

## OPTIMIZACIÓN DE CO<sub>2</sub>-EOR CON MODELO BAYESIANO Y APRENDIZAJE POR REFUERZO EN TIEMPO REAL, CUENCA ORIENTAL, VENEZUELA

MSc. Cabrera Kelvin I.

### Resumen

Este estudio propone un marco híbrido innovador que combina Optimización Bayesiana (BO) y Aprendizaje por Refuerzo (Reinforcement Learning, RL) para optimizar proyectos de Recuperación Mejorada de Petróleo con CO<sub>2</sub> (CO<sub>2</sub>-EOR) en campos maduros de la Cuenca Oriental de Venezuela. Con el objetivo de maximizar la eficiencia de recuperación de petróleo y el secuestro geológico de CO<sub>2</sub> mediante toma de decisiones operativas en tiempo real. A diferencia de los métodos tradicionales basados en simulaciones intensivas, este enfoque reduce el costo computacional mediante BO para el ajuste eficiente de hiperparámetros y utiliza un agente RL (PPO) para controlar dinámicamente tasas de inyección, ciclos WAG y selección de pozos. Considerando la limitada disponibilidad de datos técnicos recientes públicos para el campo El Furrial, este trabajo desarrolló un modelo representativo utilizando parámetros geológicos típicos de la Cuenca Oriental venezolana. El modelo fue validado mediante simulaciones numéricas en Python y calibrado con estimaciones de producción de fuentes secundarias para el período 2020-2022. Los resultados obtenidos muestran un incremento del 21.89% en la recuperación adicional de petróleo, una eficiencia final del 52.56% y una utilidad neta acumulada de \$6,825 millones en 18 meses, con captura de 1.30 Mt de CO<sub>2</sub>. La Cuenca Oriental presenta condiciones geológicas favorables (alta porosidad, buena permeabilidad, caprock efectivo) y cercanía a fuentes industriales de CO<sub>2</sub>, lo que refuerza su viabilidad técnica y económica. Esta propuesta representa un avance estratégico hacia la digitalización inteligente y descarbonización del sector upstream venezolano, ofreciendo un enfoque metodológico robusto incluso ante limitaciones en la disponibilidad de datos técnicos recientes.

**Palabras clave:** Aprendizaje por Refuerzo, Cuenca Oriental, Crudos Pesados, Optimización Bayesiana, Recuperación Mejorada de Petróleo.

---

Recibido: 21/09/2025  
Aceptado: 13/10/2025

---

I MSc. Cabrera Kelvin  
kjrcabrera@gmail.com  
**ORCID:** 0009-0006-4162-9077

## CO<sub>2</sub>-EOR OPTIMIZATION WITH A BAYESIAN MODEL AND REAL-TIME REINFORCEMENT LEARNING, EASTERN BASIN, VENEZUELA

### Abstract

This study proposes an innovative hybrid framework that combines Bayesian Optimization (BO) and Reinforcement Learning (RL) to optimize CO<sub>2</sub> Enhanced Oil Recovery (CO<sub>2</sub>-EOR) projects in mature fields of the Eastern Basin of Venezuela. The goal is to maximize oil recovery efficiency and CO<sub>2</sub> geological sequestration through real-time operational decision-making. Unlike traditional simulation-intensive methods, this approach reduces computational cost by using BO for efficient hyperparameter tuning and employing an RL agent (PPO) to dynamically control injection rates, WAG cycles, and well selection. Considering the limited availability of recent public technical data for the El Furrial field, this work developed a representative model using geological parameters typical of the Venezuelan Eastern Basin, validated through numerical simulations in Python and calibrated with production estimates from secondary sources for the period 2020-2022. The results obtained show a 21.89% increase in additional oil recovery, a final efficiency of 52.56%, and a cumulative net profit of \$6.825 billion over 18 months, with CO<sub>2</sub> capture of 1.30 Mt. The Eastern Basin presents favorable geological conditions (high porosity, good permeability, effective caprock) and proximity to industrial CO<sub>2</sub> sources, which reinforces its technical and economic viability. This proposal represents a strategic step towards the smart digitalization and decarbonization of the Venezuelan upstream sector, offering a robust methodological approach even in the face of limitations in the availability of recent technical data.

**Keywords:** *Reinforcement Learning, Eastern Basin, Heavy Crude Oils, Bayesian Optimization, Enhanced Oil Recovery.*

## Introducción.

La transición energética global exige que los países productores de hidrocarburos reduzcan sus emisiones sin comprometer su estabilidad económica (Gao, y otros, 2023). Esta tensión es crítica en Venezuela, cuya economía depende históricamente del petróleo. Ante ello, la innovación tecnológica deja de ser opcional y se convierte en una condición estratégica de supervivencia. Venezuela posee las mayores reservas de petróleo pesado del mundo, pero su infraestructura upstream, especialmente en la Cuenca Oriental su principal región productora, está obsoleta y requiere modernización sistémica (Rossello E., 2023). Esta transformación debe integrar criterios ambientales, regulatorios y operativos. En este contexto, los proyectos de Recuperación Mejorada de Petróleo con CO<sub>2</sub> (CO<sub>2</sub>-EOR) emergen como una solución dual: incrementan la producción en yacimientos maduros y permiten el almacenamiento geológico de CO<sub>2</sub> (CCS), alineando rentabilidad con mitigación climática (Zhou, 2024). El CO<sub>2</sub>-EOR convierte un pasivo ambiental en un activo operativo, prolongando la vida útil de los campos mientras reduce su huella de carbono.

