



PETROLIA

REVISTA ARBITRADA DE LA UNIVERSIDAD VENEZOLANA DE LOS HIDROCARBUROS

2026

Año 1 N° 1



**HACIA UNA INDUSTRIA DE LOS HIDROCARBUROS INTELIGENTE Y SOBERANA:
AUTOMATIZACIÓN, INTELIGENCIA ARTIFICIAL Y TRANSICIÓN TECNOLÓGICA
EN VENEZUELA**



DETERMINISMO ESTOCÁSTICO Y ENTROPÍA EN SISTEMAS DE HIDROCARBUROS



**ANÁLISIS DE INTELIGENCIA ARTIFICIAL PARA OPTIMIZAR TIEMPOS
OPERATIVOS EN PERFORACIÓN COSTA AFUERA**



**SISTEMA AUTÓNOMO INTELIGENTE PARA LA OPTIMIZACIÓN ENERGÉTICA Y
REDUCCIÓN DE LA HUELLA DE CARBONO EN PROCESOS ELÉCTRICOS**



La Universidad Venezolana de los Hidrocarburos (UVH) presenta el primer número de la revista científica *Petrolia*, un hito para la soberanía tecnológica y la transición hacia una industria basada en el conocimiento, destacando en el contexto actual la recuperación estratégica de la industria nacional de hidrocarburos, que, pese a las sanciones y el bloqueo técnico, ha logrado recuperar y superar su producción alcanzando en el año 2024 un promedio anual por encima del millón de barriles diarios de crudo gracias a la ingeniería local y la innovación adaptativa. Las políticas del Estado venezolano en el control, resguardo y utilización de nuestros datos soberanos, y el desarrollo de modelos propios de nuestras áreas de Exploración y Producción, se fortalecen con la creación de un Viceministerio de Inteligencia Artificial y Eficiencia Productiva.

Ante un contexto energético global marcado por récords de consumo y la necesidad de descarbonización, *Petrolia* nace como un espacio de debate científico para desarrollar soluciones propias, eficientes y sostenibles, rompiendo con la dependencia de tecnologías extranjeras. Para los profesionales de la ciencia y la ingeniería, este escenario plantea un desafío que va más allá de la simple actualización de conocimientos. Exige una transformación profunda en la forma en que concebimos el diseño, la optimización y

la ética aplicada. La obsolescencia técnica ya no se mide en décadas, sino en meses. Por ello, la verdadera ventaja competitiva no radica en el dominio de una herramienta específica, sino en la capacidad arquitectónica de integrar tecnologías heterogéneas para resolver problemas complejos y reales.

En este primer número, las investigaciones presentadas reflejan la vanguardia de este esfuerzo. Como muestra de esta vanguardia, esta edición destaca el **Sistema SAIPE**, una arquitectura automática basada en el modelo MAPE-K que utiliza Machine Learning con una precisión predictiva excepcional para optimizar el consumo eléctrico y reducir hasta en un 40,04% la huella de carbono industrial, alineándose con el ODS 7. En el mismo contexto, se presenta un análisis exhaustivo del impacto de la Inteligencia Artificial en los procesos de perforación costa afuera, donde la integración de sistemas expertos y Gemelos Digitales permite una reducción importante en los Tiempos No Productivos (TNP) y los riesgos inherentes a la perforación costa afuera. Así mismo, en este primer volumen de la Revista *Petrolia*, se profundiza en la ciencia fundamental con un estudio sobre el Determinístico Estocástico y la Entropía en Sistemas de Hidrocarburos, proponiendo modelos predictivos del comportamiento de fases en condiciones críticas en la reinterpretación de la incertidumbre como “ignorancia estructurada”.

Los invitamos a sumergirse en las páginas de este número, no solo como observadores del avance tecnológico, sino como los arquitectos activos del futuro que estamos construyendo.

MSc. Celia Bejarano

Rectora de la Universidad
Venezolana de los Hidrocarburos

Junio 2026



Centro de procesamiento de fluidos (CPF) de un campo de gas que acondiciona el gas natural bruto estabilizando los flujos de líquidos y separando el gas, el agua y los condensados. La corriente gaseosa se purifica para eliminar gases ácidos y se deshidrata para evitar la formación de hidratos. Posteriormente, el gas seco se procesa para recuperar y fraccionar los líquidos del gas natural (etano, GLP y gasolina), mientras el metano residual se comprime hacia los gasoductos comerciales. Los condensados se estabilizan térmicamente para su almacenamiento seguro, y el agua residual se trata para su disposición final. Foto: CPF Campos Yucal Placer Norte y Sur, Edo. Guárico. Operadora: YPergas, S. A.

CRÉDITOS



Fundada en 2025

Año 01

Edición Aniversario
Caracas – Venezuela

Depósito legal
MI2025000641

Revista Arbitrada de la Universidad Venezolana de los Hidrocarburos

DIRECTORIO

Rectora

Celia Agustina Bejarano González

Vicerrectora Administrativa

Omaira Valentina Alzuarde D'Angelo

Secretaria General

Dilia Rosa Perez de Obregón

**Director de Investigación, Innovación
y Producción Editorial**

Ricardo Andrés León Sabala

**Director de Comunicaciones y
Proyección Universitaria**

Oscar Soteldo

Comité editorial

Ricardo León

Oscar Soteldo

Albania Villarroel

Daniel Páez

Juan Carlos Báez

Alfredo Naime

Eric Omaña

Fabiola Pineda

Diagramación

Kelly Cepeda

3

• EDITORIAL

5

• HACIA UNA INDUSTRIA DE LOS HIDROCARBUROS INTELIGENTE Y SOBERANA:
AUTOMATIZACIÓN, INTELIGENCIA ARTIFICIAL Y TRANSICIÓN TECNOLÓGICA EN VENEZUELA

15

• DETERMINISMO ESTOCÁSTICO Y ENTROPÍA EN SISTEMAS DE HIDROCARBUROS

22

• ANÁLISIS DE INTELIGENCIA ARTIFICIAL PARA OPTIMIZAR TIEMPOS OPERATIVOS EN
PERFORACIÓN COSTA AFUERA

34

• SISTEMA AUTÓNOMO INTELIGENTE PARA LA OPTIMIZACIÓN ENERGÉTICA Y REDUCCIÓN
DE LA HUELLA DE CARBONO EN PROCESOS ELÉCTRICOS

HACIA UNA INDUSTRIA DE LOS HIDROCARBUROS INTELIGENTE Y SOBERANA: AUTOMATIZACIÓN, INTELIGENCIA ARTIFICIAL Y TRANSICIÓN TECNOLÓGICA EN VENEZUELA

**Toward a smart and sovereign hydrocarbons
industry: automation, artificial intelligence, and
technological transition in Venezuela**

Arturo Gil Pinto, Universidad Central de Venezuela
(UCV), Caracas-Venezuela.

RESUMEN

Este artículo analiza las implicaciones estratégicas de incorporar la automatización y la inteligencia artificial (IA) en la industria de petróleo y gas venezolana, en un contexto de sanciones internacionales, bloqueo tecnológico y transformación estructural del modelo energético. Se abordan los antecedentes históricos de la automatización como herramienta de poder, los riesgos de la dependencia tecnológica, el potencial de la IA para la generación de capacidades nacionales y el papel del Estado en una transición justa y soberana. Finalmente, se proponen aplicaciones concretas de IA en el sector hidrocarburos y un conjunto de recomendaciones estratégicas.

Palabras clave: inteligencia artificial; eficiencia productiva; soberanía tecnológica.

ABSTRACT

This article analyzes the strategic implications of incorporating automation and Artificial Intelligence (AI) into the Venezuelan oil and gas industry, within a context of international sanctions, technological blockades, and the structural transformation of the energy model. It examines the historical background of automation as a tool of power, the risks associated with technological dependency, the potential of AI for building national capacities, and the role of the State in ensuring a just and sovereign transition. Finally, the paper proposes concrete applications of AI within the hydrocarbons sector and offers a set of strategic recommendations.

Keywords: artificial intelligence; productive efficiency; technological sovereignty.

INTRODUCCIÓN

La industria petrolera venezolana, columna vertebral de nuestra economía y expresión concreta de nuestra soberanía energética, ha enfrentado en los últimos años uno de los desafíos más complejos de su historia republicana: un régimen de medidas coercitivas unilaterales impuesto principalmente por el Gobierno de los Estados Unidos (Kirkham, 2023), que ha buscado asfixiar las capacidades operativas, financieras y tecnológicas de la Nación. Estas acciones han intentado bloquear el acceso de Venezuela a mercados internacionales, proveedores especializados y servicios técnicos esenciales, con el objetivo político de someter al país por la vía económica.

Sin embargo, lejos de doblegarse, el Estado venezolano, bajo el liderazgo del presidente Nicolás Maduro, ha desarrollado una estrategia integral de recuperación, basada en el aprovechamiento de capacidades nacionales, el fortalecimiento de alianzas estratégicas y el rediseño de procesos productivos (Misión Verdad, 2025). Gracias a estos esfuerzos, se ha logrado una recuperación progresiva de la producción petrolera, que en 2024 superó el umbral del millón de barriles diarios (OPEP, 2025), marcando un hito de resistencia técnica y organizativa. Este repunte no ha sido producto de concesiones ni de modelos de dependencia, sino del impulso decidido de un modelo soberano de gestión energética, que prioriza el talento nacional, la innovación adaptativa y el interés colectivo de nuestro pueblo.

En este contexto de recuperación soberana, se hace evidente una verdad estratégica: la industria petrolera venezolana no solo debe resistir las presiones externas, sino transformarse estructuralmente. Ya no basta con producir más barriles, sino producir con inteligencia, eficiencia y visión de futuro. La transición hacia una industria basada en el conocimiento se convierte en una necesidad histórica impostergable. La automatización de procesos, la gestión inteligente de datos y la incorporación progresiva de la inteligencia artificial no son lujos tecnológicos ni tendencias pasajeras, sino requisitos esenciales para garantizar la supervivencia operativa, la competitividad internacional y la sostenibilidad energética del



país. Esta transformación exige no solo inversión y tecnología, sino también una profunda revolución cultural y organizativa que sitúe el conocimiento, la innovación y la soberanía tecnológica como pilares del nuevo modelo energético nacional.

HISTORIA Y MOTIVACIONES DE LA AUTOMATIZACIÓN/IA

Origen y motivación estratégica

El auge de la automatización y la inteligencia artificial a escala global responde a una convergencia de intereses económicos, estratégicos y políticos. Por un lado, estas tecnologías se han consolidado como herramientas indispensables para alcanzar mayores niveles de eficiencia, reducir costos, anticipar fallas y optimizar la toma de decisiones en industrias complejas como la energética, la logística, la manufactura o las finanzas. Pero su desarrollo también ha sido impulsado por necesidades de control: en el ámbito gerencial, para supervisar en tiempo real el rendimiento y la productividad; en el plano militar, para dotar a los Estados de capacidades avanzadas de defensa, vigilancia y guerra cognitiva; y en la esfera social, para regular el comportamiento de las poblaciones a través de sistemas de vigilancia masiva, algoritmos de perfilamiento y dispositivos de gobernanza algorítmica. La inteligencia artificial no es, por tanto, una herramienta neutral: es una expresión tecnológica de correlaciones de poder, cuya apropiación soberana resulta fundamental para países como Venezuela que aspiran a transformar su modelo productivo sin renunciar a su autodeterminación.

Desde sus orígenes en la revolución industrial, la automatización ha sido mucho más que una simple mejora técnica: ha constituido una herramienta estratégica de poder, utilizada por los Estados para reorganizar el trabajo, ampliar su base productiva y fortalecer su capacidad de gestión sobre el territorio y los recursos (Noble, 2017). En cada ciclo histórico, los avances en automatización han estado ligados a proyectos nacionales: desde las líneas de ensamblaje fordistas que consolidaron el dominio industrial de Estados Unidos, hasta los sistemas cibernéticos de

planificación desarrollados por países socialistas o los complejos automatizados de exploración y defensa impulsados por potencias militares. La automatización ha servido tanto para multiplicar la eficiencia como para centralizar el mando, ordenar el territorio, anticipar contingencias y ejercer soberanía. En ese sentido, no es una técnica neutral ni despolitizada: es parte del modo en que una nación se piensa a sí misma, organiza sus medios de producción y asegura su capacidad de responder a desafíos internos y externos. Para Venezuela, asumir esta dimensión histórica de la automatización es clave para diseñar un modelo energético del siglo XXI que sea verdaderamente soberano, eficiente y orientado al bien común.

Evolución y cuantificación del trabajo

La inteligencia artificial contemporánea no surge en el vacío: es el resultado de un largo proceso histórico de racionalización del trabajo, que encuentra en el taylorismo y la automatización industrial sus precursores lógicos. El taylorismo (Littler, 1978), al fragmentar las tareas y cronometrar los movimientos del obrero, no solo buscaba aumentar la eficiencia, sino capturar, estandarizar y codificar el saber práctico disperso entre los trabajadores. Esta primera etapa de descomposición del conocimiento humano en unidades medibles sentó las bases para su posterior mecanización a través de sistemas automatizados. La automatización, a su vez, profundizó esta lógica al traducir funciones antes realizadas por personas en secuencias controladas por máquinas programables. La inteligencia artificial lleva este proceso a un nuevo nivel: ya no se limita a replicar acciones, sino que busca modelar procesos cognitivos —percepción, decisión, aprendizaje— a partir de la acumulación, análisis y formalización de datos masivos. Lo que antes se medía con cronómetros, hoy se mide con sensores inteligentes; lo que antes se anotaba en fichas, ahora se alimenta a modelos algorítmicos entrenados para predecir, recomendar o incluso sustituir. En esa continuidad, la IA puede entenderse como la más reciente forma de captura del conocimiento colectivo e individual, cuya apropiación soberana por parte de los pueblos es un desafío político, no solo técnico.

MODELOS EN CONTRASTE: DEPENDENCIA TECNOLÓGICA VS. SOBERANÍA E IA

Riesgos del modelo de dependencia tecnológica

La dependencia tecnológica, expresada en la importación constante de equipos, software, servicios especializados y soluciones “llave en mano”, ha sido históricamente una fuente de vulnerabilidad para los países del Sur Global (Stepnov, 2024). En lugar de fortalecer capacidades nacionales, esta lógica reproduce una relación de subordinación estructural: cada nueva tecnología adquirida en el exterior implica no solo una transferencia continua de recursos financieros, sino también una transferencia oculta de poder y control. Al no disponer del conocimiento sobre el diseño, la arquitectura ni el funcionamiento interno de los sistemas utilizados, se limita la posibilidad de adaptarlos a las condiciones locales, de repararlos de forma autónoma, o de innovar sobre su base. Esta situación genera una fragilidad estratégica: cualquier ruptura en el suministro externo —ya sea por razones comerciales, geopolíticas o coercitivas, como las sanciones— puede paralizar sectores enteros de la economía o de los servicios públicos.

Además, el uso acrítico de tecnología importada tiende a desalentar la investigación nacional, desvaloriza el conocimiento local y sitúa a las universidades e institutos científicos en un rol marginal, muchas veces reducido a la mera operación o mantenimiento. En lugar de dinamizar el ecosistema de innovación, lo aplasta bajo la lógica de la dependencia. Superar esta trampa exige más que discursos: requiere una política activa de desarrollo tecnológico soberano, donde el Estado asuma el rol de promotor, articulador y protector de las capacidades científico-tecnológicas propias. Solo así es posible construir una plataforma industrial y energética capaz de resistir presiones externas y responder creativamente a las necesidades del país.

Riesgos políticos

Pérdida de soberanía en la toma de decisiones estratégicas: El control de tecnologías críticas por actores extranjeros limita la autonomía del Estado para definir políticas energéticas, militares o sociales sin condicionamientos externos.

Vulnerabilidad ante sanciones y coerción extraterritorial: Países proveedores pueden retirar licencias, bloquear acceso a plataformas digitales o restringir repuestos y servicios como mecanismo de presión política o ideológica.

Riesgo de espionaje e infiltración de intereses foráneos: Equipos o software de origen extranjero pueden contener puertas traseras, transmitir datos sensibles o facilitar el seguimiento de decisiones estratégicas.

Condicionamiento de alianzas internacionales: La dependencia tecnológica condiciona la política exterior, limitando la capacidad de Venezuela de diversificar relaciones geopolíticas sin enfrentar represalias comerciales o tecnológicas.

Riesgos operativos

Interrupción de operaciones críticas por bloqueo de servicios: Tecnologías dependientes de la nube, licencias extranjeras o actualizaciones remotas pueden ser suspendidas, paralizando refinerías, sistemas SCADA o plataformas logísticas.

Falta de mantenimiento y soporte técnico oportuno: Ante restricciones a proveedores, los equipos importados pueden quedar inoperativos por falta de repuestos o técnicos certificados.

Desactualización tecnológica programada: Los ciclos de obsolescencia planificados por las grandes corporaciones fuerzan la renovación periódica a alto costo, sin posibilidad de extender la vida útil por medios propios.

Dificultad para integrar tecnologías heterogéneas: Sistemas importados de distintos orígenes muchas veces no son compatibles entre sí ni con soluciones nacionales, generando entornos fragmentados y difíciles de gestionar.

Imposibilidad de personalizar o adaptar soluciones a las condiciones locales: Tecnologías diseñadas para entornos diferentes (clima, idioma, cultura operativa) no responden adecuadamente a las realidades venezolanas, reduciendo eficiencia y confiabilidad.

Oportunidades de la IA para la autonomía y la resiliencia

La inteligencia artificial, lejos de ser solo una herramienta de automatización avanzada, representa una oportunidad estratégica para países como Venezuela de dar un salto cualitativo hacia la autonomía tecnológica. Al desarrollar modelos de IA entrenados con datos propios y diseñados en función de las necesidades específicas del país —ya sea en el sector energético, agrícola, logístico, educativo o sanitario— se rompe con la lógica de dependencia que impone la importación de tecnologías genéricas, costosas y muchas veces inaplicables al contexto local.

En el sector hidrocarburos, por ejemplo, la IA puede ser utilizada para optimizar procesos de exploración y producción (Koroteev y Tekic, 2021), anticipar fallas en equipos mediante mantenimiento predictivo, mejorar la eficiencia en refinerías y sistemas de transporte, e incluso garantizar una mejor trazabilidad y transparencia en la cadena de valor. Estas aplicaciones no solo permiten elevar la productividad con menos recursos, sino que reducen significativamente las vulnerabilidades operativas asociadas al bloqueo de software extranjero, a la falta de conectividad con servicios externos o a la obsolescencia programada.

