuperación mejorada (EOR) mediante algoritmos genéticos y aprendizaje por refuerzo.

La gestión de inyección de fluidos mediante tecnologías avanzadas representa un componente crítico de la optimización dinámica, diseñado para contrarrestar la declinación natural de la presión y maximizar la eficiencia de barrido en el yacimiento. En los procesos de optimización de patrones de inundación (*Waterflooding*) y recuperación mejorada (EOR), la determinación de las tasas óptimas de inyección y producción en sistemas multifásicos complejos plantea un desafío matemático de alta no linealidad. La integración de algoritmos genéticos y aprendizaje por refuerzo (*Reinforcement Learning*) permite automatizar y dinamizar estas decisiones. Los algoritmos genéticos actúan como herramientas de optimización global que evalúan de forma heurística millones de configuraciones de tasas de flujo para identificar la distribución ideal de pozos inyectores y productores.

Por su parte, el aprendizaje por refuerzo entrena agentes inteligentes que interactúan de forma continua con el entorno digital del reservorio, ajustando en tiempo real las variables de control operativas (como la apertura de válvulas inteligentes) basándose en una función de recompensa orientada a maximizar el valor presente neto (VPN) del proyecto y el factor de recobro final.

La aplicación de técnicas de inteligencia artificial al control de procesos EOR e inundación por agua ha demostrado superar con creces las estrategias de inyección estáticas o basadas en reglas empíricas convencionales.

Al respecto, Willhite y Green (2018), en sus amplios estudios sobre los mecanismos de recuperación secundaria y mejorada, señalan que la eficiencia de un proceso de inyección depende directamente de la gestión de la heterogeneidad del subsuelo y del control oportuno de

las tasas de fluidos para evitar la canalización prematura del agua o los químicos. Los autores explican que la incorporación de algoritmos metaheurísticos, como los algoritmos genéticos acoplados a modelos de simulación, viabiliza el diseño predictivo de patrones de flujo dinámicos. Esto faculta a los ingenieros para adaptar la arquitectura de inyección a las variaciones de presión y saturación del reservorio a lo largo del tiempo, logrando un frente de invasión uniforme que desplaza eficientemente el petróleo atrapado en los poros microscópicos de la roca, lo que minimiza la producción temprana de agua en los pozos productores.

c) Análisis de Curvas de Declinación (DCA) Avanzado: Integración de IA para el pronóstico de reservas (EUR) en yacimientos no convencionales y maduros.

El Análisis de Curvas de Declinación (DCA) Avanzado representa la evolución digital de los métodos empíricos tradicionales (como los modelos de Arps) hacia soluciones dinámicas de alta precisión capaces de procesar la complejidad de los yacimientos maduros y no convencionales. El DCA convencional asume condiciones operativas constantes y regímenes de flujo estables; sin embargo, en campos maduros con alta producción de agua o en reservorios no convencionales (*shale*) caracterizados por regímenes de flujo transitorio de larga duración, estas suposiciones conducen a errores críticos en la estimación de la Recuperación Final Acumulada (EUR).

La integración de la Inteligencia Artificial mediante modelos híbridos y algoritmos de redes neuronales recurrentes (como LSTM) transforma este análisis al fusionar las tendencias históricas de declinación con variables dinámicas operativas (presiones de fondo, cambios en el estrangulador e intervenciones de pozos). Esto permite capturar el comportamiento no lineal de la producción y generar pronósticos automáticos basados en datos en tiempo real, minimizando la incertidumbre en el cálculo de reservas y optimizando la planificación económica del activo a largo plazo.

La modernización del análisis de declinación a través de la analítica avanzada ha demostrado ser indispensable para resolver la severa caída de presión y los flujos multifásicos complejos que definen a las formaciones de baja permeabilidad.