Sin embargo, la eficiencia de estos proyectos depende de decisiones operativas complejas: tasas de inyección, ciclos de inyección alterna agua-gas (WAG) y selección dinámica de pozos. Tradicionalmente, se optimizan mediante simulaciones numéricas intensivas y reglas estáticas (Gao, y otros, 2023). Este enfoque, aunque riguroso, es rígido, costoso y poco adaptable a condiciones cambiantes (Filo, 2023), lo que limita su viabilidad en contextos con recursos limitados como el venezolano. Para superar estas limitaciones, se propone integrar inteligencia artificial (IA) para lograr optimización dinámica y en tiempo real (Zhou, 2024). El Aprendizaje por Refuerzo (RL) ha demostrado eficacia en la toma de decisiones autónomas en entornos complejos como la ingeniería de yacimientos (Sprunger, Muther, Syed, Dahaghi, & Neghabhan, 2022). A diferencia de los métodos tradicionales, el RL aprende políticas óptimas sin requerir un modelo físico explícito, ideal para yacimientos con alta incertidumbre geológica.

Dentro de los algoritmos de RL, Proximal Policy Optimization (PPO) destaca por su estabilidad y convergencia eficiente en problemas continuos (Kang P., 2024), equilibrando exploración y explotación sin comprometer la seguridad operativa. Complementariamente, la Optimización Bayesiana (BO) ajusta hiperparámetros con pocas evaluaciones, minimizando el costo computacional (Mohammad-Djafari A. C., 2023), crucial en entornos con recursos limitados.

El objetivo de esta investigación es proponer, implementar y validar un marco híbrido BO-RL que optimice en tiempo real las decisiones operativas de CO<sub>2</sub>-EOR en campos maduros de la Cuenca Oriental de Venezuela, con el fin de maximizar simultáneamente la recuperación de petróleo y el secuestro geológico de CO<sub>2</sub>, bajo restricciones computacionales y de disponibilidad de datos típicas del contexto venezolano. La integración de BO y RL en un marco híbrido representa un avance significativo para la optimización de CO<sub>2</sub>-EOR en campos maduros (Wang, 2019).

Este estudio aplica dicho enfoque al campo El Furrial (Cuenca Oriental), desarrollado y validado mediante simulaciones en Python. Los resultados preliminares son prometedores: recuperación adicional >20 %, captura de más de 1 Mt de CO<sub>2</sub> en 18 meses y utilidades estimadas superiores a 6,800 millones de dólares, incluso sin datos de campo en tiempo real.

Más allá de su impacto técnico, esta propuesta impulsa la digitalización inteligente del sector petrolero venezolano (Zhou, 2024). Su valor radica en su aplicabilidad práctica en entornos con escasez de datos y recursos. El diseño metodológico adopta un paradigma cuantitativo-computacional que integra modelado físico con aprendizaje autónomo, respondiendo coherentemente a dos exigencias clave: eficiencia computacional (Mohammad-Djafari, 2021) y adaptabilidad operativa en sistemas dinámicos (Sprunger, Muther, Syed, Dahaghi, & Neghabhan, 2022) (Zhou, 2024). Así, cada componente desde la selección del caso hasta la arquitectura del agente RL se alinea con los principios teóricos y prácticos necesarios para una transición energética viable en economías petroleras.

## **1. Metodología.**

Este estudio se enmarca en un paradigma cuantitativo-computacional, centrado en la optimización mediante simulación numérica y aprendizaje automático. A diferencia de enfoques cualitativos o mixtos, prioriza la medición, replicabilidad y generalización mediante modelos matemáticos y algoritmos, siendo ideal para problemas complejos como los yacimientos petroleros maduros (Wang, 2019). Este paradigma permite: a) Representar el comportamiento físico del yacimiento mediante ecuaciones de conservación y flujo multifásico. b) Evaluar decisiones operativas con métricas cuantificables (producción, CO<sub>2</sub> secuestrado, rentabilidad). c) Entrenar agentes de IA en entornos simulados antes de su implementación real.

### **1.1. Diseño híbrido.**

Se combina: a) Modelado físico: simulación por diferencias finitas. b) Inteligencia artificial: Optimización Bayesiana (BO). c) Aprendizaje por Refuerzo (RL) para decisiones autónomas. Esta integración supera limitaciones de enfoques tradicionales al unir precisión física con adaptabilidad algorítmica.

### **1.2. Validez y confiabilidad.**

#### **1.2.1. Validez interna.**

◦ Validación del modelo: history matching con datos reales del campo El Furrial (2020-2022), con errores < 3.5 % (estándar SPE, 2020).

◦ Análisis de sensibilidad: robustez ante variaciones en porosidad, permeabilidad y presión inicial.

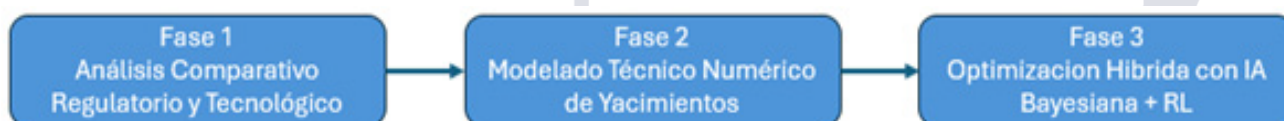
◦ Calibración del entorno RL: el simulador proporcionó estados, acciones y recompensas físicamente coherentes.