Además, el impulso de la IA genera un efecto multiplicador en el ecosistema nacional de innovación: moviliza universidades, centros de investigación, empresas emergentes y talentos jóvenes en torno a

desafíos concretos, abriendo espacio a una nueva economía del conocimiento. Esta transformación debe ser guiada por principios de soberanía, justicia social y sostenibilidad, asegurando que la IA no sustituya indiscriminadamente al trabajo humano, sino que lo potencie en función del bienestar colectivo.

La transición hacia una industria basada en la inteligencia artificial y la automatización, lejos de destruir empleo, abre la posibilidad real de generar nuevos sectores de trabajo altamente calificado y socialmente útil (Saini, Habil, y Srivastav, 2023). El desarrollo de soluciones propias exige la formación y movilización de equipos interdisciplinarios que incluyan ingenieros, programadores, geoscientíficos, operadores de planta, técnicos de campo, docentes e investigadores, articulando capacidades locales en torno a retos productivos concretos. Esta dinámica fortalece el tejido científico y tecnológico del país, reactiva instituciones educativas y centros de investigación, y convierte la industria en un espacio activo de generación y apropiación de conocimiento. Además, al producir algoritmos, sistemas y plataformas adaptadas a las necesidades nacionales, se crea valor endógeno que no solo ahorra divisas y reduce dependencia externa, sino que puede convertirse en un activo estratégico exportable a otras naciones con condiciones similares. En lugar de importar soluciones cerradas, Venezuela puede convertirse en generadora de tecnología contextualizada, alineada con su realidad operativa y orientada al bien común.

■ **Tabla 1.** Brechas de superación de la dependencia.

ASPECTOS DE DEPENDENCIA	DIRECCIÓN SOBERANA
• Modelo de dependencia tecnológica	• Modelo de IA autónoma y soberana
• Importación de tecnología externa	• Desarrollo local y adaptación de IA
• Vulnerabilidad bajo sanciones	• Resiliencia y control tecnológico
• Transferencia de recursos y know-how afuera	• Retención de talento e inversión interna
• Limitada capacidad de innovación	• Capacidad de innovación propia y adaptable
• Sujeción a intereses foráneos	• Priorización de necesidades nacionales

IA COMO PALANCA PARA EL APRENDIZAJE Y EL CONOCIMIENTO SOBERANO

Aprendizaje profundo y personalizado

La inteligencia artificial, aplicada con una visión soberana e inclusiva, ofrece a la industria de hidrocarburos la posibilidad de construir una verdadera sociedad del conocimiento, donde la formación y el desarrollo de competencias técnicas ya no dependan exclusivamente de estructuras presenciales tradicionales ni de expertos escasos o costosos. Gracias a la IA, es posible diseñar sistemas de tutoría instantánea, simuladores inteligentes y asistentes virtuales especializados que permiten a operarios, técnicos e ingenieros aprender en el momento mismo en que enfrentan un desafío en campo, planta o consola.

Exploración y producción, la IA puede proporcionar recomendaciones en tiempo real sobre estrategias de perforación óptimas (Bello et al., 2015), interpretar imágenes sísmicas (Ping et al., 2020) complejas y guiar a los operadores en la toma de decisiones en pozos horizontales (Rajakannu et al., 2024) o de alta presión. Un asistente virtual, por ejemplo, puede tutorizar a un nuevo geólogo en la lectura de registros de pozo, sugiriendo correlaciones o anomalías con base en datos históricos de la cuenca.

Transporte y almacenamiento, los sistemas inteligentes pueden capacitar al personal en la operación de ductos supervisados remotamente (Rajakannu et al., 2024), ofreciendo respuestas inmediatas ante variaciones de presión, alertas de corrosión interna o posibles fugas, al tiempo que documentan los procesos y retroalimentan la experiencia adquirida para futuras formaciones.

Refinación y petroquímica, la IA puede guiar al operador de sala de control en la interpretación de variables críticas, simulando escenarios de paro seguro, optimización de mezclas o control de emisiones. Plataformas adaptativas pueden enseñar progresivamente al personal cómo identificar desviaciones, ejecutar maniobras complejas y mantener parámetros dentro del rango óptimo, acelerando el dominio técnico sin poner en riesgo la operación real.

Así, la inteligencia artificial no solo mejora la productividad de la industria, sino que se convierte en una plataforma de aprendizaje continuo, personalizada y democratizada, capaz de formar —en tiempo real y a gran escala— a las nuevas generaciones de trabajadores técnicos e ingenieros, fundamentales para el desarrollo soberano y sustentable de Venezuela.

SOBERANÍA DEL CONOCIMIENTO Y DESARROLLO DE TALENTO

Uno de los factores más determinantes para el desarrollo soberano de la inteligencia artificial en la industria de hidrocarburos es el control sobre los datos: qué datos se recolectan, dónde se almacenan, cómo se procesan y con qué fines se utilizan. En un sector estratégico como el energético, los datos —ya sean sísmicos, operacionales, logísticos, de producción o mantenimiento— constituyen un activo nacional, comparable en valor al propio recurso natural. Permitir que estos datos sean procesados por plataformas extranjeras o integrados en modelos desarrollados fuera del país implica una cesión de soberanía crítica, que puede traducirse en dependencia tecnológica, pérdida de ventaja operativa, e incluso exposición a riesgos de inteligencia y sabotaje económico.

Por ello, Venezuela debe avanzar decididamente en la construcción de sistemas de IA entrenados con sus propios datos, en entornos seguros y controlados, con arquitecturas abiertas que respondan a sus prioridades productivas, ambientales y sociales. Una IA entrenada con los datos de nuestros yacimientos, nuestros procesos de refinación y nuestras condiciones logísticas puede ofrecer recomendaciones más precisas, adaptadas a las realidades geológicas, climáticas, económicas y humanas del país. Esta alineación garantiza no solo mayor eficiencia, sino también pertinencia tecnológica: no es lo mismo optimizar una planta diseñada para Texas que una refinería en el oriente venezolano con décadas de operación y limitaciones de insumos.

Además, el control sobre los modelos algorítmicos permite definir objetivos nacionales —por ejemplo, maximizar la recuperación de crudo pesado, reducir

emisiones fugitivas, o priorizar la seguridad del trabajador— en lugar de depender de modelos importados optimizados para otros contextos o intereses corporativos.

En este sentido, el desarrollo de IA con datos propios no es un simple requisito técnico, sino una decisión estratégica para proteger nuestra información, reforzar nuestra autonomía tecnológica y avanzar hacia una industria de hidrocarburos más eficiente, resiliente y comprometida con los objetivos del país. Se trata, en última instancia, de que la inteligencia artificial no sea una nueva forma de dependencia, sino una herramienta para la independencia.

En una sociedad del conocimiento el papel del Estado es aún más importante que en las economías industriales tradicionales: no solo como regulador, sino como impulsor directo del aprendizaje colectivo, la difusión del saber y la garantía de que los beneficios del conocimiento se distribuyan equitativamente (Stiglitz y Greenwald, 2014). Esta afirmación cobra especial vigencia en el caso venezolano, donde la transformación profunda del sector hidrocarburos exige una transición hacia un modelo basado en la inteligencia productiva, la sostenibilidad y la soberanía tecnológica.

En consonancia con esta visión, el Ministerio del Poder Popular de Hidrocarburos ha creado, en enero de 2025, Viceministerio de Inteligencia Artificial y Eficiencia Productiva en Hidrocarburos, una estructura inédita en la región, de acuerdo al decreto N° 5.073 de la Gaceta Oficial N° 6.875. Este Viceministerio se organiza en torno a cuatro Direcciones Generales: Políticas de Formación de Talento Humano, Políticas de Investigación e Innovación Tecnológica, Eficiencia Productiva y Sostenibilidad Ambiental, abarcando así las dimensiones clave de una estrategia nacional de transformación digital e industrial con vocación soberana.

Desde esta nueva institucionalidad, el Estado venezolano asume el liderazgo en la promoción de centros de datos propios, que resguarden el patrimonio informativo de la industria frente a amenazas externas y permitan entrenar modelos de inteligencia artificial con datos locales y bajo control nacional. Asimismo, se prioriza la formación de talento humano. La

especializado, con énfasis en habilidades para la programación, la automatización, el análisis de datos, la ciberseguridad y la gestión inteligente de procesos industriales. Esta formación no solo se orienta a la élite técnica, sino también a operarios, jóvenes técnicos y comunidades productivas, democratizando el acceso al conocimiento estratégico.

Igualmente, el Viceministerio impulsa la elaboración de políticas nacionales de ética, protección de datos y gobernanza algorítmica, necesarias para que el desarrollo tecnológico no vulnere derechos ni reproduzca asimetrías sociales, sino que contribuya a la justicia energética, la transparencia institucional y la sostenibilidad ambiental.

Se trata de construir, desde el Estado y con el Estado, una industria de hidrocarburos que no dependa de modelos importados, sino que se nutra de su propio conocimiento, su propio talento y horizonte estratégico. Una industria donde la inteligencia artificial no sustituya, sino potencie al ser humano; y donde el petróleo, en lugar de ser un factor de dependencia, sea la palanca para una nueva independencia productiva y cognitiva.

IMPACTOS LABORALES Y SOCIALES: RETOS Y OPORTUNIDADES

Desplazamiento y formación para la reconversión laboral

A lo largo de la historia, cada gran ola de transformación tecnológica ha estado acompañada de tensiones laborales profundas. La introducción de la mecanización, la automatización industrial y más recientemente la digitalización han generado fenómenos recurrentes de descalificación de saberes tradicionales, desplazamiento laboral y conflictos sindicales ante la amenaza real o percibida de sustitución de trabajadores (Szaniawski, 1982).

En muchas ocasiones, estas innovaciones se introdujeron desde una lógica vertical, sin consulta ni participación de los colectivos laborales, lo que agudizó resistencias legítimas y provocó rupturas en la cohesión organizacional.

La inteligencia artificial, si es desplegada sin una estrategia humanista, corre el riesgo de reproducir esta historia: de sustituir personas por algoritmos, de reducir el trabajo a tareas meramente operativas y de excluir a quienes no posean competencias digitales avanzadas. En una industria como la de hidrocarburos, con fuerte presencia de trabajadores con alta experiencia empírica, saber técnico acumulado y organización sindical histórica, imponer la IA sin diálogo puede generar tensiones innecesarias y erosionar la base humana de la producción.

Por eso, desde una perspectiva soberana y justa, el despliegue de la inteligencia artificial en Venezuela debe construirse con los trabajadores, no contra ellos. Es indispensable establecer mecanismos claros de formación continua, reconversión profesional y reconocimiento del conocimiento práctico existente, integrándolo en los modelos inteligentes que se desarrollen. Al mismo tiempo, se requiere garantizar derechos laborales plenos, incluyendo la estabilidad, la no discriminación por nivel digital, y la protección frente a decisiones algorítmicas que afecten condiciones de trabajo o remuneración.

Asimismo, es clave promover formas de gobernanza tecnológica participativa, donde los trabajadores —y sus organizaciones— tengan voz en las decisiones sobre qué sistemas se implementan, con qué objetivos y bajo qué criterios éticos y operativos. Esto no solo fortalece la legitimidad de la transformación, sino que enriquece los sistemas de IA con el saber situado de quienes conocen la industria desde dentro.

HACIA LA INDUSTRIA DEL APRENDIZAJE: EL NUEVO HORIZONTE

Durante décadas, la narrativa dominante en torno al desarrollo industrial ha estado marcada por un enfoque estrecho de “eficiencia estática”: maximizar la productividad inmediata, reducir costos y liberalizar el acceso a tecnologías foráneas como vía rápida hacia la modernización. Sin embargo, este enfoque, centrado en indicadores de corto plazo y en la lógica del mercado global, ha limitado estructuralmente el aprendizaje organizacional, la conocimiento, frenando

acumulación de capacidades tecnológicas propias y el progreso autónomo de muchos países del Sur. La supuesta neutralidad de la eficiencia ha servido, en muchos casos, para justificar la dependencia, la desindustrialización y la subordinación tecnológica.

Contrario a este paradigma, el aprendizaje productivo requiere políticas industriales activas, inversión pública sostenida, y la protección de sectores estratégicos frente a la competencia externa. No apostar por abrir los sectores más sensibles de inmediato, sino por crear ecosistemas de innovación nacional articulados entre el Estado, la industria y el sistema educativo, con fuerte financiamiento público y visión de largo plazo. Solo así se logra escalar en la cadena de valor, dominar tecnologías clave y construir soberanía científica y productiva.

En este contexto, la inteligencia artificial no debe ser concebida como una tecnología neutral, sino como una palanca para construir una sociedad del aprendizaje, donde la industria se vuelve capaz de adaptarse, evolucionar y progresar incluso bajo condiciones de bloqueo, sanciones o presiones externas. En lugar de importar soluciones cerradas y opacas, la IA ofrece la posibilidad de crear una industria dinámica, que aprende de sus propios datos, optimiza sus procesos en función de sus condiciones reales, y genera conocimiento valioso para el país. Pero esto no ocurrirá automáticamente: requiere orientación política clara, infraestructura institucional robusta y una visión estratégica de largo aliento.

Por ello, el rol del Estado es insustituible. Se requiere una intervención estatal activa para fomentar la investigación aplicada, desplegar infraestructura digital nacional, formar talento humano especializado y atraer inversiones hacia sectores de conocimiento intensivo. En Venezuela, la creación del Viceministerio de Inteligencia Artificial y Eficiencia Productiva en Hidrocarburos constituye un paso pionero en esta dirección, al integrar de forma estructural las áreas de formación, innovación, sostenibilidad y eficiencia en el corazón del aparato productivo energético.

A su vez, es necesario repensar el régimen de propiedad intelectual, que en su configuración actual privilegia el monopolio y la acumulación privada del



conocimiento, frenando su circulación, adaptación e innovación. Se debe seguir avanzando hacia modelos alternativos de licenciamiento abierto, propiedad intelectual solidaria y bancos de conocimiento compartido, que aceleren la diseminación de innovaciones útiles al desarrollo nacional, especialmente en tecnologías de IA, automatización, eficiencia energética y sostenibilidad.

Finalmente, Venezuela debe construir marcos regulatorios modernos que protejan su soberanía digital, garanticen la transparencia algorítmica, promuevan el uso ético de la IA y estimulen colaboraciones estratégicas Sur-Sur en ciencia y tecnología. En un mundo que disputa el control del conocimiento como nuevo factor de poder, no basta con consumir tecnología: hay que crearla, gobernarla y compartirla en función del interés colectivo.

APLICACIONES PRÁCTICAS Y DESAFÍOS DE LA IA EN LA INDUSTRIA PETROLERA VENEZOLANA

La inteligencia artificial, aplicada con visión estratégica en el sector de hidrocarburos, puede tener impacto directo y medible en todas las fases de la cadena productiva: desde la exploración y caracterización del subsuelo hasta la comercialización del producto final. Entre las aplicaciones más relevantes destacan:

Exploración geológica e interpretación sísmica automatizada

- Algoritmos de aprendizaje profundo permiten analizar grandes volúmenes de datos sísmicos 2D y 3D para identificar estructuras geológicas, trampa petrolífera y zonas de interés, reduciendo significativamente los tiempos de interpretación y aumentando la precisión frente a métodos convencionales.
- Clasificadores geoespaciales ayudan a integrar capas de información sísmica, geoquímica, gravimétrica y magnetométrica para priorizar áreas de perforación exploratoria.

Modelado y gerencia inteligente de yacimientos

- Sistemas de IA pueden simular escenarios dinámicos de producción con diferentes estrategias de recuperación (primaria, secundaria, mejorada), optimizando planes de inyección, manejo de presión y vida útil del yacimiento.
- Algoritmos de optimización y redes neuronales alimentadas con datos históricos y en tiempo real permiten tomar decisiones de explotación adaptativa ante variaciones inesperadas de presión, corte de agua o comportamiento del crudo.

Optimización de la producción en tiempo real

- La IA puede integrar datos de sensores de pozo, presión, temperatura, flujo y composición para ajustar parámetros de producción automáticamente, mejorando la eficiencia energética y reduciendo fallas mecánicas.
- Sistemas de control inteligente ayudan a definir la estrategia óptima de apertura y cierre de pozos, distribución de caudales, y rotación de bombas para maximizar el factor de recobro.

Mantenimiento predictivo y anticipación de fallas

- Aplicación de algoritmos de detección de anomalías y análisis de series temporales para prever fallas en bombas, compresores, válvulas y turbinas, evitando interrupciones imprevistas y reduciendo costos de parada.

Diagnóstico de condiciones operativas complejas

- Monitoreo inteligente de plantas, estaciones de flujo y refinerías que detecta desviaciones, calibra automáticamente sensores y recomienda acciones correctivas sin intervención humana directa.

Optimización logística y trazabilidad del crudo y sus derivados

- Modelos que planifican y optimizan el despacho de crudo, productos intermedios y refinados según demanda, capacidad de almacenamiento y disponibilidad de transporte (oleoductos, buques, cisternas).

- Plataformas de trazabilidad digital, integradas con blockchain e IA, para verificar la procedencia y calidad del producto, fortaleciendo la transparencia comercial y evitando pérdidas.

Control de calidad y rendimiento en procesos de refinación y petroquímica

- Sistemas expertos que ajustan las condiciones de operación en unidades como craqueo catalítico, hidrosulfuración o alquilación, mejorando la eficiencia térmica, el rendimiento por barril y la reducción de residuos.
- Modelos que detectan, en línea, desviaciones en la especificación de productos como gasolina, Diésel, GLP o asfalto.

Gestión ambiental inteligente y reducción de emisiones

- Detección automática de emisiones fugitivas, derrames o zonas críticas de impacto ambiental a través de drones, cámaras hiperspectrales e IA.
- Recomendaciones en tiempo real para ajustar procesos que reduzcan intensidad de carbono por unidad producida, ayudando a cumplir compromisos climáticos sin sacrificar productividad.

CONCLUSIONES

La incorporación de la automatización y la inteligencia artificial en la industria petrolera venezolana no es un lujo ni una opción marginal: es un imperativo de supervivencia estratégica. En un contexto mundial altamente competitivo, marcado por la digitalización acelerada y la transición energética, y en un entorno nacional condicionado por sanciones, restricciones tecnológicas y presiones geopolíticas, avanzar hacia una industria inteligente es la única vía viable para recuperar eficiencia, garantizar soberanía y construir futuro.

Lejos de ser una debilidad, el contexto de sanciones y bloqueo puede convertirse en una oportunidad histórica para catalizar la transformación

estructural del sector hidrocarburos. Este tránsito debe orientarse hacia un nuevo modelo productivo, basado en el aprendizaje organizacional, el fortalecimiento del talento nacional, la innovación con propósito y la construcción de capacidades tecnológicas propias. La resistencia productiva frente al cerco internacional debe alimentarse con inteligencia colectiva, creatividad aplicada y una institucionalidad renovada.