Al respecto**,** Lee y Wattenbarger (2014), en sus extensos estudios sobre ingeniería de producción y análisis de comportamiento de pozos en yacimientos no convencionales, exponen que las ecuaciones clásicas de declinación tienden a sobreestimar de manera sistemática el EUR si no se modela adecuadamente el largo periodo de flujo transitorio lineal. Los autores explican

que la aplicación de metodologías avanzadas asistidas por algoritmos de aprendizaje computacional permite acoplar de forma analítica la física del medio poroso con el reconocimiento de patrones de datos históricos. Este enfoque automatizado faculta al ingeniero para segmentar con exactitud los diferentes regímenes de flujo (transitorio, de transición y de frontera) y ajustar las curvas predictivas de manera continua ante perturbaciones operacionales, garantizando estimaciones de reservas técnicamente viables y financieramente auditables bajo estándares internacionales.

1.4. Ecosistema de toma de decisiones y Gemelos Digitales

El ecosistema de toma de decisiones basado en gemelos digitales representa la cúspide de la integración tecnológica en la Ingeniería de Yacimientos 4.0, al consolidar una réplica virtual dinámica que interactúa continuamente con el reservorio real. Esta arquitectura digital no constituye un modelo estático aislado, sino una plataforma integral que fusiona de manera sinérgica la infraestructura de adquisición de datos en tiempo real (SCADA) con los algoritmos de analítica avanzada. A través de este flujo constante de información, el gemelo digital faculta a las organizaciones operadoras para evaluar escenarios operativos instantáneamente, transformando la administración reactiva tradicional en una gobernanza proactiva del activo sub-superficial.

Sin embargo, la viabilidad científica de estos ecosistemas inteligentes enfrenta desafíos críticos asociados a la veracidad del dato y la interpretabilidad de los modelos matemáticos. La opacidad inherente a los algoritmos avanzados de "caja negra" genera incertidumbre metodológica, lo que exige la evolución hacia marcos de trabajo transparentes y auditables que resguarden la seguridad física del reservorio. El valor fundamental de un gemelo digital en entornos de alta complejidad no radica únicamente en la simulación visual, sino en su capacidad analítica para predecir anomalías estructurales, optimizar el uso de los recursos e incrementar sustancialmente el factor de recobro final bajo estrictos criterios de mitigación del riesgo operacional.

El objetivo es examinar, de manera crítica, los desafíos teóricos y consideraciones éticas en la implementación de Gemelos Digitales para yacimientos, analizando las limitaciones impuestas por la calidad del dato, opacidad de los modelos de 'caja negra' y requerimientos computacionales dentro del marco de la Ingeniería de Yacimientos 4.0**.**

En esta sección se expone la estrategia metodológica que articula el planteamiento del problema, los objetivos trazados, la ruta procedimental y los criterios de validación que sostienen la rigurosidad científica de la investigación:

a) Arquitectura del *Digital Twin*: Conceptualización del yacimiento como una entidad digital que evoluciona en tiempo real.

La arquitectura del gemelo digital (*Digital Twin*) define el marco estructural que permite concebir e instrumentar un yacimiento petrolífero como una entidad digital viva y en constante evolución. Este enfoque trasciende las representaciones numéricas estáticas tradicionales al establecer un cordón umbilical de datos bidireccional entre las formaciones del subsuelo y las plataformas de cómputo en superficie.

La arquitectura se fundamenta en capas de adquisición automatizada que absorben continuamente flujos masivos de datos multivariables (presiones de fondo, temperaturas, tasas de flujo y caídas de tensión) provenientes de sensores inteligentes e infraestructura SCADA. Al ser procesados por algoritmos predictivos en tiempo real, estos datos actualizan de forma automática las propiedades dinámicas del modelo matemático. De este modo, el gemelo digital evoluciona sincrónicamente con el reservorio físico, permitiendo diagnosticar anomalías de producción de manera instantánea, simular escenarios de intervención sobre la marcha y operar el activo mediante un control en lazo cerrado que optimiza la eficiencia energética y la rentabilidad del campo.

La construcción de una arquitectura de gemelo digital robusta en el sector *Upstream* exige la convergencia precisa entre la fenomenología del flujo multifásico y los sistemas ciberfísicos.