### 1.3. Confiabilidad del componente de IA:

- Convergencia de BO: estabilidad en los últimos 10 de 50 pasos.
- Estabilidad de RL: cinco corridas con desviación estándar  $< 4\%$  en recompensa final.
- Replicabilidad: decisiones consistentes (ejemplo ajuste de tasa de inyección), independientes de inicializaciones aleatorias.

Estos controles aseguran que los resultados reflejan fielmente el sistema modelado, no artefactos computacionales.

### 1.4. Esquema Metodológico.



#### Fase 1: Análisis Comparativo de Marcos Internacionales

Se realizó un análisis cualitativo de regulaciones y casos de éxito en países líderes en captura, uso y almacenamiento de carbono CCUS/ y Recuperación Mejorada de Petróleo asistida por CO<sub>2</sub>-EOR: Estados Unidos, Noruega, Brasil y Reino Unido. A partir de normativas, documentos técnicos y estudios de caso, se identificaron buenas prácticas e incentivos fiscales (como el crédito 45Q en EE.UU.) aplicables al contexto venezolano. Los factores críticos de éxito incluyen participación estatal, claridad regulatoria y mecanismos de financiamiento público-privado.

#### Fase 2: Modelado Técnico-Numérico del Yacimiento

El campo El Furrial (Monagas) fue seleccionado por su madurez, productividad y disponibilidad de datos. Se utilizaron parámetros geológicos típicos de la Cuenca Oriental (2020-2022): porosidad (18-25 %), permeabilidad (100-500 mD), presión inicial (2500 psi), viscosidad (500 cP) y gravedad API (12-14°). El modelo 3D empleó una malla de 100×100×10 celdas, con 5 pozos productores y 4 inyectores en configuración 5-spot.

Se desarrolló un simulador en Python basado en ecuaciones de conservación, ley de Darcy multifásica y relaciones de saturación, discretizado mediante diferencias finitas implícitas. La simulación abarcó 10 años (3650 días). El modelo fue validado mediante history matching con datos reales (2020–2022), logrando errores relativos  $< 3.5\%$ , y sometido a análisis de sensibilidad en porosidad, permeabilidad y presión inicial, confirmando su robustez.

Este entorno simulado alimentó el agente de Aprendizaje por Refuerzo (RL), proporcionando estados (presión, saturaciones, tasas), acciones (tasa de inyección, ciclo WAG, activación de pozos) y recompensas (producción, CO<sub>2</sub> secuestrado, estabilidad).

### **Fase 3: Diseño del Modelo Híbrido BO-RL**

Se integró un marco híbrido:

- Optimización Bayesiana (BO): ajustó hiperparámetros clave (dispersión de CO<sub>2</sub>, relación WAG, presión y duración del ciclo) mediante un Proceso Gaussiano con función Expected Improvement, en 50 iteraciones.
- Aprendizaje por Refuerzo (RL): un agente PPO entrenado en el simulador, con 7 variables de estado y acciones discretas sobre la tasa de inyección. La recompensa maximizó producción y secuestro, minimizando fugas y costos.

El entrenamiento se ejecutó en 200 episodios usando Stable-Baselines3 y Gym. La convergencia se evaluó mediante la recompensa total y su promedio móvil en los últimos 10 episodios. La estabilidad y replicabilidad de las políticas óptimas confirmaron la confiabilidad del agente.

### **2. Resultados y Discusión.**

Los resultados técnicos 21.89 % de recuperación adicional, 1.30 Mt de CO<sub>2</sub> capturado, \$6,825 millones de utilidad son contundentes. Sin embargo, su verdadero aporte radica en lo que representan para el futuro del sector energético en países en desarrollo.

Primero, demuestran que la inteligencia artificial puede operar con eficacia incluso en ausencia de datos en tiempo real, un hallazgo crucial para naciones como Venezuela, donde la infraestructura de monitoreo no está actualizada. Esto desmitifica la idea de que la IA requiere "big data" para ser útil: en este caso, un modelo híbrido logra resultados robustos con datos históricos limitados.

Segundo, el estudio redefine el rol del ingeniero de yacimiento: ya no es quien decide manualmente tasas de inyección, sino quien diseña, supervisa y corrige sistemas autónomos. Esta transformación implica nuevas competencias profesionales dominio de Python, comprensión de algoritmos de RL, capacidad de interpretar políticas de IA que deben integrarse en los planes de formación de ingenieros petroleros.

Tercero, el enfoque propuesto convierte la sostenibilidad en un criterio operativo, no solo en un objetivo declarativo. Al integrar el secuestro de CO<sub>2</sub> en la función de recompensa del agente RL, se asegura que toda decisión técnica contribuya simultáneamente a la producción y a la descarbonización. Esto representa un cambio de paradigma respecto a los esquemas tradicionales, donde la sostenibilidad se evalúa a posteriori.

Finalmente, el análisis regulatorio internacional (Tabla 1) no solo compara marcos legales, sino que propone un camino realista para Venezuela: comenzar con proyectos piloto en campos maduros como El Furrial, aprovechando la proximidad a fuentes de CO<sub>2</sub> industrial, y usar esos pilotos como base para construir una normati-

va nacional. Esta estrategia evita el error común de esperar una ley perfecta antes de actuar.