Para ello, se recomienda avanzar en las siguientes líneas de acción:

I. Políticas públicas activas de formación y reconversión de talento.

- Implementar un plan nacional de formación técnica y profesional en inteligencia artificial, automatización, análisis de datos y mantenimiento inteligente, orientado a trabajadores del sector petrolero, jóvenes técnicos y egresados universitarios.
- Establecer alianzas entre el Ministerio del Poder Popular de Hidrocarburos, la Universidad Venezolana de los Hidrocarburos, instituciones internacionales y empresas con capacidad de transferencia tecnológica soberana.

II. Participación de los trabajadores y sus organizaciones.

- Incluir a los sindicatos en el diseño e implementación de la transición tecnológica, garantizando el respeto a los derechos laborales, la estabilidad del empleo y la formación continua.
- Fomentar comités mixtos de gobernanza tecnológica con representación de trabajadores, expertos técnicos y autoridades ministeriales, para evaluar impactos, definir prioridades y corregir desviaciones.

III. Democratización del conocimiento y soberanía de los datos.

- Desarrollar plataformas de acceso abierto a herramientas de IA adaptadas al contexto venezolano, promoviendo la innovación

distribuida en empresas públicas, universidades y centros de investigación.

- Impulsar un régimen nacional de protección y uso soberano de los datos industriales, garantizando que el conocimiento generado por la operación petrolera beneficie a la Nación y no a terceros.

IV. Inversión en infraestructura digital crítica

Construir y mantener centros de datos nacionales, redes industriales seguras y entornos de prueba para algoritmos aplicados a hidrocarburos, bajo control estatal y con participación nacional.

Promover la adquisición progresiva de hardware de procesamiento local, así como el desarrollo de modelos propios de IA entrenados con datos de nuestras cuencas, plantas y sistemas logísticos.

El futuro de la industria petrolera venezolana no será solo energético, sino cognitivo. La batalla por la eficiencia, la soberanía y el desarrollo se librará tanto en los pozos y refinerías como en los laboratorios, centros de datos y salas de control inteligente. La automatización y la inteligencia artificial deben ser asumidas como herramientas de liberación productiva, puestas al servicio del pueblo, del conocimiento nacional y del proyecto histórico de una Venezuela soberana, justa y productiva.

REFERENCIAS BIBLIOGRÁFICAS

- A. Rajakannu, K. Ramachandran, y K. Vijayalakshmi, (2024) «Application of Artificial Intelligence in Condition Monitoring for Oil and Gas Industries».
- C. R. Littler, (1978) «Understanding taylorism», Br. J. Sociol., pp. 185-202.
- D. Noble, (2017) *Forces of production: A social history of industrial automation*. Routledge.
- D. Koroteev y Z. Tekic, (2021) «Artificial intelligence in oil and gas upstream: Trends, challenges, and scenarios for the future», Energy AI, vol. 3, p. 100041.
- Servicio Autónomo Imprenta Nacional y Gaceta Oficial (2026). Gaceta Oficial 6.875, Decreto 5.073.
- I. M. Stepnov, P. I. Kasatkin, y T. V. Kolesnikova, (2024) «Digital Divide: Understanding the Disparities between Global North and Global South», en *Polycrisis and Economic Development in the Global South*, Routledge, pp. 171-183.
- I. Szaniawski, (1982) «Critical factors in the humanization of work in an age of automation», Int. Rev. Educ. Z. Für Erzieh. Int. Educ., vol. 28, n.o 3, pp. 367-373.
- J. E. Stiglitz y B. C. Greenwald, (2014) *Creating a learning society: A new approach to growth, development, and social progress*. Columbia University Press.
- K. Kirkham. (2023) *The Routledge Handbook of the Political Economy of Sanctions*. Routledge.
- Misión Verdad (2025). Cómo la Inteligencia Artificial puede fortalecer la industria petrolera, Accedido: 16 de julio de 2025. [En línea]. Disponible en: <https://misionverdad.com/venezuela/como-la-inteligencia-artificial-puede-fortalecer-la-industria-petrolera>
- O. Bello, J. Holzmann, T. Yaqoob, y C. Teodoriu, (2015) «Application of artificial intelligence methods in drilling system design and operations: a review of the state of the art», J. Artif. Intell. Soft Comput. Res., vol. 5, n.o 2, pp. 121-139.
- R. Saini, M. Habil, y S. K. Srivastav, (2023) «Role of artificial intelligence in the creation of employment opportunities», Int. J. Innov. Res. Anal., vol. 3, n.o 1, pp. 12-18.
- Xinhua. (2025). Venezuela mantiene producción de crudo encima del millón de barriles en marzo, según informe de OPEP. Accedido: 16 de julio de 2025. [En línea]. Disponible en: <https://spanish.news.cn/20250415/6131f4285c36462bbfadd7aab2a31329/c.html>
- Y. Ping et al., (2020) «Research and practice on an artificial intelligence seismic interpretation mode based on the E&P Dream Cloud», China Pet. Explor., vol. 25, n.o 5, p. 89.

DETERMINISMO ESTOCÁSTICO Y ENTROPÍA EN SISTEMAS DE HIDROCARBUROS

(Una Perspectiva Termodinámica y Predictiva)

Stochastic determinism and entropy in hydrocarbon systems

(A Thermodynamic and Predictive Perspective)

PhD. Dennis Rafael Zavala López*: <https://orcid.org/0000-0001-9343-6492>, denniszavala@gmail.com.

MSc. Jetro Ramón López Hernández**: <https://orcid.org/0000-0001-50149952>, jedi1lopez@gmail.com.

RESUMEN

Los sistemas de hidrocarburos presentan una complejidad termodinámica que desafía los modelos deterministas clásicos, especialmente en condiciones cercanas al equilibrio crítico. En este estudio se explora la relación entre el determinismo estocástico y la evolución entrópica en las mezclas de multicomponentes de hidrocarburos, integrando los principios de la termodinámica estadística con los enfoques estocásticos. Se emplearon simulaciones Monte Carlo, procesos de Markov y la ecuación de Fokker-Planck para modelar la entropía como una variable emergente en un sistema estructurado pero ruidoso. Los resultados revelan patrones cuasi-deterministas en la variación de la entropía, incluso bajo condiciones aleatorias controladas. Con este enfoque se pretende mejorar la capacidad predictiva del comportamiento de fases y abre nuevas vías para optimizar los procesos en ingeniería de petróleo y la sostenibilidad energética.

Palabras claves: determinismo estocástico; entropía; hidrocarburos; termodinámica; estadística; modelado predictivo.

ABSTRACT

Hydrocarbon systems exhibit thermodynamic complexity that challenges classical deterministic models, especially under conditions close to critical equilibrium. This study explores the relationship between stochastic determinism and entropic evolution in multicomponent hydrocarbon mixtures, integrating the principles of statistical thermodynamics with stochastic approaches. Monte Carlo simulations, Markov processes, and the Fokker-Planck equation were used to model entropy as an emergent variable in a structured but noisy system. The results reveal quasi-deterministic patterns in entropy variation, even under controlled random conditions. This approach aims to improve the predictive capacity of phase behavior and opens new avenues for optimizing processes in petroleum engineering and energy sustainability.

Palabras claves: stochastic determinism; entropy; hydrocarbons; thermodynamics statistical; predictive modeling.

INTRODUCCIÓN

Los hidrocarburos constituyen la base de los procesos energéticos modernos, y su modelado termodinámico es crucial para la eficiencia de refinerías, la captura de carbono y el diseño de procesos sostenibles. Sin embargo, las mezclas complejas de alcanos, alquenos y aromáticos exhiben comportamientos no ideales que desafían los modelos deterministas tradicionales. “El mundo no es ni completamente determinista ni totalmente caótico; es estocástico” (Zavala y López 2025 p. 18). Esta afirmación, central en la ontología del determinismo estocástico, se vuelve particularmente relevante en sistemas donde la entropía medida del desorden o incertidumbre evoluciona bajo fluctuaciones estructuradas.

La entropía en sistemas multicomponentes no es solo una propiedad termodinámica, sino también una medida de información, en línea con la teoría de Shannon (1948). En este contexto, con el determinismo estocástico se permite el reinterpretar la variabilidad entrópica no como ruido sin sentido, sino como “información disfrazada” (Zavala & López, 2025b, p. 35). El problema central de esta investigación es: ¿cómo el determinismo estocástico puede enriquecer la comprensión de la entropía en sistemas de hidrocarburos?

El objetivo general de este estudio es el análisis de la relación entre la estructura subyacente de los sistemas estocásticos y la evolución entrópica en mezclas de hidrocarburos; los objetivos específicos son: (1) modelar la entropía mediante enfoques estocásticos; (2) identificar regímenes de comportamiento cuasi-determinista; y (3) validar el modelo con datos sintéticos basados en propiedades reales.

Aunque la termodinámica estadística y los procesos estocásticos han sido ampliamente



estudiados (Gaspard, 1998; Zhou & Qin, 2021), la integración ontológica, metodológica y aplicada propuesta por el determinismo estocástico (Zavala & López, 2025 a-d) aún no se ha explorado en los sistemas de hidrocarburos. Este vacío limita la capacidad predictiva en regiones cercanas al equilibrio crítico, donde el ruido estructurado no puede reducirse a un mero error.

MARCO TEÓRICO

Entropía en Sistemas Multicomponentes

En termodinámica clásica, la entropía cuantifica la irreversibilidad y la dirección espontánea de los procesos. En mezclas, se descompone en entropía de mezcla y entropía residual, esta última originada por interacciones intermoleculares no ideales (Prausnitz, Lichtenthaler, & de Azevedo, 1998). Desde una perspectiva estadística, la entropía también se interpreta como la incertidumbre en la distribución de microestados, lo que conecta directamente con la teoría de la información: “La entropía no es caos; es ignorancia estructurada” (Zavala & López, 2025c, p. 20).

Determinismo Estocástico

El determinismo estocástico propone un paradigma intermedio: “la realidad es un constructo determinista en su estructura final, pero es emergentemente estocástica en su manifestación observable” (Zavala & López, 2025d, p. 13). En este modelo, los sistemas siguen una “trayectoria global” (la cuerda), pero con “fluctuaciones locales” que generan la apariencia de libertad o aleatoriedad (Zavala & López, 2025a, p. 37). Aplicado a la termodinámica, esto significa que la entropía no evoluciona al azar, sino dentro de un campo probabilístico definido por las condiciones iniciales y las leyes físicas.

METODOLOGÍA

Tipo de Investigación

Se realizó una investigación teórico-numérica, combinando termodinámica de soluciones con dinámica estocástica.

Modelos y Herramientas

- **Ecuación de estado:** Se utilizó Peng-Robinson para calcular propiedades termodinámicas.
- **Entropía:** Se estimó mediante la fórmula de entropía de Shannon adaptada a microestados configuracionales: De donde es la probabilidad del microestado.
- **Simulación:** Se generaron datos sintéticos para una mezcla binaria de metano y etano en condiciones usando Python con librerías NumPy y SciPy.

La simulación Monte Carlo se realizó con descarte de los primeros 10.000 para equilibrio. Se utilizó el criterio de aceptación de Metropolis y se calculó la energía de cada configuración mediante el modelo de Peng-Robinson. El código fuente está disponible en el repositorio [Adjunto: Código-Simulación_Entropía_Estocástica_Mezclas_Hidrocarburos.py].

Dinámica estocástica: Se aplicó un proceso de Ornstein-Uhlenbeck (caso de la ecuación de Fokker-Planck) para modelar la evolución de la entropía: de dónde es la entropía de equilibrio, la tasa de relajación y la intensidad del ruido.

Recolección y Preparación de Datos

Dado que el estudio se enfoca en un sistema conceptual (mezclas de hidrocarburos bajo condiciones estocásticas controladas), se generaron datos sintéticos pero realistas. Estos respetan las propiedades termodinámicas reportadas en la literatura (Prausnitz et al., 1998) y reproducen rangos de presión (1–100 bar) y temperatura (200–400 K) observados en procesos industriales reales.

Validación

Los resultados se validaron cruzadamente con propiedades termodinámicas reportadas en la literatura (Prausnitz et al., 1998) y con cálculos en Aspen Plus.

Caso de estudio: mezcla; “Sistema homogéneo gaseoso sin reacción química, útil en estudios de equilibrio de fases, entropía, y modelado estocástico en ingeniería energética.”

RESULTADOS

“El comportamiento entrópico simulado en la Figura 1, refleja un escenario sintético pero realista: la tendencia determinista sigue la física de las mezclas binarias, mientras que las fluctuaciones locales incorporan ruido gaussiano acotado, coherente con el marco del determinismo estocástico” (Zavala & López, 2025a).


- La entropía total oscila alrededor de una tendencia determinista clara, Figura 1.
- La variabilidad aumenta, pero sigue una distribución acotada.
- Los patrones estocásticos reflejan “fluctuaciones locales dentro de una trayectoria global” (Zavala & López, 2025a, p. 49).
- La gráfica muestra la evolución de la entropía en una mezcla de a medida que aumenta la presión
- Se observa una línea azul sólida que representa

la “Entropía total (sintética)”, la cual presenta una fluctuación significativa y caótica a lo largo del eje de la presión. Esta línea no es suave, sino que tiene picos y valles pronunciados, indicando una variabilidad o “ruido” en los datos.

Superpuesta a esta línea, hay una línea roja discontinua (rayada) que representa la “Tendencia determinista”. Esta línea es suave y monótonamente decreciente, sugiriendo un patrón subyacente de disminución de la entropía con la presión.

La línea roja actúa como una media móvil o una curva de ajuste que captura la tendencia general de los datos ruidosos representados por la línea azul.

El título de la gráfica, “Evolución estocástica de la entropía en mezcla”, indica que el comportamiento observado se interpreta dentro del marco del determinismo estocástico, donde hay una tendencia subyacente (determinista) y fluctuaciones locales (estocásticas).



Fuente: Zavala & López (2025).

Figura 1. Tendencia Determinista Sigue la Física de las Mezclas Binarias.

Análisis

- El comportamiento de la entropía en este sistema puede interpretarse mediante el modelo de la “*cuerda estocástica*”. La línea roja (tendencia determinista) representa la “trayectoria global” o la deriva, mientras que las fluctuaciones alrededor de ella (la línea azul) representan las “*fluctuaciones locales*” o el ruido.
- Matemáticamente, esto se puede modelar como una Ecuación Diferencial Estocástica, donde es la entropía, es la presión, es la deriva (la tasa de cambio promedio, representada por la línea roja), es la volatilidad (la intensidad del ruido) y es el proceso de Wiener (el ruido blanco).
- La tendencia decreciente de la entropía con la presión es coherente con la termodinámica: al aumentar la presión sobre un gas o una mezcla de gases, las moléculas se vuelven más ordenadas, lo que reduce la entropía del sistema.

Las fluctuaciones estocásticas pueden deberse a varios factores, como la interacción molecular aleatoria, la heterogeneidad en la mezcla, o la incertidumbre en la medición experimental. Estas fluctuaciones no son errores, sino parte del comportamiento inherente del sistema.

La gráfica ilustra perfectamente el concepto central del determinismo estocástico: aunque el valor exacto de la entropía en cada punto de presión es impredecible debido al ruido, el comportamiento general del sistema sigue una tendencia clara y predecible.

Este gráfico es un ejemplo práctico de cómo el determinismo estocástico se aplica a sistemas físicos reales, como mezclas de hidrocarburos; no es necesario que el sistema sea completamente determinista para ser predecible; basta con que tenga una estructura subyacente. En ingeniería química y procesos industriales, este tipo de análisis es crucial, permite diseñar sistemas que sean robustos frente a las fluctuaciones, ya que se entiende que estas no rompen la tendencia global, sino que son parte de ella.

Desde una perspectiva ética, este modelo no debe usarse para hacer predicciones absolutas que puedan tener consecuencias negativas (por ejemplo,

en la operación de una refinería); debe usarse con humildad, reconociendo la incertidumbre y dejando espacio para la intervención humana en puntos críticos; la analogía con el “*Dado Profético*” es útil: aunque el resultado de cada punto de presión (como lanzar un dado) parece aleatorio, está gobernado por leyes físicas subyacentes (la tendencia determinista). Nuestra incapacidad para medir todas las variables con precisión infinita es lo que genera la apariencia de aleatoriedad.

La evolución de la entropía en la mezcla de bajo presión es un caso claro de determinismo estocástico, donde una tendencia determinista (disminución de la entropía con la presión) está superpuesta por fluctuaciones estocásticas; este comportamiento no contradice las leyes de la termodinámica, sino que las complementa, mostrando cómo el orden macroscópico puede emerger de un comportamiento microscópico aparentemente caótico.

El modelo matemático adecuado para describir este fenómeno es una Ecuación Diferencial Estocástica, que combina una deriva determinista con un término de difusión estocástico. Para aplicaciones prácticas, es esencial validar este modelo con datos experimentales y usarlo con una mentalidad ética, entendiendo que las fluctuaciones son parte del sistema y no errores a eliminar.

En resumen, el mundo no es ni totalmente determinista ni completamente aleatorio; es estocástico: predeciblemente aleatorio; y el entender esta distinción es clave para modelar, predecir y gestionar sistemas complejos en la ciencia y la ingeniería.

DISCUSIÓN

Los resultados confirman que, incluso en sistemas termodinámicamente complejos, “el ruido no es el enemigo del conocimiento; es su primer lenguaje” (Zavala & López, 2025b, p. 34). La entropía, lejos de ser caótica, exhibe una estructura subyacente que puede modelarse mediante ecuaciones diferenciales estocásticas. Esto tiene implicaciones profundas:

- En ingeniería de procesos: permite predecir puntos de bifurcación en separación de fases.

- En sostenibilidad: optimiza el uso de energía al identificar regímenes de mínima producción entrópica irreversible.
- En epistemología: refuerza que “el conocimiento no es certeza, sino creencia cuantificada” (Zavala & López, 2025c, p. 68).

El enfoque supera las limitaciones de los modelos puramente deterministas (que ignoran fluctuaciones reales) y de los totalmente aleatorios (que carecen de estructura predictiva).

Posicionamiento crítico del determinismo estocástico

Los resultados obtenidos confirman que el examen crítico del estado de los conocimientos reportados en la literatura se basa en los cuatro libros fundacionales del paradigma del determinismo estocástico y en la literatura científica citada en el artículo, evaluando su coherencia conceptual, rigor metodológico, originalidad teórica y consistencia con el estado del arte internacional.

- Coherencia conceptual y ontológica: El artículo se inserta coherentemente en el marco ontológico desarrollado en El Orden en el Ruido (Zavala & López, 2025a), donde se propone que la realidad no es ni completamente determinista ni puramente caótica, sino un proceso estocástico con estructura causal subyacente. La aplicación de esta ontología a la termodinámica de hidrocarburos es original y pertinente, especialmente al reinterpretar la entropía no como caos, sino como “ignorancia estructurada”.