Al respecto, Satter y Iqbal (2016), en sus investigaciones sobre la gestión integrada de activos inteligentes, sostienen que un gemelo digital no es simplemente un visualizador de datos 3D, sino un ecosistema computacional unificado donde la ingeniería convencional se asocia dinámicamente con la analítica avanzada. Los autores explican que la arquitectura debe ser capaz de asimilar la velocidad y variedad de la información de campo para recalibrar los balances de materia y los modelos de simulación de manera continua. Este proceso de asimilación y ajuste automatizado permite que la entidad digital herede el comportamiento histórico real del yacimiento y proyecte, con un mínimo margen de error, las respuestas de presión ante futuras estrategias de explotación, facultando a los equipos multidisciplinarios para tomar decisiones operativas óptimas basadas en un entendimiento en tiempo real de la física del subsuelo.

b) Soporte de Decisiones en Tiempo Real: Integración de flujos de datos SCADA con motores de inferencia para la optimización de la presión de fondo y levantamiento artificial.

El soporte de decisiones en tiempo real representa la integración operativa de la infraestructura SCADA (*Supervisory Control and Data Acquisition*) con motores de inferencia automatizados, configurando un sistema de analítica prescriptiva en la superficie. En la gestión de pozos activos, la captura continua de variables críticas como la presión de fondo fluyente, la temperatura, los aportes de gas y las frecuencias de operación es procesada de manera inmediata por algoritmos inteligentes. Estos motores de inferencia cruzan los datos crudos del SCADA con modelos matemáticos multifásicos, diagnosticando de forma instantánea ineficiencias u oportunidades de optimización en los sistemas de levantamiento artificial (como bombeo electrosumergible, cavidades progresivas o gas lift).

El sistema actúa emitiendo recomendaciones automáticas o ejecutando ajustes dinámicos directos sobre la frecuencia de los variadores y la apertura de válvulas inteligentes. Esto permite mantener la presión de fondo en niveles técnicamente ideales, estabilizar el flujo de hidrocarburos, prevenir daños prematuros en los equipos de fondo y extender de forma sustancial la vida productiva de los pozos sin requerir intervención humana constante.

La fusión de los flujos de datos en tiempo real con la lógica computacional de los motores de decisión ha redefinido el control operacional en campos inteligentes maduros y complejos.

Al respecto, Bratvold y Begg (2020), en sus profundos análisis sobre la toma de decisiones basada en datos dentro de la industria petrolera, exponen que el verdadero valor de la automatización industrial no reside en la acumulación pasiva de variables de campo, sino en la capacidad de procesarlas mediante modelos analíticos que reduzcan proactivamente la incertidumbre operativa. Los autores explican que al integrar los sistemas SCADA con motores de inferencia probabilística —como las redes bayesianas o la lógica difusa—, es posible modelar las interacciones dinámicas no lineales que ocurren entre el yacimiento y el pozo. Este enfoque estructurado faculta al sistema para predecir escenarios críticos, tales como la interferencia por gas o la sobrecarga del motor de fondo, recalculando instantáneamente las directrices de operación del levantamiento artificial para maximizar el flujo neto de hidrocarburos bajo un marco operativo seguro y completamente auditable.

c) Ética y Gobernanza del Dato: Calidad del dato, interpretabilidad de modelos (XAI - *Explainable AI*) y el rol del ingeniero frente a la "caja negra".

La ética y gobernanza del dato en la Ingeniería de Yacimientos 4.0 establece el marco regulatorio, técnico y moral que rige la captura, procesamiento y aplicación de la información del subsuelo para la toma de decisiones automatizadas. Este paradigma aborda la criticidad de la calidad del dato, entendiendo que algoritmos alimentados con información ruidosa, incompleta o descalibrada proveniente de sensores defectuosos generarán predicciones erróneas que ponen en riesgo la seguridad operacional del reservorio. Ante esto, la Inteligencia Artificial Explicable (XAI, *Explainable AI*) surge como una necesidad técnica indispensable para derribar la opacidad de los modelos de "caja negra", los cuales arrojan resultados sin detallar la lógica subyacente.

Las metodologías de XAI permiten desglosar matemáticamente cómo cada variable petrofísica o dinámica influye en el veredicto del algoritmo. En este entorno, el rol del ingeniero de petróleo se transforma radicalmente: deja de ser un analista pasivo de datos para convertirse en un auditor crítico del software, cuya responsabilidad ética es validar que las recomendaciones de la IA sean físicamente coherentes, técnicamente viables y alineadas con los principios de sostenibilidad y seguridad industrial.