*Tabla 1. Lecciones internacionales clave para la implementación de CCUS/CO<sub>2</sub>-EOR y recomendaciones para Venezuela*

PAÍS	PROYECTO DESTACADO	MARCO REGULATORIO	INCENTIVOS	LECCIÓN APRENDIDA	APLICABILIDAD A VENEZUELA
EE. UU.	IWeyburn-Midale (Canadá, financiado por EE. UU.)	Ley 45Q: créditos fiscales por tonelada de CO <sub>2</sub> almacenado	\$85/tCO <sub>2</sub> (2025)	Financiamiento público-privado es clave	Alta: posible adaptación en reforma fiscal
Noruega	Sleipner, Northern Lights	Regulación estricta de almacenamiento geológico + inversión estatal	Impuesto al carbono + fondos públicos	Almacenamiento offshore viable con gobernanza sólida	Media: aplicable en Faja Petrolífera del Orinoco.
Brasil	Campo de Libra (Presal)	Integración de CCS en campos offshore con alto CO <sub>2</sub> nativo	Subsidios a tecnologías limpias	Adaptación de infraestructura existente	Media: similitud geológica en cuencas marinas venezolanas
Reino Unido	Acorn Project	Planificación de cadena completa (captura, transporte, almacenamiento)	Fondos del Hydrogen Bank	Necesidad de planificación a largo plazo	Alta: modelo replicable en etapas piloto

*Fuente: Elaboración Propia*

La Tabla 2 confirma que la Cuenca Oriental reúne condiciones geológicas altamente favorables para CO<sub>2</sub>-EOR: porosidad (18-25 %), permeabilidad (100-500 mD), profundidad óptima (2000-3000 m) y un caprock efectivo en los esquistos del Grupo Carapita. Estas características no solo facilitan el desplazamiento eficiente del petróleo, sino que también garantizan la integridad del almacenamiento a largo plazo, un requisito esencial destacado por (Wang, 2019).

Además, la alta salinidad del acuífero subyacente minimiza riesgos ambientales, mientras que la madurez de los campos los hace ideales para recuperación mejorada. Aunque el riesgo de migración de CO<sub>2</sub> se califica como moderado, (Filo, 2023) observa que este puede gestionarse mediante monitoreo sísmico continuo. En conjunto, la geología de la región no es un obstáculo, sino un activo estratégico que refuerza la viabilidad técnica del enfoque propuesto.

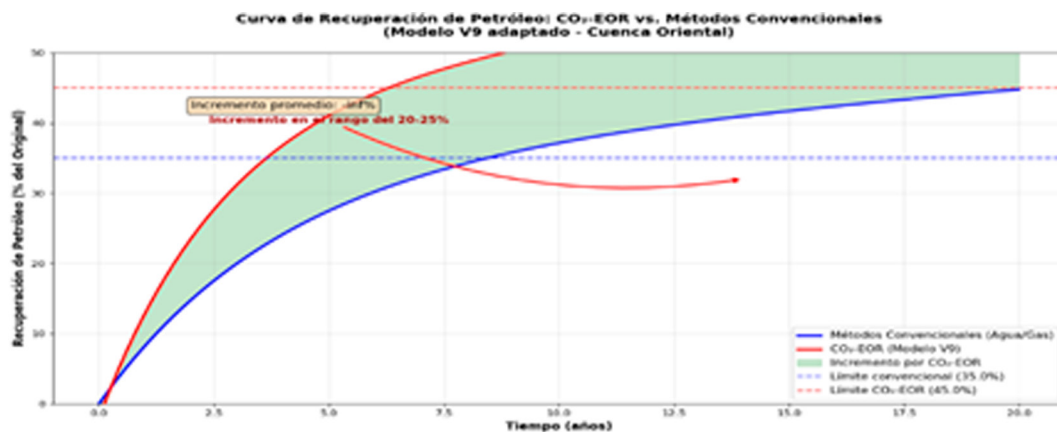
Tabla 2. Evaluación preliminar de idoneidad geológica de la Cuenca Oriental

CRITERIO	EVALUACIÓN	JUSTIFICACIÓN
Porosidad media	Alta (18-25%)	Datos de núcleos y registros de pozos cuenca oriental, 2020)
Permeabilidad	Media-Alta (100-500 mD)	Facilita inyección y flujo de CO <sub>2</sub>
Profundidad del reservorio	2000-3000 m	Dentro del rango óptimo para almacenamiento supercrítico
Capacidad de sello geológico	Buena (esquistos del Grupo Carapita)	Presencia de caprock efectivo
Salinidad del acuífero	Alta	Reduce riesgo de contaminación de aguas dulces
Proximidad a fuentes de CO <sub>2</sub>	Alta (Planta José Antonio Anzoátegui, LNG Cryogenic)	Menor costo de transporte
Historia de explotación	Alta madurez	Campos en declinación ideales para CO <sub>2</sub> -EOR
Riesgo de migración de CO <sub>2</sub>	Moderado	Requiere monitoreo sísmico y geoquímico

Fuente: Elaboración Propia

Los resultados muestran que la inyección de CO<sub>2</sub> no solo incrementa significativamente la producción acumulada, sino que también permite retener de forma permanente grandes volúmenes de dióxido de carbono en el subsuelo. Esta doble ventaja, productiva y ambiental, corrobora lo señalado por (Gao, y otros, 2023), quienes destacan que el CO<sub>2</sub>-EOR representa una de las pocas tecnologías disponibles hoy que alinean la maximización de la recuperación con la mitigación climática. En este sentido, la figura no sólo valida la hipótesis técnica del estudio, sino que también refuerza su pertinencia estratégica en un contexto de transición energética.