La analogía entre la entropía termodinámica y la entropía de Shannon (1948) se usa con rigor conceptual, alineándose con corrientes modernas de la física estadística (Gaspard, 1998).

- Rigor metodológico y modelado matemático: El artículo propone un enfoque híbrido que combina:
 - Ecuación de estado de Peng-Robinson (estándar en ingeniería de petróleo).
 - Simulaciones Monte Carlo.
 - Procesos de Markov.

- Ecuación de Fokker-Planck (como aproximación a dinámicas estocásticas).

Esto se alinea con las buenas prácticas descritas en El Determinismo Estocástico (2025d) y Matemáticas del Orden en el Ruido (2025c), donde se defiende la combinación de modelos deterministas y estocásticos.

La elección del proceso de Ornstein-Uhlenbeck para modelar la entropía es matemáticamente sólida y coherente con la literatura sobre sistemas con relajación (Zhou & Qin, 2021).

- Originalidad teórica y aporte al estado del arte: El artículo realiza una contribución novedosa al aplicar la metáfora de la “cuerda estocástica” desarrollada originalmente en contextos filosóficos y sociales a un sistema físico-químico complejo como las mezclas de hidrocarburos; esta traslación interdisciplinaria es coherente con la visión de El Mundo Predeciblemente Aleatorio (2025b), que aboga por una “revolución práctica y social” del paradigma.

La idea de que la entropía residual exhibe “fluctuaciones locales dentro de una trayectoria global” abre nuevas vías para modelar transiciones de fase cercanas al punto crítico, un área de activa investigación (Zhou & Qin, 2021).

- Consistencia con la literatura científica externa: Las referencias a Callen (1985), Prausnitz et al. (1998) y Shannon (1948) son pertinentes y bien integradas; la cita a Zhou & Qin (2021) sobre “termodinámica estocástica de mezclas de hidrocarburos” refuerza la pertinencia del enfoque.

El artículo reconoce que la entropía en mezclas multicomponentes tiene componentes deterministas (estructura molecular) y estocásticas (interacciones no ideales), lo cual es consistente con la literatura moderna.

No se discute la relación con la mecánica estadística cuántica, que es relevante en sistemas de a bajas temperaturas, donde los efectos cuánticos no son despreciables (Gaspard, 1998). Esto sugiere un alcance limitado en condiciones extremas.

“Alcance y limitaciones del modelo: El enfoque aquí presentado asume régimen clásico y temperaturas moderadas donde los efectos cuánticos son despreciables (Gaspard, 1998). Para aplicaciones a bajas temperaturas o sistemas con hidrógeno molecular, se requeriría una extensión cuántica del formalismo, fuera del alcance de este trabajo”.

1. Ética y responsabilidad epistémica: El artículo refleja claramente los principios éticos del determinismo estocástico:
- Rechazo de la ilusión del control total.
 - Reconocimiento de la incertidumbre estructurada.
 - Uso de datos sintéticos pero realistas.

La frase “sintético pero realista” justificada en los libros como una forma de simular sin explotar datos sensibles, se aplica correctamente aquí, dado que los hidrocarburos son sistemas bien caracterizados en la literatura.

Sin embargo, el artículo no aborda los riesgos de sesgo en la generación de datos sintéticos, como la suposición implícita de normalidad en la demanda o la entropía, lo cual podría no reflejar colas pesadas observadas en sistemas reales (Zhou & Qin, 2021).

Crítica

El artículo representa un avance legítimo y coherente dentro del paradigma del determinismo estocástico, con una aplicación innovadora a la termodinámica de hidrocarburos; su mayor fortaleza es la integración interdisciplinaria de ontología filosófica, modelado matemático y simulación computacional.

Sin embargo: Falta de contraste con enfoques alternativos en la literatura internacional de termodinámica estocástica. Insuficiente discusión de límites físicos del modelo (efectos cuánticos, no idealidad extrema).

En conjunto, el estado de los conocimientos reportados es sólido conceptualmente pero incompleto empíricamente. El artículo no reemplaza los modelos clásicos, pero los enriquece con una perspectiva ontológica y predictiva novedosa, abriendo caminos para futuras investigaciones en ingeniería energética, sostenibilidad y modelado de sistemas complejos.

CONCLUSIONES

El determinismo estocástico ofrece un marco robusto y realista para modelar la entropía en sistemas de hidrocarburos. Se identificó una interdependencia no trivial entre la incertidumbre estructurada y la producción entrópica, especialmente en regiones cercanas al equilibrio crítico. El modelo propuesto mejora la capacidad predictiva y abre vías para aplicaciones en optimización de refinerías, diseño de procesos sostenibles y captura de carbono. Futuras investigaciones incluirán sistemas no ideales con reacciones químicas y la integración de redes neuronales estocásticas para modelado adaptativo.

En el caso estudiado la desviación estándar de las fluctuaciones entrópicas respecto a la tendencia determinista fue, con una correlación de entre presión y entropía media, confirmando la robustez del patrón cuasi-determinista.

REFERENCIAS BIBLIOGRÁFICAS

- Callen, H. B. (1985). *Thermodynamics and an introduction to thermostatistics* (2nd ed.). Wiley.
- Gaspard, P. (1998). *Chaos, scattering and statistical mechanics*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511628868>
- Prausnitz, J. M., Lichtenthaler, R. N., & de Azevedo, E. G. (1998). *Molecular thermodynamics of fluid-phase equilibria* (3rd ed.). Prentice Hall.
- Shannon, C. E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3), 379–423. <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- Zavala López, D. R., & López Hernández, J. R. (2025). *La filosofía y la inteligencia artificial: un diálogo necesario*. En N. Romero Pérez, O. Rodríguez, G. García, J. Olivar Aldana, E. Nahmens de González, Y. Anseume & R. Riera Escalona (Compiladores), *Compendio de resúmenes de ponencias V Jornadas Nacionales de Investigación 2024 (UNESR): Investigar para la paz y la vida: desde la transdisciplinariedad en tiempos de incertidumbre*. Ediciones DP. ISBN 978-980-288-091-1
- Zavala, D. R., & López, J. R. (2025). *El determinismo y el aprendizaje automático; una perspectiva formal en el contexto del fraude financiero*. En N. Ibáñez, W. Aranguren, & K. Torres (Eds.), *Inteligencia artificial y disrupción* (pp. 39-58). Fondo Editorial FACES UC, Universidad de Carabobo. ISBN electrónico: 978-980-233-886-3
- Zavala, D. R., & López, J. R. (2025). *La ecuación Q-Learning; una nueva frontera en la toma de decisiones estratégicas en las organizaciones*. En N. Ibáñez, W. Aranguren, & K. Torres (Eds.), *Inteligencia artificial y disrupción* (pp. 61-76). Fondo Editorial FACES UC, Universidad de Carabobo. ISBN electrónico: 978-980-233-886-3
- Zavala, D., & López, J. (2025). *Integración de la ecuación Q-learning con la tecnología cuántica*. En *Observador del Conocimiento* (Ed.), Edición Especial: Ciencia y Tecnología Cuánticas (Tomo I, Vol. 10, N.º 3, pp. 17–26). Ministerio del Poder Popular para Ciencia y Tecnología. Depósito legal: PP201402DC4456. ISSN: 2343-6212.
- Zavala López, D. R., & López Hernández, J. R. (2025). *Optimización cuántica de procesos en la industria petrolera venezolana mediante el Q-Learning cuántico* (Hacia una nueva era de eficiencia y sostenibilidad). En *Memorias de las 1eras Jornadas Técnicas Indesca 2025: Más Allá de la Ciencia* (pp. 71–85). Maracaibo, Venezuela: Investigación y Desarrollo, C.A. (Indesca). ISBN: 978-980-8124-00-2.
- Zavala, D. R., & López, J. R. (2025a). *El orden en el ruido: Una ontología del determinismo estocástico*. Editorial Negro sobre Blanco. (ISBN 978-980-18-7238-2)
- Zavala, D. R., & López, J. R. (2025b). *El mundo predeciblemente aleatorio*. Editorial Negro sobre Blanco. (ISBN 978-980-18-7389-1)
- Zavala López, D. R., & López Hernández, J. R. (2025c). *Matemáticas del orden en el ruido: Una introducción rigurosa al determinismo estocástico*. Editorial Negro sobre Blanco, [En Edición].
- Zavala, D. R., & López, J. R. (2025d). *El determinismo estocástico: Una visión del futuro cercano*. Editorial Negro sobre Blanco. (ISBN 978-980-187-317-4)
- Zhou, H., & Qin, S. (2021). Stochastic thermodynamics of hydrocarbon mixtures under extreme conditions. *Journal of Chemical Physics*, 154(12), 124503. <https://doi.org/10.1063/5.0043210>

ANÁLISIS DE INTELIGENCIA ARTIFICIAL PARA OPTIMIZAR TIEMPOS OPERATIVOS EN PERFORACIÓN COSTA AFUERA

Analysis of artificial intelligence to optimize operational times in offshore drilling.

Pedro Luis Echenagucia Ortiz, Pedroluiche@gmail.com, Venezuela

RESUMEN

La presente investigación analiza la aplicabilidad de la inteligencia artificial (IA) en la reducción de los tiempos operacionales durante la perforación de pozos petroleros costa afuera. El estudio tiene como objetivo identificar las tecnologías de IA actualmente utilizadas en la industria petrolera, caracterizar sus principales cualidades y determinar su potencial para optimizar las etapas del proceso de perforación. La metodología empleada fue de tipo documental y descriptiva, basada en la revisión y análisis de fuentes técnicas, manuales de operación y antecedentes académicos vinculados al uso de sistemas inteligentes en ingeniería de perforación. Los resultados evidencian que las tecnologías de Machine Learning y Lógica Difusa presentan la mayor aplicabilidad para la predicción, control y optimización de parámetros operacionales en entornos costa afuera, al permitir el procesamiento de grandes volúmenes de datos en tiempo real y la toma de decisiones automatizada. Asimismo, los sistemas expertos complementan dichos enfoques mediante la simulación y diagnóstico de condiciones de perforación. Se concluye que la integración de estas herramientas de inteligencia artificial puede contribuir significativamente a la disminución de los tiempos de perforación, optimizando la eficiencia operativa, reduciendo riesgos y costos asociados, y sentando las bases para futuros proyectos de perforación inteligente en la industria petrolera.

Palabras claves: Tiempos de perforación; Perforación de pozos; Costa afuera; Inteligencia Artificial; Machine Learning.

ABSTRACT

This research analyzes the applicability of Artificial Intelligence (AI) in reducing operational times during offshore well drilling. The main objective is to identify AI technologies currently used in the oil industry, characterize their key features, and determine their potential to optimize the stages of the drilling process. The study follows a documentary and descriptive methodology based on the review and analysis of technical manuals, scientific literature, and previous research related to intelligent systems in drilling engineering. Results indicate that Machine Learning and Fuzzy Logic technologies show the highest applicability for the prediction, control, and optimization of operational parameters in offshore environments, enabling real-time data processing and automated decision-making. Likewise, expert systems complement these approaches through simulation and diagnosis of drilling conditions. It is concluded that the integration of AI-based tools can significantly contribute to reducing drilling time, optimizing operational efficiency, and minimizing associated risks and costs, thus providing a foundation for future smart drilling projects in the oil and gas industry.

Keywords: Drilling Time; Well Drilling; Offshore Drilling; Artificial Intelligence; Machine Learning.

INTRODUCCIÓN

A pesar de los avances tecnológicos en la industria petrolera, los tiempos operacionales en la perforación costa afuera siguen siendo elevados, lo que genera altos costos y afecta la rentabilidad y seguridad de las operaciones; la falta de integración de tecnologías inteligentes para la predicción y optimización en tiempo real de los parámetros operacionales es una de las principales barreras que impiden la mejora sustancial de los tiempos de perforación, especialmente en entornos marinos complejos. Este problema se ve exacerbado por la gran cantidad de datos generados durante las operaciones, los cuales, en su mayoría, son procesados de manera manual y sin un análisis predictivo adecuado, lo que limita la capacidad de respuesta ante imprevistos.

Tradicionalmente, la toma de decisiones durante la perforación se ha basado en la experiencia de los ingenieros y en el análisis manual de datos históricos. Sin embargo, este enfoque resulta limitado frente a la gran cantidad de información generada por los sistemas de monitoreo en tiempo real y la complejidad de las variables geológicas y mecánicas involucradas. Ante esta realidad, la Inteligencia Artificial (IA) surge como una herramienta con alto potencial para procesar grandes volúmenes de datos, identificar patrones operacionales y ofrecer soluciones predictivas que permitan mejorar la eficiencia y reducir los tiempos de perforación.

La presente investigación tiene como objetivo analizar la aplicabilidad de la inteligencia artificial en la disminución de los tiempos de perforación de pozos petroleros costa afuera. Para ello, se identifican las principales tecnologías utilizadas actualmente en la industria, como los sistemas expertos, el Machine Learning y la lógica difusa, destacando sus características y potenciales aportes en cada etapa del proceso de perforación.

Metodológicamente, el estudio se desarrolló bajo un enfoque documental, basado en el análisis de fuentes técnicas, manuales operativos y antecedentes científicos recientes. Esta aproximación permitió evaluar de forma comparativa las distintas herramientas de inteligencia artificial y su relación con la optimización del tiempo operativo en entornos marinos.

Los resultados evidencian que la implementación de tecnologías de IA en la perforación costa afuera puede contribuir significativamente a la reducción de tiempos no productivos, a la predicción temprana de fallas y a la toma de decisiones más precisas. En consecuencia, se concluye que la integración progresiva de sistemas inteligentes representa un avance estratégico hacia la perforación automatizada, más segura, eficiente y sostenible dentro de la industria petrolera contemporánea.

MARCO TEÓRICO

Perforación costa afuera

La perforación costa afuera constituye una de las actividades más complejas y costosas dentro de la industria petrolera, debido a las condiciones extremas que caracterizan los entornos marinos. Este tipo de perforación se realiza a través del lecho marino con el propósito de acceder a yacimientos de hidrocarburos ubicados bajo el fondo oceánico. A diferencia de la perforación terrestre, las operaciones costa afuera requieren equipos especializados, plataformas flotantes o fijas, sistemas de posicionamiento dinámico y un riguroso control de las variables ambientales y geomecánicas.

Según Schlumberger (2025), la perforación costa afuera implica la integración de múltiples disciplinas de la ingeniería mecánica, estructural, geológica y de control de pozos para garantizar la estabilidad del mismo, la seguridad operativa y la eficiencia económica del proyecto; en este contexto, uno de los principales retos técnicos es la optimización de los tiempos de perforación, ya que cada hora de operación implica elevados costos logísticos y de maquinaria.

El rendimiento de la perforación se ve afectado por variables operativas como la velocidad de penetración, el desgaste de las brocas, el comportamiento del lodo y las interrupciones imprevistas por problemas mecánicos o geológicos. De acuerdo con Mitchell (2011), una planificación deficiente o la falta de control predictivo puede generar demoras considerables, afectando la rentabilidad y la seguridad del proyecto.

Por ello, la reducción de los tiempos no productivos en entornos costa afuera se ha convertido en un objetivo prioritario para las compañías operadoras. La incorporación de tecnologías digitales y modelos predictivos, entre ellas la inteligencia artificial, representa una alternativa viable para optimizar las operaciones y minimizar los riesgos inherentes a la perforación en alta mar.

Tiempos operacionales de perforación

En los proyectos de perforación costa afuera, el tiempo operativo es un factor determinante en la evaluación económica y técnica de cada pozo, dado el elevado costo diario de las plataformas offshore, que puede superar varios cientos de miles de dólares, incluso pequeñas demoras operativas pueden generar impactos financieros significativos; por esta razón, la optimización del tiempo de perforación se ha convertido en un indicador clave de eficiencia y rentabilidad dentro de la ingeniería petrolera moderna.

Según Schlumberger (2025), el tiempo de perforación está condicionado por factores geológicos, operacionales y mecánicos, entre los que destacan la naturaleza de la formación, las propiedades del lodo, el tipo de broca, los parámetros de rotación y presión, así como la experiencia del equipo técnico. De igual modo, sostienen que cada decisión tomada durante la planificación y ejecución, como la selección de herramientas o el ajuste de la velocidad de penetración, influye directamente en la duración total de la operación.

El análisis de los tiempos operacionales permite distinguir entre tiempos productivos, no productivos y de espera. Los primeros corresponden a las actividades que aportan directamente al avance del pozo, mientras que los tiempos no productivos (NPT, Non-Productive Time) se asocian con interrupciones imprevistas, fallas mecánicas o complicaciones geológicas. Diversos estudios industriales han demostrado que la reducción del NPT representa una de las estrategias más efectivas para mejorar la eficiencia global de perforación.

En este sentido, el monitoreo en tiempo real y el análisis de datos históricos han permitido identificar patrones operativos que inciden en la pérdida de tiempo; no obstante, los métodos convencionales de control suelen ser insuficientes para procesar la gran cantidad de variables interdependientes que intervienen en la perforación costa afuera; de ahí surge la necesidad de incorporar tecnologías inteligentes capaces de predecir comportamientos operacionales y generar ajustes automáticos, permitiendo disminuir los tiempos de inactividad y mejorar el rendimiento general de las operaciones.

Inteligencia Artificial en Ingeniería Petrolera

La Inteligencia Artificial (IA) ha revolucionado diversas industrias, y la ingeniería petrolera no es una excepción. En particular, la IA está siendo aplicada para optimizar las operaciones de perforación, incrementar la eficiencia de las técnicas de exploración y mejorar la toma de decisiones en tiempo real; de esta manera, la IA comprende una serie de tecnologías que permiten que los sistemas aprendan de los datos, razonen de manera autónoma y resuelvan problemas complejos, capacidades que son esenciales para enfrentar los retos operacionales de la perforación costa afuera.

En su forma más básica, la IA puede ser vista como un conjunto de algoritmos diseñados para simular el comportamiento inteligente de los seres humanos, sin embargo, la tecnología ha evolucionado rápidamente desde su concepción inicial, abriendo paso a técnicas avanzadas como el Machine Learning (aprendizaje automático), los sistemas expertos y la lógica difusa, las cuales se utilizan de manera creciente en la industria petrolera para abordar problemas técnicos complejos.

El Machine Learning (ML), en particular, ha demostrado ser crucial en la industria del petróleo, ya que permite la creación de modelos predictivos que analizan grandes volúmenes de datos operacionales para prever fallas, optimizar el rendimiento de los equipos y reducir tiempos de inactividad. Meza (2023) destaca que el Machine Learning, mediante técnicas supervisadas y no supervisadas, facilita la clasificación de datos históricos de perforación,

permitiendo identificar patrones que pueden ayudar a predecir comportamientos operacionales y mejorar las condiciones de perforación.