La implementación de modelos matemáticos avanzados desprovistos de un control humano riguroso plantea severas limitaciones y riesgos económicos dentro de la administración de activos petroleros.

Al respecto, Mohaghegh (2017), en sus profundos análisis sobre la transición hacia la modelización basada en datos, expone que la confianza ciega en algoritmos predictivos puramente comerciales puede inducir a errores críticos de inversión si no se comprende su arquitectura interna. El autor explica que el ingeniero de yacimientos no puede delegar la toma de decisiones de subsuelo a una "caja negra" computacional, sino que debe exigir la adopción de herramientas de explicabilidad que traduzcan los patrones matemáticos abstractos en fenómenos físicos audibles (como gradientes de presión, balances de materia o regímenes de flujo). De esta manera, una gobernanza del dato bien fundamentada faculta al profesional para certificar la veracidad de los datos de entrada y descifrar la lógica interna del algoritmo, garantizando que el ecosistema digital funcione como un soporte complementario transparente que reduzca con seguridad el riesgo geológico y comercial.

2. Metodología

2.1. Tipo y diseño de investigación

El presente estudio se desarrolló bajo un enfoque cualitativo de carácter descriptivo-explicativo, mediante un diseño documental y bibliográfico no experimental. La investigación consistió en la búsqueda, recolección, sistematización, análisis crítico y síntesis de la literatura científica reciente relacionada con la transición hacia la Ingeniería de Yacimientos 4.0, la analítica de *Big Data* y la aplicación de algoritmos de Inteligencia Artificial (IA) en la caracterización y simulación de reservorios de hidrocarburos.

2.2. Unidades de análisis y criterios de selección

Las unidades de análisis estuvieron constituidas por artículos científicos, libros técnicos, *papers* indexados de la *Society of Petroleum Engineers* (SPE) y repositorios académicos especializados publicados entre 2005 y 2026.

Para la selección del material documental se aplicaron los siguientes criterios:

- **Criterios de inclusión:**

  a) Estudios vinculados directamente con la aplicación de Machine Learning, Deep Learning y redes neuronales (PINNs) en la gestión de subsuelo.

  b) Investigaciones sobre optimización de EOR, caracterización petrofísica, gemelos digitales y sistemas SCADA aplicados a yacimientos.

  c) Publicaciones respaldadas por autores clave en el área (e.g., Mohaghegh, Raissi, Caers, Bratvold, Wu, Satter).

- **Criterios de exclusión:**

  a) Documentos con falta de rigor metodológico o sin arbitraje de pares.

  b) Literatura enfocada exclusivamente en instalaciones de superficie sin impacto o conexión con la dinámica del reservorio.

3. Análisis y discusión de los resultados

La integración de la Inteligencia Artificial (IA) y la analítica de Big Data dentro de los flujos de trabajo de la Ingeniería de Yacimientos 4.0 demuestra una transformación operativa y

conceptual significativa respecto a los métodos tradicionales de simulación numérica y caracterización estática.

A partir de la revisión y síntesis metodológica realizada a lo largo de este estudio, el análisis de los resultados se articula en torno a cinco ejes fundamentales de beneficio técnico, operativo y económico:

3.1. Reducción de incertidumbre geológica y petrofísica

El uso de algoritmos de aprendizaje no supervisado (como K-means), modelos geológicos inteligentes y redes bayesianas permite una representación sustancialmente más fidedigna de las heterogeneidades del reservorio. A diferencia de la interpolación geoestadística convencional (ejemplo Kriging), el modelado basado en datos e IA procesa de manera simultánea atributos sísmicos 3D/4D, datos de núcleos y registros de pozos. Esto optimiza la precisión en la definición de unidades de flujo y la identificación automatizada de fallas mediante visión artificial (CNNs), mitigando el riesgo financiero al reducir la probabilidad de perforar pozos secos o subestimar/sobreestimar las reservas.