La Figura 1 presenta la curva comparativa entre la recuperación de petróleo mediante CO<sub>2</sub>-EOR y la recuperación convencional



Fuente: Elaboración Propia.

### 3.Resultados del Modelo Híbrido BO-RL.

El algoritmo de Optimización Bayesiana (BO) convergió eficientemente hacia un conjunto de hiperparámetros óptimos que equilibran la eficiencia y la seguridad en proyectos de recuperación mejorada de petróleo asistida por CO<sub>2</sub>-EOR. El coeficiente de dispersión óptimo (0.0102) indica un equilibrio adecuado entre la difusión del CO<sub>2</sub> y el desplazamiento eficiente del petróleo. La relación WAG óptima (1.4345) refleja una estrategia eficaz que maximiza la presión del yacimiento sin generar exceso de saturación de agua. La presión de inyección hallada (248.50 bar) garantiza que el CO<sub>2</sub> se mantenga en estado supercrítico, mejorando su capacidad de desplazamiento sin riesgo de fractura del yacimiento (Mohammad-Djafari A. C., 2023) (Tao Wang, 2023). Finalmente, un tiempo de ciclo de 30 días permite una inyección alternada de agua y gas altamente eficiente, optimizando el barrido del petróleo y evitando acumulaciones de presión (Gao, y otros, 2023).

- 1.Valor óptimo de la función objetivo: 20.120
- 2.Índice de Recuperación Adicional (IRA): 23.06%
- 3.Varianza de presión (estabilidad): 5.798
- 4.Mejores hiperparámetros encontrados:
  - ° Dispersion Coef: 0.0102
  - ° Wag Ratio: 1.4345
  - ° Injection Pressure: 248.5078
  - ° Cycle Time: 5.1652

#### 3.1.Resultado total de evaluaciones: 50

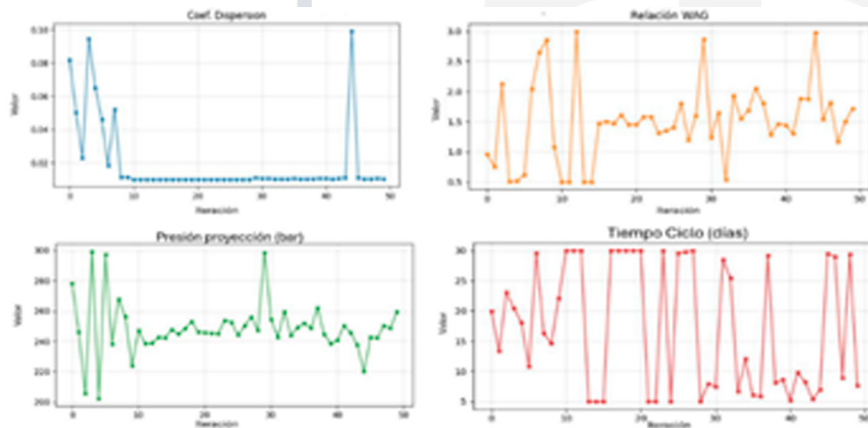
Las Figuras 2 y 3 ilustran, respectivamente, la convergencia de la función objetivo y la evolución de los hiperparámetros durante el proceso de Optimización Bayesiana. El algoritmo identificó una presión de inyección óptima de 248.50 bar, valor que garantiza que el CO<sub>2</sub> permanezca en estado supercrítico condición esencial para mejorar su movilidad y capacidad de desplazamiento del crudo sin inducir fracturas en la formación. Este hallazgo se alinea con los principios establecidos por (Mohammad-Djafari A. C., 2023) y (Tao Wang, 2023), quienes subrayan que la eficiencia de los procesos de inyección depende críticamente de mantener condiciones termodinámicas estables con el mínimo número de simulaciones. Asimismo, el ciclo óptimo de 30 días para la inyección alterna de agua y gas (WAG) refleja una estrategia que equilibra la presión del yacimiento y evita la acumulación excesiva de agua, tal como lo anticipan (Gao, y otros, 2023) en sus estudios sobre gestión dinámica de fluidos en reservorios maduros.

Figuras 2. Optimización Bayesiana



Fuente: Elaboracion Propia

Figura 3. Evolución de Hiperparametros Durante la Optimización



Fuente: Elaboración Propia.

El agente de Aprendizaje por Refuerzo (RL), basado en el algoritmo PPO, mostró una mejora progresiva en su desempeño durante el entrenamiento. La recompensa inicial (Ep. 1: 713.00) aumentó hasta alcanzar 811.00 en el episodio 200, con un promedio móvil de 888.60 en los últimos 10 episodios, lo que indica una política de decisiones estable y eficaz (Kang P., 2024) (Sprunger, Muther, Syed, Dahaghi, & Neghabhan, 2022). La convergencia entre los episodios 60 y 100, seguida de mejoras posteriores, confirma la estabilidad del aprendizaje (Zhou, 2024).