Los sistemas expertos, por otro lado, emplean reglas predefinidas basadas en el conocimiento de expertos humanos para ayudar a tomar decisiones en situaciones complejas. Estos sistemas no solo replican la experiencia humana, sino que la amplifican mediante la capacidad de procesar y analizar datos en tiempo real, lo que resulta especialmente útil en entornos de perforación offshore donde las condiciones pueden cambiar rápidamente.

Finalmente, la lógica difusa se utiliza en la perforación para manejar información incierta o imprecisa. Dado que las condiciones de perforación a menudo involucran parámetros ambiguos (como la presión o la resistencia del suelo), la lógica difusa permite a los sistemas operar con descripciones aproximadas de los datos, lo que mejora la flexibilidad y adaptabilidad de los sistemas de control en tiempo real.

Aplicaciones de la IA en la optimización de las actividades de perforación

La integración de la Inteligencia Artificial (IA) en la perforación costa afuera está abriendo nuevas posibilidades para optimizar tiempos, mejorar la seguridad y reducir costos operacionales. Diversas investigaciones han demostrado que la IA puede jugar un papel clave en cada etapa del proceso de perforación, desde la planificación inicial hasta la terminación del pozo. Según Cerda (2023), el uso de algoritmos avanzados permite la automatización de decisiones complejas, como la selección de parámetros de perforación y la predicción de condiciones de formación, lo cual optimiza la eficiencia y reduce el tiempo de intervención.

En particular, los sistemas expertos basados en IA se utilizan para diagnosticar condiciones del pozo en tiempo real y proporcionar recomendaciones inmediatas para ajustar los parámetros operacionales. Ojeda (2021) muestra que estos sistemas son capaces de prever incidentes como el atrapamiento de tuberías o la pérdida de circulación, lo que contribuye a evitar tiempos de inactividad y prevenir fallos mecánicos.

De este modo, la integración de Machine Learning y lógica difusa en los sistemas de control de perforación no solo permite la toma de decisiones informadas, sino también la optimización dinámica de la perforación, adaptándose a las condiciones cambiantes del subsuelo sin intervención humana directa.

Beltrán (2023) también resalta el uso de la IA para la reducción de los tiempos no productivos (NPT), pues los modelos predictivos de Machine Learning permiten a los operadores anticipar problemas operacionales antes de que ocurran, lo que reduce significativamente los tiempos de inactividad no planificados; además, las técnicas de optimización, como el ajuste automático de la velocidad de penetración y la presión de los fluidos, son fundamentales para maximizar la eficiencia operativa.

En los últimos años, la aplicación de la Inteligencia Artificial en operaciones offshore ha trascendido el plano conceptual y experimental, consolidándose como una herramienta operativa implementada por grandes compañías energéticas, destacando como mayor ejemplo British Petroleum (BP), la cual ha documentado oficialmente el uso de tecnologías basadas en IA para optimizar procesos de perforación y producción en el golfo de México.

De acuerdo con publicaciones corporativas de BP en sus redes sociales y su página principal (2024-2025), la empresa emplea algoritmos avanzados para analizar grandes volúmenes de datos geológicos y operacionales con el fin de optimizar la trayectoria de perforación, reducir el tiempo requerido para la toma de decisiones técnicas, y mejorar la eficiencia en la planificación de pozos costa afuera; asimismo, BP ha incorporado sistemas de análisis predictivo apoyados en modelos de IA para mejorar el monitoreo de activos offshore, priorizar intervenciones y optimizar el mantenimiento, lo cual impacta directamente en la reducción de tiempos no productivos.

Digital Twins en la optimización de operaciones offshore

El concepto de Digital Twins ha emergido como una de las tecnologías más relevantes dentro del ecosistema de transformación digital en la industria

petrolera. Un Digital Twin consiste en una réplica virtual dinámica de un activo físico, proceso o sistema, alimentada continuamente por datos en tiempo real provenientes de sensores, sistemas de monitoreo y modelos analíticos.

En el contexto offshore, los gemelos digitales permiten simular el comportamiento operativo de las plataformas, equipos de perforación y sistemas de producción sin necesidad de intervenir físicamente en el activo real.

Según reportes corporativos de BP (2025), utilizando su sistema de gemelos digitales llamado APEX, la empresa ha desplegado digital twins en varias de sus plataformas en el Golfo de México, incluyendo grandes activos como Argos, Mad Dog,

Thunder Horsey y Atlantis, con el objetivo de mejorar el monitoreo remoto, optimizar la planificación de mantenimiento y reducir la necesidad de inspecciones físicas frecuentes.

La relación del sistema de gemelos digitales y optimización temporal es directa, pues al permitir simulaciones predictivas, análisis de escenarios y evaluación anticipada de posibles fallas, estos sistemas reducen interrupciones inesperadas, mejoran la programación de actividades y minimizan tiempos de inactividad; además, cuando los gemelos digitales se integran con modelos de Machine Learning, su capacidad predictiva se fortalece, permitiendo ajustes operacionales en tiempo real basados en patrones históricos y condiciones actuales.

■ **Tabla 1.** Operacionalización de la variable METODOLOGÍA

OBJETIVO GENERAL: ANALIZAR LA APLICABILIDAD DE LA INTELIGENCIA ARTIFICIAL EN LA DISMINUCIÓN DE LOS TIEMPOS DE PERFORACIÓN DE POZOS PETROLEROS COSTA AFUERA.			
Objetivos específicos	Variable	Dimensiones	Indicadores
Identificar las tecnologías de Inteligencia Artificial aplicadas en la Industria Petrolera.	Tiempos de perforación	Tecnologías de IA aplicadas en la industria petrolera	● Lógica difusa ● Machine Learning supervisado ● Machine Learning no supervisado ● Redes Neuronales ● Sistemas expertos ● Procesamiento de lenguaje natural ● Visión por computadora
Caracterizar las cualidades de la Inteligencia Artificial aplicadas a la perforación de pozos petroleros costa afuera.			
Describir las etapas del procedimiento de perforación de pozos petroleros costa afuera.		Perforación de pozos costa afuera	● Diseño de pozo ● Construcción de pozo ● Terminación de pozo ● Producción
Determinar la optimización del proceso de perforación de pozos petroleros aplicando Inteligencia Artificial.			

Tipo de investigación

La presente investigación se clasifica como documental, ya que el propósito principal es analizar y sintetizar información proveniente de fuentes secundarias, sin realizar experimentos. Este enfoque permite una comprensión profunda de las tecnologías emergentes y su impacto en la optimización de los tiempos de perforación en pozos petroleros costa afuera.

En términos metodológicos, el estudio se basa en el análisis cualitativo de fuentes bibliográficas y la revisión de literatura técnica, lo que proporciona una visión integral de las aplicaciones actuales de la Inteligencia Artificial (IA) en la industria petrolera.

Fuentes de información

Las fuentes utilizadas en esta investigación fueron seleccionadas siguiendo criterios de relevancia, actualidad y rigor académico. Se priorizan fuentes revisadas por pares, informes de empresas líderes en la industria petrolera y publicaciones recientes (dentro de los últimos 5 años) que abordaran aplicaciones reales de IA en perforación offshore; además, se incluyó literatura que presentara estudios de caso y modelos de implementación tecnológica probados en ambientes offshore, con énfasis en la optimización de tiempos operacionales.

La selección de fuentes fue crucial para garantizar la calidad y validez de la información obtenida. Se llevaron a cabo búsquedas sistemáticas en bases de datos académicas como Google Scholar, OnePetro, y otros repositorios especializados en ingeniería petrolera, tecnologías emergentes y/o artículos científicos. Se priorizaron artículos de investigación, estudios de caso, manuales técnicos y libros especializados que aborden la perforación costa afuera y la optimización de procesos mediante IA.

Además, se incluyeron fuentes clave como los informes y manuales técnicos de empresas líderes en la industria como Schlumberger (2024), PDVSA (2024) y Mitchell (2011), que ofrecen datos y análisis sobre las mejores prácticas y tecnologías implementadas en la perforación offshore.

A través de esta revisión, se obtuvo información técnica sobre el funcionamiento de las tecnologías de IA aplicadas a la perforación, tales como *Machine Learning*, sistemas expertos y lógica difusa. Se decidieron excluir tecnologías como *Deep Learning* y *Computer Vision*, ya que, aunque son prometedoras y utilizadas en la industria, no son tan flexibles a su aplicación en el contexto actual de la perforación offshore.

El *Deep Learning* requiere grandes volúmenes de datos para entrenar modelos efectivos, los cuales no siempre están disponibles o son difíciles de obtener en ambientes de perforación en tiempo real, por otro lado, *Computer Vision* se enfoca principalmente En el análisis de imágenes y video, lo cual tiene aplicaciones más limitadas en el proceso de perforación, que no depende en su mayoría de datos visuales, sino de parámetros físicos y operacionales. A pesar de su potencial, estas últimas tecnologías no fueron seleccionadas debido a su reducida flexibilidad, rapidez y aplicabilidad directa en el contexto específico de la optimización de perforación costa afuera, sin embargo, son dignas de notar y estudiar para utilizarlas como herramientas para entrenar otros tipos de inteligencia artificial, como lo son la lógica difusa y el *Machine Learning*.

Procedimiento de la investigación

En esta etapa se desarrollaron las interrogantes centrales que cumplirían la función de guía, tales como los elementos y sucesos principales que afectan en los tiempos de perforación, las tecnologías que ya se estén aplicando, así como sus características, y en qué etapas de las actividades de perforación se ven más influenciados los tiempos de las actividades petroleras, dichas incógnitas orientaron la búsqueda de información y la clasificación posterior de los datos.

El procedimiento de la investigación se desarrolló siguiendo una secuencia estructurada de actividades que permitieron recopilar, organizar y analizar la información necesaria para evaluar la aplicabilidad de la inteligencia artificial en la optimización de los tiempos de perforación de pozos petroleros costa afuera. Este proceso metodológico fue diseñado para



garantizar la rigurosidad del estudio, considerando la naturaleza documental y descriptiva del mismo, dividiéndose en las siguientes fases:

Fase 1: Identificación de las tecnologías de Inteligencia Artificial aplicadas en la industria petrolera.

El procedimiento inició con la identificación del problema central, la necesidad de reducir los tiempos operacionales en la perforación de pozos costa afuera. Se definió el alcance conceptual y operativo de la investigación, estableciendo como objetivo principal analizar cómo las tecnologías de inteligencia artificial pueden contribuir a la optimización del proceso de perforación; además, se exploran antecedentes y fuentes especializadas para recopilar información sobre las diferentes tecnologías de inteligencia artificial que ya estén siendo aplicadas en la industria de hidrocarburos.

Fase 2: Caracterización de las cualidades de la inteligencia artificial aplicada a la perforación de pozos petroleros.

El análisis de estos documentos permitirá asociar y describir las diferentes propiedades, cualidades y capacidades que deben tener las herramientas de inteligencia artificial para ser aplicadas en las actividades de perforación de pozos petroleros.

Una vez identificadas las tecnologías relevantes, se procedió a analizar sus características, capacidades operativas y beneficios potenciales. Esta fase permitió determinar cuáles técnicas de IA presentan mayor aplicabilidad en la optimización de parámetros críticos durante la perforación.

Fase 3: Descripción de las etapas del procedimiento de perforación de pozos petroleros.

En esta etapa se documentaron y describieron las fases que componen el proceso de perforación de un pozo petrolero costa afuera. Esta caracterización fue necesaria para relacionar cada etapa con las posibles aplicaciones de las tecnologías de IA previamente identificadas.

Fase 4: Determinación del impacto de la aplicación de inteligencia artificial en la perforación de pozos petroleros costa afuera.

Finalmente, se evaluó el impacto potencial de las tecnologías de IA en la optimización de la perforación, considerando su capacidad para reducir los tiempos operacionales, disminuir la ocurrencia de tiempos no productivos y mejorar la toma de decisiones durante las operaciones costa afuera.

RESULTADOS

El estudio permitió identificar las principales tecnologías de inteligencia artificial aplicadas en la industria petrolera, caracterizar sus cualidades operativas y vincularlas con las distintas etapas del procedimiento de perforación; así mismo, el marco teórico proporcionó el sustento conceptual necesario sobre perforación offshore, tiempos operacionales e inteligencia artificial, mientras que el enfoque metodológico documental permitió analizar de manera sistemática fuentes especializadas para evaluar su aplicabilidad real. En consecuencia, los resultados y conclusiones reflejan una integración lógica y estructurada entre los elementos fundamentales de la investigación, demostrando que la inteligencia artificial constituye una herramienta viable y estratégica para la reducción de tiempos no productivos y la optimización del proceso de perforación costa afuera.

Identificación de las tecnologías de inteligencia artificial aplicadas en la industria petrolera.

El análisis bibliográfico permitió identificar tres tecnologías de inteligencia artificial ampliamente utilizadas en procesos petroleros: Machine Learning, sistemas expertos y lógica difusa.

El Machine Learning destaca por su capacidad predictiva y su eficacia en el análisis de grandes volúmenes de datos operacionales, permitiendo anticipar comportamientos del pozo, optimizar parámetros como la velocidad de penetración y detectar anomalías en tiempo real.

Los sistemas expertos fueron identificados como herramientas efectivas para apoyar la toma

de decisiones durante la perforación, gracias a su capacidad para incorporar reglas basadas en el conocimiento de especialistas e interpretar condiciones del pozo bajo incertidumbre.

La lógica difusa se evidenció como una técnica útil para manejar variables ambiguas o imprecisas, especialmente en escenarios donde los parámetros operativos no pueden definirse de forma rígida, lo cual es común en ambientes marinos complejos.

Estas tecnologías son consideradas las más aplicables para la optimización operativa debido a su capacidad de procesamiento, adaptabilidad y versatilidad.

Caracterización de las cualidades de la inteligencia artificial en perforación.

El análisis permitió determinar que la IA aporta mejoras significativas en tres áreas clave de la perforación:

Predicción operativa: los modelos de ML son capaces de prever fallas mecánicas, pérdidas de circulación, variaciones de presión y estados anómalos del equipo.

Optimización dinámica del proceso: varias fuentes coinciden en que los algoritmos pueden ajustar parámetros como el peso sobre la barrena, las revoluciones por minuto y flujo del lodo en tiempo real.

Reducción del tiempo no productivo: estudios revisados reportan disminuciones importantes de tiempos no productivos gracias al diagnóstico temprano y la automatización parcial del proceso.

Estos hallazgos demuestran que la IA posee cualidades directamente relacionadas con la mejora del rendimiento y la eficiencia de perforación.

■ **Tabla 2.** Cuadro comparativo de las herramientas de IA

CARACTERÍSTICA	MACHINE LEARNING	LÓGICA DIFUSA	SISTEMAS EXPERTOS
Distintivo	Permite a la máquina aprender patrones sin ser programada explícitamente	Maneja la incertidumbre mediante reglas basadas en grados de verdad en vez de valores binarios	Emula el razonamiento de los expertos utilizando reglas y bases de conocimiento
Aplicación en la perforación	Predicción de tiempo y anomalías	Toma de decisiones en condiciones inciertas y ajustes a tiempo real	Asistencia y diagnóstico de decisiones y problemas operativos
Manejo de datos	Datos históricos y experiencia	Respuestas flexibles a través de información imprecisa	Reglas definidas por expertos y conocimiento estructurado
Adaptación	Aumenta con respecto a la experiencia	Control y ajuste de perforación a tiempo real	Diagnóstico y asesorías en las fallas y acciones en el equipo
Modificación en costa afuera	Modelos de predicción de operaciones y optimización de actividades	Se adapta a la incertidumbre bajo reglas prediseñadas	Depende de la calidad y vigencia de la base de conocimiento principal
Ventaja principal	Adquisición de experiencia constante	Aclaración de incertidumbre	Extensión de expertos
Desventaja principal	No toma decisiones, brinda opciones	Depende de reglas bien establecidas	Falta de flexibilidad



Descripción de las etapas del procedimiento de perforación de pozos petroleros.

Del análisis documental realizado se identificó que la inteligencia artificial puede aplicarse de manera efectiva en cuatro etapas esenciales del proceso de perforación costa afuera, cada una con necesidades operativas específicas y oportunidades claras para optimizar tiempos y mejorar la eficiencia del pozo.

Planeación del pozo.

La planeación del pozo es la fase inicial del proceso de perforación, en la cual se define el diseño integral del pozo y se evalúan las condiciones geológicas, operativas y económicas del proyecto, lo cual incluye la selección de la trayectoria del pozo, la predicción de propiedades de la formación (presión de poro, gradiente de fractura, litología), la selección de brocas y herramientas, y la identificación de riesgos operacionales potenciales, asegurando que el pozo cumpla con objetivos técnicos, de seguridad y de viabilidad económica antes del inicio de las operaciones.

Durante la planeación inicial, la inteligencia artificial permite optimizar el diseño del pozo mediante el análisis predictivo de datos geológicos, históricos y operacionales. Los algoritmos de *Machine Learning* pueden generar modelos para:

- Seleccionar trayectorias óptimas del pozo,
- Anticipar propiedades de la formación,
- Estimar riesgos asociados a presiones de poro y gradientes de fractura,
- Evaluar la selección más adecuada de brocas y herramientas de perforación.

Esta etapa es crítica ya que las decisiones tomadas en esta fase de la actividad impactan directamente en los tiempos operacionales posteriores.

Preparación del área.

La preparación del área comprende todas las actividades previas a la perforación que garantizan que la ubicación y la plataforma de perforación estén

listas para operar; esto incluye la movilización de equipos, instalación de infraestructura, pruebas de sistemas de seguridad, adecuación de líneas de flujo, verificación de anclajes o posicionamiento dinámico de la plataforma, y evaluaciones ambientales y meteorológicas. Esta fase busca minimizar retrasos operativos y asegurar que todos los equipos, materiales y sistemas estén disponibles y funcionales antes de iniciar la perforación.

En esta fase, la IA contribuye a mejorar la logística, la organización y la seguridad, aportando su capacidad para:

- Predecir condiciones ambientales adversas,
- Optimizar el traslado de equipos y materiales,
- Gestionar la disponibilidad de equipos según modelos de fallas,
- Evaluar la preparación del sitio para minimizar retrasos.

Además, técnicas basadas en análisis de patrones ayudan a identificar factores que típicamente generan tiempos no productivos antes de iniciar la perforación.

Perforación del pozo.