3.2. Optimización dinámica de la producción

La implementación de modelos híbridos (PINNs) y algoritmos de aprendizaje por refuerzo (*Reinforcement Learning*) facilitan el monitoreo y control, en tiempo real, de los procesos de extracción. La capacidad de analizar volúmenes continuos de datos provenientes de sistemas SCADA y sensores de fondo permite la detección temprana de fenómenos desfavorables como la conificación prematura de agua o gas, la canalización de fluidos en patrones de inyección y los cambios en las presiones de fondo. Esto faculta a los ingenieros para ajustar dinámicamente la apertura de estranguladores y válvulas inteligentes, maximizando el valor presente neto (VPN) y la eficiencia del barrido.

3.3. Eficiencia operativa y reducción de tiempos de cómputo

Uno de los mayores cuellos de botella de la simulación numérica de reservorios (modelos *Black Oil* o composicionales) reside en los elevados tiempos de procesamiento requeridos para iterar soluciones de ecuaciones en derivadas parciales. Los modelos sustitutos o *Proxy Models* (desarrollados con redes neuronales y funciones de base radial) emulan la respuesta de los simuladores convencionales en fracciones de segundo. Esta aceleración computacional hace

viables procesos complejos como el cotejo de históricos asistido (*Assisted History Matching*), el análisis masivo de sensibilidad y las simulaciones estocásticas probabilísticas en tiempo operativo.

3.4. Mantenimiento predictivo y mitigación de fallas

A nivel de la interfaz yacimiento-pozo, el cruce continuo de datos dinámicos mediante motores de inferencia automatizados promueve el mantenimiento predictivo de los sistemas de levantamiento artificial (BES, BCP, Gas Lift). Al prever anomalías en el comportamiento de los fluidos y fluctuaciones de presión, se minimizan las interrupciones no planificadas, se evita el daño prematuro a los equipos de fondo y se extienden los ciclos de vida útil de las instalaciones operativas.

3.5. Sostenibilidad y eficiencia en procesos EOR

La optimización de patrones de inundación (*Waterflooding*) y procesos de Recuperación Mejorada (EOR) mediante algoritmos genéticos garantiza un desplazamiento más uniforme de los hidrocarburos en el medio poroso. Esto no solo incrementa el factor de recobro final (EUR), sino que reduce el volumen de fluidos inyectados no eficientes, la producción excesiva de agua asociada y el consumo energético en superficie, alineando la gestión del yacimiento con los estándares actuales de descarbonización y reducción de la huella de carbono industrial.

Consideraciones finales

a) La transición hacia la Ingeniería de Yacimientos 4.0 representa un cambio de paradigma irreversible e integral en la gestión de activos petroleros, donde la convergencia entre la ciencia de datos, analítica avanzada y física del subsuelo redefine la toma de decisiones técnicas y operativas. A partir del análisis y desarrollo conceptual realizado en este trabajo, se sintetizan las siguientes consideraciones finales:

b) Reducción sustancial de la incertidumbre geológica y petrofísica**:** La integración de algoritmos de aprendizaje no supervisado (*clustering* K-means), geomodelos inteligentes e interpretación automatizada basada en visión artificial (redes convolucionales) permite capturar heterogeneidades complejas y discontinuidades estructurales con mayor precisión. Este enfoque supera las limitaciones de la interpolación geoestadística convencional, proporcionando una

caracterización del reservorio más robusta y minimizando el riesgo financiero en la perforación de nuevos pozos.

c) Optimización dinámica y en tiempo real de la producción**:** La implementación de modelos híbridos como las Redes Neuronales Informadas por la Física (PINNs) y algoritmos de Aprendizaje por Refuerzo (*Reinforcement Learning*) faculta la detección temprana y mitigación de fenómenos dinámicos adversos, como la conificación prematura de agua o gas y la canalización ineficiente de fluidos. El acople en lazo cerrado con datos dinámicos garantiza una maximización del Valor Presente Neto (VPN) del activo.

d) Eficiencia computacional mediante modelos sustitutos (Proxy Models): La sustitución de simuladores numéricos de flujo tradicionales por *Proxy Models* de respuesta rápida disminuye los tiempos de procesamiento de semanas a fracciones de segundo. Esto viabiliza operativamente flujos de trabajo de alta demanda computacional, tales como el cotejo de históricos asistido (*Assisted History Matching*), el análisis masivo de sensibilidad y la simulación estocástica en tiempo real.