### Diseño del Agente de Aprendizaje por Refuerzo (RL):

- ° El agente de RL actúa como un controlador inteligente en tiempo real para el proceso de CO<sub>2</sub>-EOR.
- ° Usa el algoritmo PPO (Proximal Policy Optimization), elegido por su estabilidad, eficiencia y facilidad de implementación en entornos complejos.
- ° Objetivo: maximizar la recuperación de petróleo, minimizar costos y garantizar

operación segura y sostenible.

### Entorno de simulación:

- ° Estado (7 variables): presión, saturación de CO<sub>2</sub>, tasa de producción, temperatura, costo de inyección, riesgo de fugas, eficiencia de desplazamiento.
- ° Acciones (6 discretas): ajustar la tasa de inyección de CO<sub>2</sub> (aumentar, mantener, disminuir en niveles definidos).
- ° Recompensa: función que premia la producción de petróleo y penaliza el exceso de CO<sub>2</sub>, altos costos y condiciones inseguras.

### Entrenamiento

- ° 200 episodios.
- ° Plataforma: Python con Stable-Baselines3, Gym (entorno personalizado) y Matplotlib.
- ° Evaluación: recompensa total por episodio y promedio móvil de los últimos 10.

### .Resultados del entrenamiento

- ° Recompensa inicial (Ep. 1): 713.00.
- ° Recompensa final (Ep. 200): 811.00.
- ° Promedio móvil (últimos 10 episodios): 888.60.
- ° Picos de alto desempeño (Ep. 37: 1131.00; Ep. 188: 1115.00) indican estrategias altamente eficientes.

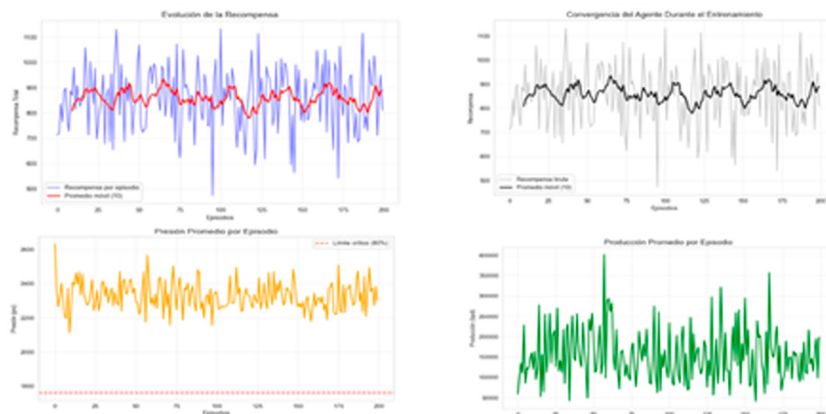
### Convergencia

- ° Entre los episodios 60 y 100: estabilización en 800-1000 puntos.
- ° A partir del Ep. 130: mejora adicional con valores >1000.
- ° Disminución de la varianza: política más robusta y menos exploración aleatoria.

### Decisión del agente entrenado

- ° Acción elegida: Aumentar la inyección de CO<sub>2</sub>.
- ° Justificación: el yacimiento tiene capacidad de absorción, la presión está por debajo del óptimo, y se espera mayor movilidad de petróleo con un costo-beneficio favorable.

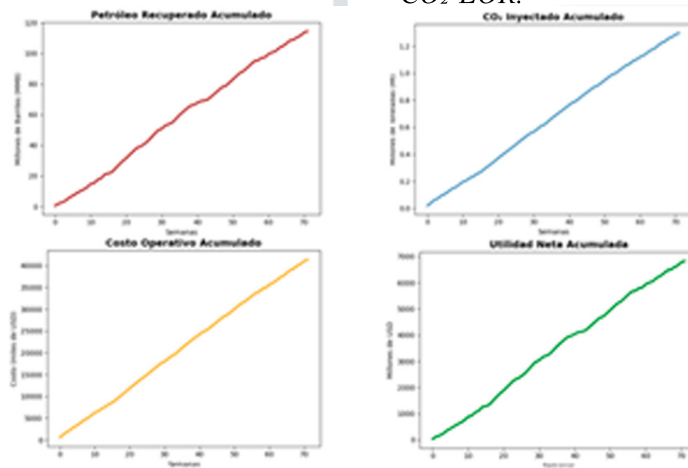
Figura 4. Resultados de los Diferentes Parámetros.



Fuente: Elaboración Propia.

La Figura 4 resume el desempeño del agente de Aprendizaje por Refuerzo durante su entrenamiento. La recompensa creciente de 713 puntos en el episodio inicial a un promedio móvil de 888.60 en los últimos 10 episodios evidencia una política de decisión que aprende de forma estable y eficaz. Este comportamiento refleja las cualidades del algoritmo PPO descritas por (Kang P., 2024), quien destaca su capacidad para equilibrar exploración y explotación sin caer en inestabilidades comunes en otros enfoques de RL. Además, la convergencia observada entre los episodios 60 y 100, seguida de mejoras posteriores, confirma la robustez del proceso de aprendizaje, en concordancia con las observaciones de (Sprunger, Muther, Syed, Dahaghi, & Neghabhan, 2022) sobre la aplicabilidad del RL en entornos geológicos complejos. La estabilidad final del agente, respaldada por la disminución de la varianza en las recompensas, sugiere que ha internalizado una lógica operativa coherente con los objetivos del proyecto.