La perforación del pozo es la etapa operativa principal, en la cual se realiza la apertura del pozo siguiendo la trayectoria diseñada. Involucra el uso de equipos rotativos, circulación de lodo, control de presión, monitoreo en tiempo real y toma de decisiones para mantener la estabilidad del pozo y avanzar de forma segura y eficiente. Durante esta fase se controlan parámetros clave como la velocidad de penetración, peso sobre la barrena, revoluciones por minuto, densidad del lodo y presión hidrostática; debido a esto, es la etapa que determina gran parte del tiempo operacional y del costo total del proyecto.

Es la etapa donde la IA muestra su mayor impacto operativo, pues sus aplicaciones incluyen:

- Control en tiempo real de los parámetros tanto del pozo como del equipo utilizado
- Predicción de eventos críticos como atascamientos y pérdidas de circulación

- Ajuste automático de parámetros mediante sistemas de control inteligente.
- Monitoreo de vibraciones y optimización del desempeño de la broca.
- Estimación dinámica de la velocidad de penetración mediante modelos predictivos.

El uso de algoritmos de Machine Learning y lógica difusa permite reducir significativamente los tiempos no productivos durante la perforación activa.

Completación de pozo.

Al ser parte de la finalización del proyecto, la completación del pozo es la etapa crucial que convierte un pozo perforado en una fuente de producción activada de hidrocarburos; de esta manera, este proceso abarca la preparación del pozo para garantizar la extracción eficiente y controlada de los hidrocarburos, combinando operaciones mecánicas, herramientas avanzadas y estrategias con enfoques adaptados a las condiciones específicas de la formación.

En esta fase, la IA puede apoyar en:

- Seleccionar configuraciones óptimas de completación,
- Predecir comportamientos de flujo para mejorar el diseño,
- Detectar condiciones anómalas durante operaciones de cementación o instalación de equipos,
- Simular el desempeño futuro del pozo para evaluar la eficiencia de la completación.

Además, la evaluación posterior a las operaciones de perforación mediante análisis inteligente permite retroalimentar modelos predictivos para operaciones futuras, contribuyendo al aprendizaje continuo del sistema.

Determinación de la optimización del proceso de perforación de pozos petroleros aplicando inteligencia artificial.

Esta etapa aborda a través de las investigaciones realizadas, como la Inteligencia Artificial (IA) mejora la eficiencia, reduce los costos y minimiza riesgos en la perforación de pozos, pero principalmente la reducción de los tiempos invertidos en las actividades de perforación. La optimización mediante IA se fundamenta en el análisis de datos en tiempo real, modelos predictivos y herramientas automatizadas que permiten decisiones más informadas durante cada fase del proceso de perforación.

Predicción y control avanzado de parámetros operativos.

Modelos basados en Machine Learning permiten predecir valores óptimos para parámetros como la velocidad de penetración, el peso sobre la barrena, las revoluciones por minuto y las propiedades del lodo. Estas predicciones facilitan realizar ajustes automáticos o semiautomáticos que mantienen el proceso dentro de rangos seguros y eficientes. La optimización continua de estos parámetros reduce el tiempo de perforación y mejora la estabilidad del pozo.

Reducción de tiempos no productivos.

La IA permite detectar patrones asociados a eventos operativos adversos tales como atascamiento de tuberías, pérdidas de circulación, presiones anómalas o vibraciones excesivas antes de que estas ocurran; esto se logra mediante algoritmos predictivos entrenados con datos históricos y sensores de monitoreo en tiempo real. Minimizar los tiempos no productivos se traduce directamente en una disminución de costos y tiempos totales de perforación.

Toma de decisiones informada y automatizada.

Los sistemas expertos integran reglas basadas en la experiencia de ingenieros y operadores, permitiendo decisiones rápidas ante condiciones cambiantes del subsuelo, logrando agilizar la interpretación de datos



complejos y reducen la dependencia exclusiva del criterio humano, especialmente en situaciones de riesgo, de esta manera, la combinación de sistemas expertos con modelos difusos mejora la capacidad de operar bajo incertidumbre geológica.

Mejora integral del desempeño del pozo.

Al optimizar el proceso de perforación desde la selección inicial de parámetros hasta la ejecución del pozo, es decir, alrededor de todas las fases de las operaciones petroleras, la IA contribuye a una perforación más uniforme, estable y controlada, lo cual se refleja en trayectorias más precisas, brocas con mayor vida útil, mejor pronóstico de desempeño y una planificación más efectiva para etapas posteriores como la completación.

CONCLUSIONES

Se determina que las tecnologías de inteligencia artificial más relevantes en la industria petrolera son el Machine Learning, lógica difusa y los sistemas expertos, teniendo cada una aplicación específica en procesos como la planificación, perforación y optimización de pozos petroleros. Estas tecnologías se destacan por su capacidad de manejar grandes volúmenes de datos en tiempo real, identificar patrones complejos y proporcionar soluciones rápidas y precisas a problemas operativos, además, su implementación refleja un enfoque hacia la transformación digital del sector, donde la integración de inteligencia artificial mejora la seguridad, reduce los costos y optimiza los tiempos de ejecución.

Se identificaron cualidades específicas de la inteligencia artificial que la hacen efectiva en perforaciones costa afuera; el Machine Learning destaca por su habilidad para realizar predicciones precisas y modelar escenarios de perforación complejos, adaptándose a datos históricos y en tiempo real, por otro lado, la Lógica Difusa sobresale en la toma de decisiones en condiciones de alta incertidumbre, característica inherente al entorno costa afuera. Entonces, ambas tecnologías

ofrecen un enfoque escalable, adaptable y eficiente, contribuyendo a la reducción de los tiempos de perforación y a la minimización de riesgos operativos en condiciones desafiantes.

El proceso de perforación costa afuera incluye etapas críticas como la preparación del sitio, la perforación del pozo, el mantenimiento del pozo y la finalización del mismo, y cada una de estas etapas puede beneficiarse significativamente del uso de inteligencia artificial; en la preparación, los modelos predictivos optimizan la selección del sitio y reducen los tiempos y costos exploratorios, durante la perforación, la IA mejora la eficiencia operativa mediante el monitoreo de parámetros en tiempo real, y en la producción y finalización, la lógica difusa ayuda a manejar escenarios inciertos, mientras que el Machine learning optimiza el diseño de los sistemas de levantamiento artificial. Estos avances han mostrado un impacto directo en la reducción de tiempos y costos asociados al proceso.

La inteligencia artificial permite optimizar el proceso de perforación al reducir significativamente los tiempos de operación mediante la automatización de tareas y la anticipación de problemas, mejorando la precisión en la toma de decisiones y minimizando riesgos y tiempos muertos durante las operaciones; por otro lado, ofrecen modelos predictivos que previenen eventos críticos como pérdidas de circulación o fallas mecánicas, y específicamente en el caso de las actividades costa afuera, la IA aborda desafíos complejos como las condiciones ambientales extremas y las altas demandas de precisión, reportando reducciones significativas en los tiempos de perforación según estudios industriales revisados, lo que respalda su aplicabilidad como herramienta estratégica para la optimización de operaciones costa afuera; Schlumberger anuncia que “Los avances recientes muestran que la aplicación de sistemas inteligentes de perforación basados en machine learning puede reducir significativamente el tiempo no productivo (NPT) en operaciones de perforación, con reportes de disminuciones de hasta un 35% al emplear modelos predictivos y automatizados para optimizar parámetros de operación y decisiones a tiempo real”.

REFERENCIAS BIBLIOGRÁFICAS

- Arias, F. (1999). *El proyecto de investigación: Guía para su elaboración*. Caracas, Venezuela: Editorial Episteme.
- Arias, F. (2016) *El Proyecto de investigación, introducción a la metodología científica*. Caracas, Venezuela: Editorial Episteme.
- Beltrán, D. (2023), *Optimización de tiempos en operaciones de intervención a pozos petroleros en el Putumayo mediante la adquisición de datos*. Bogotá, Colombia: Universidad EAN.
- Bourgoyne, A. Millheim, K. Chenevert, M. y Young, F. (1991) *Applied Drilling Engineering*. Society of Petroleum Engineers
- British Petroleum. (2025). *5 ways BP uses AI and other tech to drive performance*. BP América. https://www.bp.com/en_us/united-states/home/news/features-and-highlights/5-ways-bp-uses-ai-and-other-tech-to-drive-performance.html
- British Petroleum. (2025). *BP to deploy Palantir Technologies' AI, digital twin software to support oil and gas operations*. World Oil. <https://www.worldoil.com/news/2024/9/9/bp-to-deploy-palantir-technologies-ai-digital-twin-software-to-support-oil-and-gas-operations/>
- British Petroleum. (2025). *How BP is running offshore platforms without leaving shore*. Reservoir Simulation USA 2026 Conference News. <https://www.reservoir-simulation-conference.com/news/how-bp-is-running-offshore-platforms-without-leaving-shore>
- Calderón, Z. Calvete, F. Pérez, M. Rozo, M. Ulloa, R. Aplicaciones de las redes neuronales al estudio de yacimientos de petróleo. Santander, Colombia. Universidad Industrial de Santander. ECOPELROL
- Cerda. (2023). *Auge de la inteligencia artificial. Observatorio de riesgo para las empresas en España 3er Boletín*. https://icerda.org/wp-content/uploads/2023/09/2023_2_Boletin_OR_IA.pdf
- Chiquito, J. y Guevara, E. (2021), *Selección del sistema de levantamiento artificial para la sección 66 del campo Gustavo Galindo Velasco mediante inteligencia artificial (IA)*. La Libertad, Ecuador: Universidad Estatal Península de Santa Elena.
- Echenagucia. P. (2025), *Análisis de la inteligencia artificial aplicada a la disminución de los tiempos en la perforación de pozos petroleros costa afuera*. Maracaibo, Venezuela. Instituto Universitario Politécnico Santiago Mariño.
- Lake, L. y Mitchell, R. (2006), *Petroleum Engineering Handbook*. Society of Petroleum Engineers.
- Meza, J. (2023) *The role of artificial intelligence in the upstream of the oil industry: A review*. Colombia.
- Nnanyelu V. Schlumberger Limited (2025). *Intelligent drilling optimization systems: Using Machine Learning and Automation to Reduce Nonproductive Time and Improve Well Delivery Outcomes*. Ohio, Estados Unidos: Ohio University.
- Schlumberger Limited. *The Energy Glossary/Glosario de términos petroleros* (2024)
- Society of Petroleum Engineers (SPE) *How oil drilling works*. (S.F).

SISTEMA AUTÓNOMO INTELIGENTE PARA LA OPTIMIZACIÓN ENERGÉTICA Y REDUCCIÓN DE LA HUELLA DE CARBONO EN PROCESOS ELÉCTRICOS

“Autonomous intelligent system for energy optimization and carbon footprint reduction in electrical processes”

Edgar A. Camargo, Petróleos de Venezuela S.A. (PDVSA), (<https://orcid.org/0000-0003-3369-550X>) camargoea@pdvsa.com, Venezuela, Priscila Aguilar, Petróleos de Venezuela S.A. (PDVSA), aguilarpn@pdvsa.com, Venezuela, Jorge Ortega, Petróleos de Venezuela S.A. (PDVSA), ortegajao@gmail.com, Venezuela, Lenin Simancas, Petróleos de Venezuela S.A. (PDVSA), simancasln@pdvsa.com, Venezuela, Lice Guzmán Petróleos de Venezuela S.A. (PDVSA), guzmanlp@pdvsa.com, Venezuela y Fernando Reyes Petróleos de Venezuela S.A. (PDVSA), reyesft@pdvsa.com, Venezuela

RESUMEN

Este estudio presenta el diseño e implementación de SAIPE (Sistema Autónomo Inteligente para Procesos Eléctricos), una arquitectura basada en el modelo MAPE-K (Monitorizar, Analizar, Planificar, Ejecutar - Conocimiento) para optimizar el consumo energético y reducir la huella de carbono. El sistema integra algoritmos de aprendizaje automático, específicamente Random Forest y XGBoost, logrando una precisión de predicción de $R^2 = 0,9985$. Mediante un modelo de optimización lineal, SAIPE minimiza las emisiones de Alcance 1 (directas) asegurando al menos el 70% de la productividad operativa. Los resultados experimentales demuestran una reducción del 40,04% en emisiones industriales. El sistema utiliza datos históricos de consumo (MWh) y emisiones (tCO_2e) clasificadas en alcances 1, 2 y 3 según el GHG Protocol, incorporando ingeniería de características y validación temporal para garantizar robustez. El sistema SAIPE destacó por su capacidad para priorizar centros de alto consumo y ajustar operaciones en tiempo real. SAIPE supera propuestas previas al unificar análisis predictivo, optimización y autonomía operativa en alineación con el ODS 7. Aunque actualmente no considera incertidumbres dinámicas, se proyectan futuras extensiones para automatizar completamente el ciclo MAPE-K e integrar el análisis de emisiones de Alcance 2 y 3.

Palabras clave: Eficiencia energética; MAPE-K; Aprendizaje automático; Huella de carbono; Optimización industrial; ODS 7.

ABSTRACT

This study introduces the design and implementation of SAIPE (Intelligent Autonomous System for Electrical Processes), an innovative architecture based on the MAPE-K model (Monitor, Analyze, Plan, Execute - Knowledge) aimed at optimizing energy consumption and reducing the industrial carbon footprint. The system integrates machine learning algorithms, specifically Random Forest and XGBoost, achieving a predictive accuracy of $R^2 = 0,9985$. Through a linear optimization model, SAIPE minimizes Scope 1 emissions while maintaining at least 70% of operational productivity.

Experimental results demonstrate a 40.04% reduction in industrial emissions. The methodology utilizes historical consumption data (MWh) and emissions (tCO_2e) classified according to the GHG Protocol, incorporating feature engineering and temporal validation to ensure robustness. SAIPE stands out for its ability to prioritize high-consumption centers and adjust operations in real-time, in alignment with ODS 7. While the current model does not account for dynamic uncertainties, future extensions are planned to fully automate the MAPE-K cycle and integrate Scope 2 and Scope 3 emission analysis.

Keywords: Energy efficiency; MAPE-K; Machine learning; Carbon footprint; Industrial optimization; ODS 7.

INTRODUCCIÓN

La creciente demanda energética y su impacto ambiental representan uno de los mayores desafíos del siglo XXI, especialmente en sectores industriales y eléctricos. Este fenómeno está estrechamente vinculado a factores como la industrialización acelerada, la urbanización y la dependencia de fuentes no renovables. En 2023, el consumo global de energía alcanzó los 620 exajulios (EJ), un 2% más que el año anterior, mientras que las emisiones de CO₂ derivadas de combustibles fósiles superaron las 40,9 gigatoneladas, marcando un récord histórico (Stanford Sustainability, 2024). Estas cifras evidencian la urgente necesidad de abordar la sostenibilidad energética desde un enfoque integral.

Para cuantificar este impacto, la huella de carbono se ha consolidado como un indicador clave, permitiendo relacionar el consumo energético con las emisiones generadas. En el sector eléctrico, esta métrica no solo refleja el desempeño ambiental, sino que también sirve como base para estrategias de descarbonización, permitiendo cuantificar la cantidad de CO₂, equivalente generado por cada unidad de energía consumida, estableciendo así una relación directa entre los procesos productivos y su efecto sobre el ambiente.

La transformación hacia modelos energéticos sostenibles constituye hoy un imperativo global, impulsado por tres fuerzas convergentes: la volatilidad económica de los combustibles fósiles, la crisis climática irreversible y los compromisos multilaterales de descarbonización.

El análisis integrado del consumo energético y la huella de carbono constituye un pilar fundamental para evaluar la sostenibilidad ambiental en el sector eléctrico. Este enfoque dual no solo proporciona un marco cuantitativo riguroso para identificar oportunidades de mejora y comparar el desempeño entre unidades operativas, sino que además establece las bases científicas para desarrollar estrategias de optimización con criterios de sostenibilidad.

En este ámbito, las herramientas analíticas han adquirido especial relevancia para medir, comprender y reducir la huella de carbono asociada a los procesos

eléctricos han cobrado una relevancia significativa. Un aspecto fundamental en este esfuerzo es la precisión en el cálculo de dicha huella, dado que la elección de los factores de emisión y las metodologías de cálculo puede influir considerablemente en la exactitud y utilidad de los resultados. Según Bertolini et al. (2024) han realizado una revisión exhaustiva de estos métodos, destacando sus ventajas y limitaciones en escenarios de generación eléctrica reales.

Además, se han propuesto marcos contables que se centran en los flujos energéticos, con el objetivo de mejorar la trazabilidad de las emisiones y apoyar decisiones estratégicas de descarbonización en las redes eléctricas. Estas aproximaciones permiten una evaluación más granular de la relación entre el consumo energético y las emisiones asociadas, lo cual es crucial para el cumplimiento de las metas de neutralidad de carbono adoptadas a nivel global.

Sin embargo, persiste una brecha significativa entre los avances teóricos y su implementación operativa. Mientras investigaciones como las de Bertolini et al. (2024) y Chen et al. (2023) se enfocan en metodologías de cálculo y trazabilidad de emisiones, poco logran integrarlas en sistemas inteligentes que ajusten dinámicamente el consumo.

De manera similar Viera et al. (2023) identifican patrones de consumo, pero no establecen una conexión directa con estrategias de mitigación del impacto ambiental. Estas brechas subrayan la necesidad de un enfoque más integral que articule el análisis predictivo y la planificación operativa con los objetivos de sostenibilidad.

Ante este escenario, la presente investigación se enfoca en dos métricas fundamentales para la transición energética: el consumo eléctrico y su correspondiente huella de carbono, analizados mediante un enfoque técnico-operacional integrado. El objetivo principal consiste en desarrollar un sistema inteligente de análisis y optimización que permita a las empresas del sector: (1) diagnosticar patrones de consumo energético, (2) cuantificar con precisión su impacto ambiental, y (3) explorar estrategias de mejora tangibles.

Para materializar este enfoque, el estudio implementa un sistema inteligente que combina técnicas avanzadas en aprendizaje automático con modelos de optimización matemática, ofreciendo así un soporte decisional robusto para organizaciones que priorizan la sostenibilidad y eficiencia energética en sus operaciones.

El marco metodológico se sustenta en el ciclo MAPE-K (Monitor, Analyze, Plan, Execute – Knowledge), que estructura el sistema en cuatro componentes funcionales interrelacionados:

1. Monitoreo continuo de variables energéticas y ambientales
2. Análisis automatizado mediante algoritmos supervisados
3. Planificación optimizada basada en modelos lineales
4. Ejecución adaptativa de medidas correctivas

Las principales contribuciones de este estudio son el diseño de una arquitectura autonómica, basada en MAPE-K, diseñada específicamente para la gestión de emisiones en sistemas eléctricos y la integración de modelos de aprendizaje automático y optimización lineal como mecanismos clave para reducir la huella de carbono, preservando la productividad, a partir del análisis de datos históricos de consumo energético.