e) Mantenimiento predictivo e integridad del sistema yacimiento-pozo: La interacción de motores de inferencia con redes SCADA faculta la analítica prescriptiva sobre los sistemas de levantamiento artificial (BES, BCP, Gas Lift), anticipando fallas mecánicas y variaciones desfavorables en la presión de fondo fluyente. Esto prolonga la vida útil de los equipos de fondo y asegura la continuidad operativa.

f) Sostenibilidad operacional y eficiencia en EOR**:** El uso de algoritmos metaheurísticos y genéticos en la optimización de patrones de inyección (Waterflooding y EOR) no solo incrementa la Recuperación Final Acumulada (EUR), sino que reduce el consumo de agua e insumos químicos y optimiza el uso de energía en superficie, alineando la gestión técnica con los objetivos globales de descarbonización y reducción de la huella de carbono industrial.

g) Gobernanza del dato y evolución del rol profesional**:** El éxito de este ecosistema inteligente depende de la calidad e integridad del dato masivo (*Big Data*), así como de la interpretabilidad de los modelos matemáticos mediante técnicas de IA Explicable (XAI). Frente a los riesgos asociados a los modelos de "caja negra", el ingeniero de yacimientos evoluciona de analista pasivo a un auditor crítico y supervisor ético, garantizando que las decisiones automatizadas mantengan una coherencia física, técnica y de seguridad industrial rigurosa.

Referencias

Al-Mudhafer, M. (2017). K-Means Clustering for Reservoir Zoning and Flow Units Definition. info@spe.org. Society of Petroleum Engineers. Estados Unidos. "Automated Reservoir Characterization Using Unsupervised Learning". *SPE Reservoir Evaluation & Engineering Journal*. Journal-editor@spe.org

Al-Mudhafer, W. J. (2017). Integrating well log interpretations and core measurements for flow unit classification using unsupervised machine learning algorithms. *Journal of Petroleum Science and Engineering*, 151, 201–211. https://doi.org/10.1016/j.petrol.2017.01.008

Aminian, K., & Ameri, S. (2005). Application of artificial neural networks for reservoir characterization. *Journal of Natural Gas Science and Engineering*, 2(1), 1–11. https://doi.org/10.1016/j.jngse.2005.01.001

Anifowose, F., y Abdulraheem, A. (2011). Advanced Supervised Learning Techniques for Reservoir Property Modeling. fanifowose@kfupm.edu.sa. King Fahd University of Petroleum and Minerals. Arabia Saudita. "Lithofacies Identification and Production Rate Predictions via Random Forest and SVM". *Computers & Geosciences*. cgeo-journal@elsevier.com

Bora, B., & Gupta, A. (2021). Smart fields and digital transformation in the upstream oil and gas industry: A review of current trends and future directions. *Journal of Petroleum Science and Engineering*, 203, 108620. https://doi.org/10.1016/j.petrol.2021.108620

Bratvold, R., y Begg, S. (2020). *Making Good Decisions in the Oil and Gas Industry*. reidun.bratvold@uis.no. Center for Oil Recovery, University of Stavanger. Noruega. "Epistemology and Decision-Making Under Uncertainty in Reservoir Engineering 4.0". SPE Operations & Management. manageditor@spe.org

Caers, J. (2011). *Modeling Uncertainty in the Earth Sciences*. jcaers@stanford.edu. Wiley-Blackwell. Estados Unidos. "Intelligent Geomodeling and Pattern-Based Spatial Simulation". Mathematical Geosciences. math-geosciences@springer.com

Holdaway, K. (2014). Harnessing Oil and Gas Big Data Analytics. keith.holdaway@sas.com. John Wiley & Sons. Reino Unido. "The 5 Vs of Data Applied to Modern Reservoir Characterization". *Oil & Gas Journal*. ogj-editor@pennwell.com

Lee, J. y Wattenbarger, R. (2014). *Gas Reservoir Engineering*. j.lee@tamu.edu. Society of Petroleum Engineers. Estados Unidos. Advanced decline curve analysis and EUR estimation in unconventional reservoirs. SPE Production & Operations. r.wattenbarger@tamu.edu

Mohaghegh, S. (2011). Data-driven reservoir modeling. shahab@data-drivenreservoirmodeling.com. Society of Petroleum Engineers. Estados Unidos. Implementing proxy models for rapid reservoir simulation. *Journal of Petroleum Technology*. s.mohaghegh@wvu.edu.