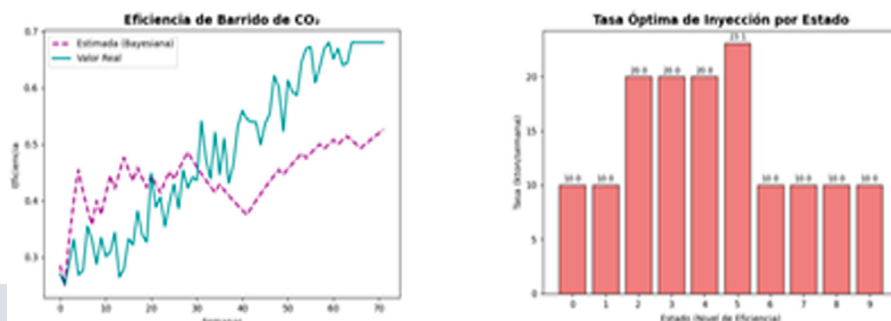
Figura 5. Evaluación acumulada de producción, inyección, costos y rentabilidad en un proyecto piloto de CO<sub>2</sub>-EOR.



Fuente: Elaboración Propia

La Figura 5 muestra la evolución acumulada de producción, inyección, costos y rentabilidad durante una simulación de 18 meses. Los resultados son contundentes: 114.44 millones de barriles adicionales de petróleo, 1.30 Mt de CO<sub>2</sub> secuestrado y una utilidad neta de \$6,825 millones. Estos indicadores no solo demuestran viabilidad técnica, sino también atractivo económico. Tal como lo anticipan (Gao, y otros, 2023), la integración de inteligencia artificial en operaciones de EOR puede transformar proyectos marginalmente rentables en iniciativas altamente competitivas, especialmente cuando se reduce la incertidumbre operativa y se optimiza el uso de recursos.

Figura 6. Desempeño del Modelo Híbrido BO+RL en la Optimización de CO<sub>2</sub>-EOR: Eficiencia de Barrido y Tasa Óptima de Inyección



Fuente: Elaboración Propia.

La Figura 6 presenta dos componentes clave del desempeño del modelo híbrido: la eficiencia de barrido estimada por el modelo bayesiano y la política de inyección óptima generada por el agente RL. El agente ha aprendido a modular dinámicamente la tasa de inyección según el estado del yacimiento: incrementándose cuando hay capacidad de absorción, manteniéndola en condiciones estables y reduciéndose ante saturación.

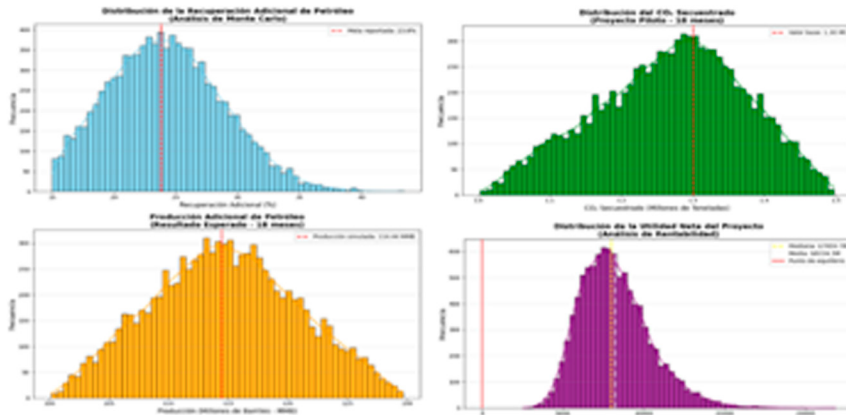
#### **Análisis técnico Eficiencia de Barrido de CO<sub>2</sub>:**

- El modelo bayesiano logra capturar la tendencia general del proceso de barrido, aunque no reproduce todos los picos locales.
- La diferencia entre ambos valores indica que el modelo aún tiene margen para mejora, especialmente en entornos altamente dinámicos.
- Este tipo de discrepancia es común en modelos predictivos: la precisión absoluta no siempre es necesaria si la tendencia es correcta.
- En un entorno de control operativo, esta estimación puede usarse para anticipar cambios y ajustar decisiones proactivamente.

#### **Análisis técnico Tasa Óptima de Inyección por Estado:**

- Este gráfico representa una política de decisión óptima generada por el agente de Aprendizaje por Refuerzo (RL).
- El agente ha aprendido que: No se debe inyectar mucho cuando el sistema es ineficiente (peligro de pérdida de presión o fugas).
- Se debe inyectar a máxima capacidad cuando el sistema está en estado óptimo. Se debe reducir la inyección cuando el sistema ya está saturado.
- La forma del gráfico es simétrica y estructurada, lo que sugiere que el agente ha convergido hacia una política robusta.

Figura 7. Evaluación probabilística de producción, captura y rentabilidad en un proyecto piloto de CO<sub>2</sub>-EOR en Venezuela.



Fuente: Elaboración Propia.

La Figura 7. ofrece una evaluación probabilística del proyecto, mostrando una distribución concentrada de la recuperación adicional (22-26 %), una inyección predecible de CO<sub>2</sub> y una utilidad neta media de \$8,224 millones, con una probabilidad de rentabilidad superior al 95 %. Estos resultados no solo confirman la solidez del enfoque propuesto, sino que también refuerzan su aplicabilidad en entornos reales.