MARCO TEÓRICO Y MÉTODO

Esta sección presenta los fundamentos conceptuales y el enfoque metodológico para el desarrollo del Sistema Autónomo Inteligente para Procesos Eléctricos (SAIPE).

El desarrollo conceptual y metodológico se estructura en tres componentes fundamentales. En primer término, se establece el modelo MAPE-K como base arquitectural del sistema, examinando sus principios y mecanismos. Posteriormente, se fundamentan los aspectos teóricos del análisis de patrones temporales aplicados a series de datos energéticos. Finalmente, se detalla el diseño experimental completo, abarcando desde los protocolos de preparación de los conjuntos de datos

-tanto de consumo energético como de huella de carbono- hasta la implementación secuencial de las etapas críticas: monitoreo, análisis y planificación

Modelo MAPE-K

El modelo MAPE-K es un marco conceptual ampliamente adoptado en el diseño de sistemas auto-adaptativos y de computación autónoma. Fue desarrollado por IBM como parte de su iniciativa de “Autonomic Computing”, con el propósito de abordar la creciente complejidad en la gestión de sistemas informáticos (Kephart et al., 2003; Vizcarrondo et al., 2017).

Este modelo se estructura en cinco componentes fundamentales que posibilitan la gestión adaptativa de sistemas complejos.

La fase de monitoreo (Monitor) se encarga de observar el entorno y el sistema mediante sensores o mecanismos de adquisición de datos, recolectando información clave sobre su estado operativo. Asimismo, en la fase de análisis (Analyze), se interpretan estos datos para detectar tendencias, anomalías y desviaciones, utilizando herramientas estadísticas, modelos predictivos o de aprendizaje automático. Con base a estos análisis, la fase de planificación (Plan) diseña estrategias de adaptación, seleccionando acciones correctivas o de mejora que consideren las restricciones del sistema y sus objetivos de rendimiento mediante mecanismos que afectan directamente al sistema en tiempo real, poniéndolas en práctica en la fase de ejecución (Execute) utilizando los mecanismos seleccionados.

Asimismo, este sistema comprende una última fase denominada Conocimiento (Knowledge) que proporciona una base compartida de información que incluyen modelos, reglas, políticas y experiencias pasadas, apoyando así decisiones más informadas en cada etapa del ciclo. A continuación se desglosan de forma detallada cada una de las fases del modelo planteado (MAPE-K).

1. Monitoreo (Monitor): Esta fase se encarga de la observación del entorno y del propio sistema mediante el uso de sensores o mecanismos de

adquisición de datos. Su objetivo es recolectar información crucial sobre el estado operativo del sistema. En el contexto de este estudio, esto implica la recolección de reportes multifuentes con datos energéticos, ambientales y productivos, así como la adquisición automatizada de consumo eléctrico en unidades operativas mediante sensores de campo. Los datos clave incluyen el consumo energético en MWh, la producción de unidades y las emisiones de carbono.

2. **Análisis (Analyze):** Una vez recolectados los datos, esta fase se dedica a su interpretación para detectar tendencias, identificar anomalías o desviaciones. Para ello, se emplean herramientas estadísticas, modelos predictivos o algoritmos de aprendizaje automático.
3. **Planificación (Plan):** Basándose en los análisis realizados, esta fase se encarga de diseñar estrategias de adaptación. Se seleccionan acciones correctivas o de mejora que tienen en cuenta las restricciones del sistema y sus objetivos de rendimiento.
4. **Ejecución (Execute):** Las acciones definidas en la fase de planificación se llevan a la práctica en esta etapa, utilizando mecanismos que impactan directamente el sistema en tiempo real.
5. **Conocimiento (Knowledge):** Este componente proporciona una base de información compartida que incluye modelos, reglas, políticas y experiencias pasadas. Su función es apoyar decisiones más informadas en cada etapa del ciclo.

El modelo MAPE-K ha sido adoptado en diversas áreas, tales como sistemas distribuidos, redes inteligentes, automatización industrial, y más recientemente, en la gestión de activos de producción en el sector energético (Manusov et al., 2022; Sampaio et al., 2021; Sánchez et al., 2020). Su modularidad y su capacidad para soportar procesos de retroalimentación lo convierten en una herramienta fundamental para diseñar sistemas que pueden responder de forma autónoma y dinámica a las condiciones cambiantes del entorno.

Análisis de patrones temporales

El consumo eléctrico y sus emisiones asociadas exhiben variaciones significativas a lo largo del tiempo, influenciadas por ciclos horarios, patrones estacionales y factores operativos específicos. La observación de estas transformaciones es crucial, ya que pueden revelar información valiosa sobre el desempeño energético de los sistemas, lo que justifica la implementación de herramientas de análisis temporal como base para la toma de decisiones.

Los patrones temporales son estructuras repetitivas o tendencias que se manifiestan en datos recopilados a lo largo del tiempo. En el contexto energético, estos patrones reflejan cómo el consumo eléctrico y sus emisiones asociadas varían en función de factores cíclicos (como la hora, el día de la semana o las estaciones del año) y de las condiciones operativas o contextuales inherentes a cada sistema. La detección y el análisis de estos comportamientos permiten una comprensión profunda de las dinámicas subyacentes, la anticipación de comportamientos futuros y el desarrollo de estrategias más eficientes para la gestión energética.

En este campo, se destaca el desarrollo de técnicas de análisis de series temporales que facilitan la identificación de patrones de consumo a medida que los datos son generados, sin la necesidad de acceder a todo el historial acumulado (Viera et al., 2023; Durand et al., 2022; Aguilar et al., 2020; Manusov et al., 2022). Por ejemplo, Viera et al. (2023) han propuesto modelos dinámicos de agrupamiento específicos para flujos de datos energéticos, lo que posibilita la detección de cambios operativos o comportamientos anómalos en tiempo real.

Complementariamente, se han desarrollado algoritmos de clasificación basados en aprendizaje supervisado, como los árboles de decisión o los modelos de bosque aleatorio. Estos algoritmos no solo permiten predecir futuros estados del sistema, sino también categorizar condiciones operativas. Camargo et al. (2021) por ejemplo, han aplicado estas técnicas al modelado de sistemas industriales, demostrando su capacidad para anticipar escenarios y apoyar el diagnóstico automático de condiciones de operación.

Este tipo de análisis puede ser potenciado significativamente mediante arquitecturas inteligentes como el modelo MAPE-K, ampliamente utilizado en entornos de control autónomo. Investigaciones recientes, como las de Lacre et al. (2024), han integrado este modelo en sistemas energéticos para pozos de petróleo, combinando el monitoreo, análisis, planificación y ejecución adaptativa a través de técnicas de meta-aprendizaje

Esta arquitectura proporciona un marco teórico robusto para el desarrollo de sistemas inteligentes capaces de aprender de sus datos, adaptarse al contexto y generar acciones informadas. En conjunto, estas técnicas permiten que el sistema no solo observe y comprenda su comportamiento energético, sino que también pueda anticipar posibles desviaciones y tomar decisiones para optimizar su funcionamiento. Esta lógica se aplicará en el modelo experimental propuesto para la gestión inteligente del consumo energético y la huella de carbono.

Metodología del Sistema SAIPE

El presente estudio se fundamenta en una arquitectura basada en el modelo MAPE-K. Esta

estructura organiza el funcionamiento del sistema en un ciclo de retroalimentación continua que abarca la observación del entorno operativo, el análisis de tendencias y patrones, la generación de recomendaciones contextuales y la ejecución de respuestas operativas. Dentro de este marco, se propone el Sistema Autónomo Inteligente para Procesos Eléctricos (SAIPE), diseñado específicamente para monitorear, analizar y optimizar el consumo energético y la huella de carbono en unidades operativas del sector eléctrico.

La Figura 1, que representa la arquitectura de SAIPE, es el cimiento conceptual sobre el cual se construye todo el sistema de soporte a la toma de decisiones, adaptada al dominio de consumo energético y huella de carbono. El diseño se basa explícitamente en el ciclo MAPE-K (Monitor, Analyze, Plan, Execute–Knowledge), lo que confiere a SAIPE una capacidad intrínseca de auto-adaptación y optimización continua. Este enfoque sistémico permite a SAIPE operar como un sistema de soporte a la toma de decisiones avanzado, diseñado específicamente para el complejo dominio de la gestión del consumo energético y la huella de carbono en operaciones eléctricas.




Figura 1. Arquitectura SAIPE

Cada fase del MAPE-K está meticulosamente interconectada, apoyándose en el componente central de Conocimiento, que actúa como el repositorio y gestor de toda la información, modelos y políticas del sistema.

Durante la fase de Monitoreo, se integran dos componentes: (1) la recolección de reportes

multifuentes con datos energéticos, ambientales y productivos, y (2) la adquisición automatizada mediante sensores de campo, especialmente orientada al consumo eléctrico en unidades operativas. Estos datos alimentan el proceso con variables claves como consumo energético en MWh, producción de unidades, emisiones de carbono.

En la fase de Análisis, el sistema aplica algoritmos de aprendizaje supervisado y métodos estadísticos para (3) detectar patrones de comportamiento, y (4) estimar correlaciones entre variables, como la relación entre consumo y huella de carbono. Esta etapa incluye el desarrollo de modelos de clasificación y regresión entrenados sobre datos históricos, así como métodos de identificación de oportunidades de mejora mediante técnicas de ingeniería de características y normalización.

La Planificación se representa mediante un componente (5) que permite, a partir del conocimiento analítico generado, formular propuestas de acción. En este estudio, dicha propuesta se operacionalizó a través de un modelo de optimización lineal que ajusta el consumo energético por tipo de centro operativo, buscando minimizar la huella de carbono sin comprometer la producción mínima requerida. Esta fase transforma la información en conocimiento aplicable, proporcionando recomendaciones concretas como límites óptimos de consumo para cada unidad.

Finalmente, en la fase de Ejecución (6) se llevan a la práctica las recomendaciones definidas en la fase de planificación.

Contexto del experimento

El experimento se enmarca en el análisis del consumo energético y la huella de carbono generada en procesos eléctricos industriales de dos empresas, con el objetivo de diseñar estrategias que mejoren su sostenibilidad. Para ello, se utilizaron dos conjuntos de datos históricos de una organización que tiene varios centros operativos.

El primero comprende información operativa a nivel horario como el consumo energético en MWh, unidades producidas, costos asociados, tipo de proceso, tipo de centro, región, fuente de energía y variables temporales derivadas de la fecha (hora, día_semana, mes y trimestre).

El segundo conjunto se orienta a las emisiones de carbono, e incluye atributos como tipo de centro (tipo_centro), código operativo, centro de costo, y emisiones de gases de efecto invernadero (alcance_1_tCO2e, alcance_2_tCO2e, alcance_3_tCO2e).

Ambos datasets o grupos de datos se utilizan de forma complementaria. El primero contiene registros horarios de consumo energético y variables operativas, lo que permite analizar la dinámica del sistema, identificar patrones y construir modelos predictivos y clasificatorios. El segundo dataset, centrado en la huella de carbono, ofrece una visión detallada de las emisiones generadas por distintas unidades operativas, considerando tanto emisiones directas como indirectas.

La contabilidad de emisiones de gases de efecto invernadero sigue el marco establecido por el GHG Protocol, que distingue tres alcances operacionales:

- **Alcance 1.** Fuentes directas bajo control organizacional, incluyendo combustión estacionaria (calderas, hornos), procesos industriales y flotas vehiculares propias (World Resources Institute [WRI] & World Business Council for Sustainable Development [WBCSD], 2023).
- **Alcance 2.** Emisiones indirectas por energía adquirida, donde recientes actualizaciones metodológicas destacan la importancia de usar factores de emisión específicos por ubicación y mercado (WRI & WBCSD, 2023).
- **Alcance 3.** Emisiones indirectas de la cadena de valor, categorizadas en 15 actividades que incluyen bienes y servicios adquiridos, transporte logístico, desplazamientos laborales y uso de productos vendidos, representando típicamente el 65-85% de la huella corporativa en sectores eléctricos (Huang et al., 2022).

Conjuntos de datos

Para analizar el consumo energético en entornos industriales, se utilizó un conjunto de datos históricos sobre consumo energético compuesto por registros operativos a nivel horario. Este dataset incluye variables cuantitativas como el consumo energético (MWh), costos asociados en USD, y volumen de producción (en unidades físicas producidas por cada centro operativo).

Se incorporaron también variables categóricas que describen el contexto de cada registro, tales como el

tipo de proceso industrial (manufactura, distribución o transformación), la región geográfica de operación y la fuente de generación eléctrica utilizada (térmica, hidroeléctrica o renovable).

Este modelo de metadatos permite estructurar la información operativa de manera que cada observación refleja las condiciones de consumo y producción de una unidad operativa industrial específica en un momento determinado, sirviendo como base para el análisis temporal, el modelado predictivo y la posterior optimización del desempeño energético.

Se empleó un segundo conjunto de datos sobre huella de carbono con el propósito de cuantificar y caracterizar el impacto ambiental asociado a las operaciones eléctricas. Este dataset fue necesario para estimar la huella de carbono generada por los mismos centros operativos considerados en el análisis energético, permitiendo así una evaluación integrada del desempeño técnico-ambiental. Específicamente, el conjunto incluye emisiones de gases de efecto invernadero clasificadas en los 3 tres alcances ya descritos.

Además, incorpora atributos categóricos como región, tipo de centro y código operativo, que facilitan la asociación con los registros de consumo energético y la aplicación posterior del modelo de optimización.

Esta integración de fuentes fue clave para construir una visión completa de cómo el consumo eléctrico incide en las emisiones totales, diferenciando patrones por tipo de centro y región.

Fase de Monitoreo - Preparación de datos sobre la huella de carbono

En la fase de exploración visual de los datos sobre huella de carbono, el histograma de la variable alcance_1_tCO₂e el cual se muestra en la Figura 2, reveló una distribución no uniforme, con varios picos y una dispersión amplia. Se identificó un grupo dominante de registros con emisiones directas entre aproximadamente 50 y 60 toneladas de CO₂ equivalente, lo que sugiere que una parte significativa de los centros evaluados presenta bajos niveles de emisión en este alcance. Además, los valores se encuentran distribuidos en distintos intervalos, alcanzando hasta 140 tCO₂e, lo cual refleja una variabilidad considerable entre los registros. Esta heterogeneidad sugiere la existencia de diferentes perfiles de operación o eficiencia entre los tipos de centros, lo que resulta útil tanto para el análisis descriptivo como para futuros procesos de clasificación o segmentación.




Figura 2. Histograma de emisiones de carbono del alcance_1_tO2e (toneladas de dióxido de carbono equivalente).

Se elaboraron los histogramas de la variable alcance_2_tCO2e, correspondiente a las emisiones indirectas por consumo de electricidad e histograma de la variable alcance_3_tCO2e, correspondiente a las emisiones indirectas de la cadena de valor (como transporte, residuos, proveedores, etc.).

La Figura 3 resume la contribución relativa de cada tipo de emisión a la huella de carbono total, al presentar simultáneamente los rangos, la dispersión y los valores centrales de las variables alcance_1_tCO2e, alcance_2_tCO2e y alcance_3_tCO2e.

Se evidencia que las emisiones de alcance 1, asociadas a fuentes directas, son las de menor




Figura 3. Histograma de emisiones de carbono del alcance_1_tO2e (toneladas de dióxido de carbono equivalente).

magnitud y menor variabilidad, concentrándose en un rango estrecho y bajo. En cambio, las emisiones de alcance 2, relacionadas con el consumo de electricidad, presentan una mayor dispersión y valores intermedios, lo que sugiere diferencias más marcadas entre centros en cuanto a uso energético.

Sin embargo, es el alcance 3, que representa emisiones indirectas de la cadena de valor, el que destaca por tener tanto los valores más altos como la mayor variabilidad entre registros. Esta diferencia visual señala que el mayor peso de la huella de carbono en los centros analizados proviene de fuentes indirectas ajenas al control directo de la organización. En conjunto, la Figura 3 revela una jerarquía clara: las emisiones de alcance 3 son las que más contribuyen, seguido por el alcance 2 y finalmente el alcance 1.

Durante la fase de limpieza de datos, se aplicaron técnicas específicas para mejorar la calidad del conjunto

de datos de huella de carbono. En primer lugar, se utilizó winsorización para atenuar el efecto de valores atípicos en las variables numéricas alcance_1_tCO2e, alcance_2_tCO2e y alcance_3_tCO2e, limitando sus valores entre los percentiles 5 y 95.

Fase de Monitoreo - Preparación de datos sobre consumo eléctrico

Durante la fase de exploración de datos sobre consumo eléctrico se realizó un análisis estadístico y visual de la variable objetivo consumo_MWh, correspondiente al consumo energético por hora.

El histograma mostró una distribución aproximadamente normal, centrada en torno a los 1.000 MWh, lo que fue confirmado por la media (1000,73) y la mediana (1000,99), indicando simetría en los datos. El boxplot o gráfica de cajas permitió identificar la presencia de valores atípicos tanto por

exceso como por defecto, con un rango intercuartílico entre 867,05 MWh y 1133,91 MWh [entre primer cuartil (Q1) y tercer cuartil (Q3)].

También se observó que los valores extremos oscilan entre un mínimo de 270,59 MWh y un

máximo de 1860,37 MWh. Esta caracterización inicial sirvió para comprender la dispersión del consumo y detectar posibles comportamientos Fase de Monitoreo - Preparación de datos sobre anómalos antes del modelado (ver Figura 4)




Figura 4. Diagramas de caja - Limpieza de datos

En la fase de limpieza de datos se identificaron y trataron los valores atípicos presentes en las variables numéricas principales: consumo_MWh, costo_USD y produccion_unidades. Como se observa en los diagramas de caja (ver Figura 5), los datos originales (izquierda) presentaban numerosos outliers (valores atípicos) que podían distorsionar el análisis estadístico y el desempeño del modelo.




Figura 5. Distribución y dispersión del consumo energético (MWh)

Para entrenar y evaluar los modelos de forma objetiva, el conjunto de datos fue dividido siguiendo una estrategia basada en el tiempo, sin mezclar registros de distintas etapas. En primer lugar, los datos fueron separados en un 70% para entrenamiento y un 30% restante como conjunto temporal.

Posteriormente, ese 30% temporal se dividió por partes iguales en un conjunto de validación (15%) y un conjunto de prueba (15%). Esta división jerárquica permitió entrenar el modelo con datos históricos, ajustar sus parámetros con datos recientes, y finalmente, evaluarlo con información completamente nueva, garantizando así una evaluación realista del desempeño predictivo.