Mohaghegh, S. (2017). Data-Driven Reservoir Modeling. shahab@data-driven-reservoir.com. Exploration and Production Data Analytics Tech. Estados Unidos. "Differences Between Physics-Based and Data-Driven Paradigm in Petroleum Engineering". *Journal of Petroleum Data Analytics*. jpda-editorial@spe.org

Oliver, D. S., & Chen, Y. (2011). Recent progress on reservoir history matching: a review. *Computational Geosciences*, 15(1), 185–221. https://doi.org/10.1007/s10596-010-9194-2

Raissi, M., Perdikaris, P., y Karniadakis, G. (2019). Physics-Informed Neural Networks: A Deep Learning Framework. maziar.raissi@colorado.edu. Brown University Center for Fluid Mechanics. Estados Unidos. "Integrating Darcy's Law in the Training of Neural Networks for Porous Media". *Journal of Computational Physics*. jcp-office@elsevier.com

Satter, A., y Iqbal, G. (2016). Reservoir Engineering 4.0 and Integrated Asset Management. abdus.satter@unisa.edu. Gulf Publishing Company. Estados Unidos. "From Analogue to Digital Assets via Advanced Analytics". *World Oil Magazine*. editorial@worldoil.com

Siddiqui, S., y Rahman, M. (2013). Stochastic Modeling and Geological Risk Analysis. ssiddiqui@ttu.edu. Texas Tech University Press. Estados Unidos. "Bayesian Networks and Probabilistic Models for Subsurface Risk Management". *Journal of Petroleum Exploration and Production Technology*. jpept-editor@springer.com

Willhite, G. y Green, D. (2018). *Enhanced Oil Recovery*. g.willhite@ku.edu. Society of Petroleum Engineers. Estados Unidos. Advanced optimization of injection patterns in mature fields. SPE Reservoir Evaluation & Engineering. d.green@ku.edu.

Wu, X. (2019*). Computer Vision in Geosciences*. xinwucg@ustc.edu.cn. University of Science and Technology of China. China. "Automated Seismic Interpretation for Fault and Discontinuity Detection Using CNNs". IEEE Transactions on Geoscience and Remote Sensing. tgrs-editor@ieee.org

Declaración de conflicto de interés y originalidad

Conforme a lo estipulado en el C*ódigo de ética y buenas prácticas* publicado en ***PetroRenova Indexed, Revista Científica de la Energía***, la autora ***Fuenmayor Molero, Lenisbeth Paola***, declara al Comité Editorial que no tiene situaciones que representen conflicto de interés real, potencial o evidente, de carácter académico, financiero, intelectual o con derechos de propiedad intelectual relacionados con el contenido del artículo: ***Gestión eficiente de yacimientos mediante inteligencia artificial***, en relación con su publicación. De igual manera, declara que el trabajo es original, no ha sido publicado parcial ni totalmente en otro medio de difusión, no se utilizaron ideas, formulaciones, citas o ilustraciones diversas, extraídas de distintas fuentes, sin mencionar de forma clara y estricta su origen y sin ser referenciadas debidamente en la bibliografía correspondiente. Consiente que el Comité Editorial aplique cualquier sistema de detección de plagio para verificar su originalidad.

La autora declara que, en la preparación de este manuscrito, no utilizó herramientas de inteligencia artificial generativa para la redacción de textos o interpretación de datos.

Para citar este artículo:

Fuenmayor, L. (2026). Gestión eficiente de yacimientos mediante inteligencia artificial. *PetroRenova Indexed, Revista Científica de la Energía*. Vol. 2, núm. 4, octubre-diciembre, 2026. https://doi.org/10.5281/zenodo. 23302643