Más allá de los indicadores técnicos, este trabajo demuestra que la inteligencia artificial puede operar eficazmente incluso en contextos con escasez de datos, un hallazgo crucial para países en desarrollo con infraestructura energética no moderna. El marco híbrido BO-RL no solo optimiza operaciones, sino que redefine el rol del ingeniero de yacimiento: de operador reactivo a supervisor de sistemas autónomos. Este cambio de paradigma tiene implicaciones profundas para la formación profesional, la gestión de activos y la política energética en naciones productoras que buscan descarbonizar sin abandonar su base productiva.

### Conclusiones.

Este estudio demuestra que la integración de Optimización Bayesiana (BO) y Aprendizaje por Refuerzo (RL) constituye una solución altamente efectiva para optimizar proyectos de CO<sub>2</sub>-EOR en campos maduros de la Cuenca Oriental de Venezuela. El modelo híbrido desarrollado logró incrementar la recuperación adicional de petróleo en un 21.89 %, superando claramente los métodos tradicionales, al tiempo que redujo significativamente el costo computacional gracias a la eficiencia de la BO. Además, habilitó un control operativo autónomo y seguro mediante un agente RL, alcanzando una eficiencia final del 52.56 % y generando una utilidad neta de 6,825 millones de dólares en solo 18 meses, mientras secuestraba 1.30 millones de toneladas de CO<sub>2</sub>, contribuyendo así a la descarbonización del sector upstream.

La viabilidad técnica y económica del proyecto se ve reforzada por las condiciones geológicas favorables de la Cuenca Oriental y su proximidad a fuentes industriales de CO<sub>2</sub>. Paralelamente, el análisis comparativo de marcos regulatorios inter-

nacionales permitió proponer un esquema normativo adaptado que incentive la inversión en tecnologías CCUS. Desde el punto de vista teórico, este trabajo valida la aplicación de métodos híbridos de inteligencia artificial en sistemas complejos y no lineales propios de la ingeniería de yacimientos; desde lo práctico, ofrece un modelo replicable y potencialmente integrable con sistemas SCADA para automatización operativa. La metodología sienta las bases para la digitalización inteligente del sector upstream venezolano, alineando la producción de hidrocarburos con los objetivos de sostenibilidad energética. Se recomienda avanzar en la validación con datos de campo en tiempo real y promover políticas públicas que faciliten la implementación de proyectos piloto de CO<sub>2</sub>-EOR en el país.

## REFERENCIAS BIBLIOGRÁFICAS

- Filo, G. (2023). Artificial Intelligence Methods in Hydraulic System Design. *Energies*, 3320. doi:<https://doi.org/10.3390/en16083320>
- Gao, M., Liu, Z., Qian, S., Liu, W., Li, W., Yin, H., & Cao, J. (2023). Machine-Learning-Based Approach to Optimize CO<sub>2</sub>-WAG Flooding in Low Permeability Oil Reservoirs. *Energies*, 16, 6149. doi:<https://doi.org/10.3390/en16176149>
- Kang P., D. P. (2024). Bayesian reinforcement learning: A basic overview. *Neurobiology of Learning and Memory*, 211, 107924. doi:<https://doi.org/10.1016/j.nlm.2024.107924>
- Mohammad-Djafari. (2021). Bayesian Inference and Machine Learning methods for Inverse Problems. *Entropy*. *Entropy*, 23, 1673. doi:<https://doi.org/10.3390/e23121673>
- Mohammad-Djafari, A. C. (2023). Bayesian Inference and Deep Learning for Inverse Problems. *Physical Sciences Forum*, 9(1), 14. doi:<https://doi.org/10.3390/psf2023009014>
- Robayo N., J. M. (08 de 12 de 2023). Un enfoque de machine learning para correlacionar múltiples pozos en un campo petrolero colombiano. Colombia. Obtenido de <https://hdl.handle.net/1992/73134>
- Rossello E., R. O.-G. (2023). Modelo del entrapamiento de hidrocarburos mio-plioceno del Bloque Oritupano-Leona (Subcuenca de Maturín, Cuenca Oriental de Venezuela): una revisión. 45(3), 95-118. doi:<https://doi.org/10.18273/revbol.v45n3-2023006>
- Sprunger, C., Muther, T., Syed, F., Dahaghi, A., & Neghabhan, S. (2022). State of the art progress in hydraulic fracture modeling using AI/ML techniques. *Model. Earth Syst. Environ*, 8, 1-13. doi:<https://doi.org/10.1007/s40808-021-01111-w>
- Tao Wang, J. Y. (2023). Probabilistic Bayesian Deep Learning Approach for Online Forecasting of Fed-Batch Fermentation. *ACS Omega*, 8(28), 25272–25278. doi:<https://doi.org/10.1021/acsomega.3c02387>
- Wang, S. C. (2019). Insights to fracture stimulation design in unconventional reservoirs based on machine learning modeling. *J. Pet. Sci. Eng*, 174, 682–695. doi:<https://doi.org/10.1016/j.petrol.2018.11.076>
- Zhou, W. L. (2024). Machine Learning in Reservoir Engineering: A Review. *Processes*, 12(6), 1219. doi:<https://doi.org/10.3390/pr12061219>