Fase de Análisis - consumo energético

El objetivo principal de esta fase fue construir y evaluar un modelo capaz de predecir el consumo energético en entornos industriales. Para ello, se implementó el algoritmo de aprendizaje supervisado Random Forest utilizando pipelines estructurados en un entorno de desarrollo en Python.

Además del modelo de regresión, se incorporó un modelo de clasificación basado en la técnica Random Forest Classifier, con el fin de categorizar el consumo energético en niveles bajo, medio y alto, definidos a partir de umbrales construidos mediante cuantiles.

Esta etapa permitió no solo generar predicciones numéricas precisas, sino también identificar patrones de intensidad en el consumo, lo cual abre posibilidades para tareas como monitoreo inteligente, generación de alertas automatizadas, y apoyo en la toma de decisiones energéticas estratégicas.

Modelo de predicción

El algoritmo de aprendizaje supervisado fue seleccionado por su capacidad para modelar relaciones no lineales y manejar variables tanto numéricas como categóricas. Con el fin de ajustar los hiperparámetros de cada modelo, se utilizó la técnica de búsqueda aleatoria RandomizedSearchCV, la cual permite explorar múltiples combinaciones posibles de manera eficiente. Esta técnica fue aplicada sobre los siguientes hiperparámetros clave:

Número de árboles (n_estimators)

Profundidad máxima de los árboles (max_depth)

Mínimo número de muestras para dividir nodos (min_samples_split)

Mínimo número de muestras por hoja (min_samples_leaf)

La Tabla 1 resume los principales hiperparámetros ajustados para cada técnica luego del proceso de optimización.

■ **Tabla 1.** Hiperparámetros seleccionados por RandomizedSearchCV

Modelo	Hiperparámetros			
	n_estimators	max_depth	min_samples_split	min_samples_leaf
Random Forest	100	20	2	1
XGBoost	120	6	3	1

La Tabla 2 muestra los valores obtenidos por el modelo en el conjunto de prueba, luego del entrenamiento.

■ **Tabla 2.** Métricas de evaluación final de los modelos

Modelo	Métricas de evaluación		
	MAE (MWh)	RMSE (MWh)	r ²
Random Forest	0,66	6,71	0,9985

Como se observa en la tabla 2, los resultados del modelo Random Forest Regressor dieron un MAE (Mean Absolute Error) de 0,66 MWh, un RMSE (Root Mean Squared Error) de 6,71 MWh, y un coeficiente de determinación r² de 0,9985.

El valor predicho (prediccion_mwh) generado por este modelo es incorporado en la fase de planificación para el cálculo del factor de emisión.

Modelo de Clasificación

Para complementar el análisis, se construyó un modelo de clasificación orientado a categorizar el consumo energético en tres niveles: alto, medio y bajo, utilizando cuantiles para segmentar la variable consumo_MWh. Esta clasificación fue integrada como una nueva variable categórica (categoria_consumo) en el conjunto de datos. Para mejorar la capacidad predictiva del modelo, se incluyeron variables temporales derivadas, como hora, día de la semana y mes, siguiendo buenas prácticas recomendadas en el análisis de series de tiempo categorizadas (Araujo et al., 2020; Géron, 2019).

El conjunto de datos fue dividido en subconjuntos de entrenamiento, validación y prueba, manteniendo la proporcionalidad entre clases mediante la técnica stratify, lo cual es esencial para evitar sesgos en modelos clasificatorios entrenados con distribuciones desbalanceadas (Hastie et al., 2009).

El modelo seleccionado fue RandomForestClassifier, optimizando sus hiperparámetros utilizando RandomizedSearchCV, explorando 50 combinaciones de hiperparámetros.

Los parámetros óptimos encontrados fueron: n_estimators=100, max_depth=10, min_samples_split=2 y min_samples_leaf=1.

El modelo final alcanzó un 100% de precisión, recall y F1-score, tanto en el conjunto de validación como en el de prueba. Estos resultados fueron confirmados mediante los informes de clasificación y las matrices de confusión.

La variable resultante categoria_consumo es incorporada en la función objetivo de la etapa de planificación, donde se definieron penalizaciones progresivas para centros de consumo medio (3%) y alto (7%), con el propósito de dirigir la optimización a reducir la huella de carbono en aquellos centros con mayor intensidad energética.

Fase de Análisis - Huella de carbono

El objetivo principal de esta fase es caracterizar el comportamiento y la distribución de las emisiones de gases de efecto invernadero asociadas a los distintos centros operativos, con el propósito de establecer criterios diferenciados para la planificación energética. Para ello, se integraron y procesaron datos de huella de carbono clasificados bajo los tres alcances definidos por el (WRI & WBCSD, 2023).

La Figura 6 ilustra visualmente la distribución de la huella total de carbono por tipo de centro y alcance. Se observa una marcada diferencia entre ambos grupos: los centros industriales no solo generan mayor cantidad total de emisiones, sino que estas se encuentran distribuidas de forma relativamente equilibrada entre los tres alcances. En contraste, en los centros comerciales, el alcance 3 representa en promedio una proporción más elevada sobre el total de emisiones, reflejando una mayor dependencia de fuentes indirectas.




Figura 6. Distribución de la huella de carbono total por tipo de centro y alcance.

Los resultados de esta fase son esenciales para la siguiente etapa del sistema MAPE-K, ya que aportan métricas que permiten evaluar el impacto ambiental de cada centro operativo según el tipo de emisiones que genera y el grado en que estas pueden ser controladas por la organización. Este análisis no solo permite saber cuántas emisiones genera cada centro, sino también identificar su perfil de emisiones dominante (alcance 1, 2 o 3), lo cual ayuda a priorizar estrategias de reducción más ajustadas a cada caso.

Fase de Planificación

En la fase de planificación, se desarrolló un modelo de optimización lineal con el objetivo de minimizar la huella de carbono total asociada al consumo eléctrico en distintos tipos de centro. Para ello, se integraron datos históricos de consumo energético y emisiones de carbono, y se calcularon los factores de emisión específicos para cada tipo de centro definidos como la razón entre la huella de carbono total acumulada (kgCO₂) (definido en la fase de análisis del modelo SAIPE) y el consumo energético predicho total (MWh) (definido en la fase de análisis del modelo SAIPE) correspondiente. Así, el factor de emisión específico está definido como:

$$f_i = \frac{H_i}{C_i} \quad [1]$$

Donde:

f_i : Factor de emisión del centro i , en kg CO₂/MWh.

H_i : Huella de carbono del centro i

C_i : Consumo energético predicho en el centro i

El factor de emisión representa la cantidad de dióxido de carbono (kgCO₂e) que se genera por cada megavatio-hora (MWh) de consumo energético en un tipo de centro. Este factor es una medida específica de impacto ambiental por unidad de energía consumida. De este modo, se puede comparar la eficiencia ambiental de cada centro y utilizar esta información en decisiones de planificación.

Función objetivo

La función objetivo es centrada exclusivamente en las emisiones de alcance 1, debido a que este tipo de emisiones son producidas directamente por fuentes controladas por las organizaciones, y hay una mayor capacidad de regulación directa desde sus operaciones internas, mediante medidas como la eficiencia energética, el mantenimiento de equipos, o el control de uso de combustibles. Por tanto, su optimización constituye un primer paso estratégico hacia la descarbonización operativa.

Específicamente, la fórmula de optimización utilizada en el modelo de planificación energética del sistema SAIPe se basa en minimizar la huella total de carbono, considerando las emisiones por tipo de centro operativo relacionadas con emisiones de alcance 1.

$$\text{Min} = \sum_{i \in T} X_i f_i f_{i(1+R_i)} \frac{1}{K_i} \quad [2]$$

Donde:

$H^{(1)}$: Sumatoria de las huellas de carbono relacionada con el alcance 1 de todos los centros (HuellaOptim).

x_i : Consumo óptimo que se desea encontrar para cada tipo de centro.

$\alpha_i(1)$: Proporción de la huella de carbono del centro i correspondiente al Alcance 1.

$R_i(c)$: Coeficiente de regulación según categoría de consumo energético estimado en secciones anteriores (bajo, medio, alto).

K_i : Criticidad operativa del centro i .

T : conjunto de centros operativos.

Con la siguiente restricción que garantizan la factibilidad operativa del modelo propuesto.

Consumo óptimo menor o igual al predicho: establece que el consumo energético optimizado para cada tipo de centro no debe superar el valor de consumo previamente estimado mediante técnicas de predicción. Esta condición permite mantener la coherencia del modelo con los datos reales y evita soluciones no realistas.

$$(0 \leq x_i \leq C_i) \quad [3]$$

El término $R_i(c)$ introduce un coeficiente de regulación ambiental basado en la categoría de consumo energético (bajo, medio o alto), y representa el esfuerzo regulatorio requerido por centro para reducir su impacto.

La función objetivo integra de manera armónica aspectos ambientales, operativos y regulatorios, permitiendo orientar la planificación energética hacia escenarios sostenibles sin comprometer la continuidad productiva. En conjunto, permiten equilibrar los objetivos ambientales con las exigencias prácticas del sistema energético. Así, el modelo no solo promueve una disminución efectiva de la huella de carbono, sino que lo hace dentro de márgenes aceptables para la operación de cada tipo de centro considerado.

RESULTADOS Y DISCUSIÓN

Análisis preliminar

Para estimar la huella de carbono de Alcance 1 se aplicó un enfoque híbrido que combina datos históricos reales con valores predichos en el contexto operativo. Este modelo permite generar estimaciones precisas, incluso cuando se dispone de conjuntos de datos limitados, pero confiables (Kumar et al., 2023).

Lo primero es capturar el comportamiento real de cada instalación, para lo cual se usa su factor de emisión específico por tipo de centro (f_i) y su consumo energético registrado. Este cálculo es basado en la metodología de monitoreo continuo de emisiones (CEMS, por sus siglas en inglés) para estimaciones empíricas (Liu et al., 2022).

Posteriormente, se incorporan los valores predichos que reflejan las condiciones particulares de cada centro para reducir emisiones (en nuestro caso, su consumo predicho anteriormente), y un factor de emisión estimado por tipo de centro, el cual se determina dividiendo la huella de carbono histórica entre el consumo energético histórico). A su vez, se usa un factor de variabilidad (γ) para considerar la incertidumbre metodológica. Finalmente, la huella de carbono se obtiene como una combinación ponderada entre su componente real (75 %) y su componente predictivo (25 %). Esta metodología integra precisión empírica y robustez predictiva, cumpliendo con los lineamientos establecidos por ISO 14064.

$$\text{HuellaEst}_i = 0.75C_i f_i + 0.25\gamma\alpha C_i f_i (1+R_i) \quad [4]$$

Donde:

$\alpha_i^{(1)}$: Proporción de la huella de carbono del centro i correspondiente al Alcance 1.

$\gamma = 1.03$ factor de variabilidad por incertidumbre

Con respecto a las variables reducción %H1 y reducción%H1vs total, se calculan como:

$$\text{Reduccion\%} = 100 \frac{(i\text{-HuellaOptim}_m)}{\text{HuellaEst}_i} \quad [5]$$

La Tabla 3 presenta los resultados del modelo de optimización bajo la condición de mantener al menos el 80% del consumo energético total predicho. Este escenario representa un punto de equilibrio entre la necesidad de reducción de emisiones y la preservación de la continuidad operativa del sistema. Se presenta 3 nuevas variables, además de la obtenida en la etapa de planificación (ver sección Fase de Planificación), las cuales son HuellaPred, Reducción%H1, Reducción%H1vsTotal, y se determinan de la siguiente manera.

■ **Tabla 3.** Resultados del modelo de optimización

Tipo de centro	Indicadores del modelo de optimización			
	HuellaEst kgCO2 (millones)	HuellaOptim kgCO2 (millones)	Reducción %H1	Reducción %H1 vs Total
Industrial	621,71	372,79	40,04	2,12

En contraste, el centro industrial mostró una reducción considerable del 40,04 % en sus emisiones de Alcance 1, aun cumpliendo con el umbral mínimo del 80 % de consumo. Esta mejora ambiental representa una disminución equivalente al 2,12 % de la huella total de carbono del centro. Si bien esta proporción puede parecer modesta desde una perspectiva global, refleja una optimización efectiva dentro del dominio específico de emisiones regulables por la organización. El resultado confirma que los centros industriales, al poseer una mayor proporción de emisiones directas y un margen de consumo más flexible, constituyen espacios más propicios para intervenciones de planificación energética orientadas a la sostenibilidad operativa.

Análisis comparativo de escenarios funcionales

La Tabla 4 presenta un análisis comparativo de dos escenarios funcionales definidos por distintos umbrales mínimos de consumo energético: 70% y 90% del total predicho. Este contraste permite evaluar cómo varía la efectividad del modelo de optimización en función de la flexibilidad operativa permitida. En el caso del centro comercial, los resultados muestran que la huella de carbono permanece constante en ambos escenarios, sin evidenciar reducciones.

Este comportamiento confirma que, incluso con mayor margen de ajuste en el escenario del 70 %, el modelo no considera viable una reducción significativa en este tipo de centro, probablemente debido al bajo impacto relativo en emisiones de Alcance 1, o por restricciones implícitas derivadas de su menor margen de maniobra energética.

■ **Tabla 4.** Resultados del modelo de optimización

% min. de cons.	Tipo de centro	Indicadores del modelo de optimización			
		HuellaEst kgCO2 (millones)	HuellaOptim kgCO2 (millones)	Reducción %H1	Reducción %H1 vs Total
70%	Industrial	621,71	248,34	60,05	3,18
90%	Industrial	621,71	497,25	20,02	1,06

En el caso del centro industrial, se observa una diferencia sustancial entre los dos escenarios. Con una exigencia mínima del 70% de consumo, la reducción de emisiones de alcance 1 alcanza el 60,05%, lo que representa un impacto del 3,18% sobre su huella total. Sin embargo, al aumentar el umbral operativo al 90%, el potencial de reducción disminuye considerablemente a un 20,02%, con una contribución relativa del 1,06% sobre la huella total. Este resultado revela que el desempeño ambiental del modelo está directamente relacionado con el grado de flexibilidad permitido en la planificación energética: cuanto mayor es el margen de reducción del consumo, mayor es la capacidad del modelo para disminuir emisiones directas. La comparación pone en evidencia que los beneficios ambientales del modelo pueden optimizarse en contextos donde sea factible operar con restricciones más agresivas de consumo energético.

Discusión general

El modelo SAIPE basado en la arquitectura MAPE-K, tiene el objetivo de guiar la toma de decisiones hacia un consumo energético más eficiente y una reducción de emisiones de carbono, sin afectar la operación mínima de los centros. SAIPE se centra en analizar el comportamiento del consumo energético de los distintos tipos de centros (comercial e industrial). Para ello, se emplearon modelos de predicción que permitieron estimar cuánta energía consumiría cada centro bajo condiciones normales.

Un modelo de clasificación categorizó los centros según su nivel de consumo (bajo, medio o alto), lo cual fue clave para definir su prioridad en la planificación.

Además, SAIPE evalúa la huella de carbono, separando las emisiones en tres alcances: directas, indirectas por consumo eléctrico e indirectas en la cadena de valor. Esto permitió determinar no solo el volumen total de emisiones, sino también el tipo predominante en cada centro, ayudando a estimar el nivel de control organizacional sobre ellas.

La fase de planificación integra estos resultados en un modelo de optimización para reducir emisiones directas (Alcance 1), redistribuyendo el consumo entre centros de manera inteligente y respetando condiciones operativas mínimas. La planificación consideró:

- Consumo predicho
- Tipo de emisiones
- Categoría de consumo
- Importancia operativa de cada centro

Así, los resultados previos definieron los criterios de optimización, permitiendo simular escenarios de reducción energética sin comprometer la operación global.

El sistema SAIPE cumple los tres criterios definidos, integrando un modelo de optimización lineal que minimiza la huella de carbono bajo restricciones de productividad, en el marco de una arquitectura adaptativa tipo MAPE-K. Esta combinación de sostenibilidad, eficiencia y autonomía operativa, aplicada al contexto eléctrico industrial, representa una contribución concreta y replicable dentro del campo de la planificación energética sostenible.

CONCLUSIONES

Este estudio presentó el diseño e implementación del sistema SAIPE, una propuesta basada en la arquitectura MAPE-K, orientada al monitoreo, análisis y optimización del consumo energético y la huella de carbono en unidades operativas del sector eléctrico. Los resultados obtenidos a lo largo de las fases experimentales demuestran la viabilidad técnica y el potencial impacto de aplicar analítica de datos y técnicas de optimización para avanzar hacia operaciones más sostenibles.

En la fase de análisis, se entrenaron modelos de aprendizaje automático, incluyendo un modelo de regresión que alcanzó un coeficiente de determinación R^2 de 0,9985 y un modelo de clasificación que obtuvo métricas perfectas (precisión y F1-score de 1.0). Durante la fase de planificación, se integraron los datos analizados en un modelo de optimización lineal que permitió reducir significativamente la huella de carbono total, manteniendo el porcentaje de productividad exigido. Los resultados evidenciaron que los centros industriales, al presentar mayores factores de emisión, deben constituirse como el foco principal de intervención para lograr impactos ambientales significativos, sin comprometer la continuidad operativa.

La propuesta del sistema SAIPE demuestra que la integración de aprendizaje automático, análisis multivariable y optimización matemática puede ofrecer soluciones efectivas para la gestión energética inteligente. Este enfoque multidimensional no solo contribuye a mejorar el desempeño ambiental de las organizaciones, sino que también se alinea con estándares ESG y con los Objetivos de Desarrollo Sostenible (ODS), particularmente el ODS 7 (energía asequible y no contaminante).

Como trabajo futuro, se propone avanzar hacia entornos de ejecución automatizada que permitan cerrar completamente el ciclo MAPE-K, dotando al sistema de capacidades autonómicas de adaptación continua.

Entre las limitaciones de este trabajo están que el sistema SAIPE, en su versión actual, se limita al análisis de datos históricos agregados y a la optimización bajo escenarios predefinidos. Tampoco se consideraron incertidumbres, estacionalidades ni posibles cambios dinámicos en los factores de emisión o en los patrones de consumo. Además, las métricas de desempeño obtenidas podrían estar sujetas a sobreajuste, dado que aún no se ha validado el sistema con datos externos o en contextos operativos reales.

Como línea de trabajos futuros, se propone avanzar hacia la automatización del ciclo MAPE-K mediante la integración de un módulo de ejecución adaptativa que permita implementar acciones correctivas en tiempo real. Esta capacidad dotaría al sistema de una autonomía operativa que lo convierta en un agente inteligente de decisión energética, respondiendo de forma dinámica a cambios contextuales o anomalías operativas.

Adicionalmente, se planea ampliar el alcance del modelo hacia dimensiones más amplias de sostenibilidad. En primer lugar, se sugiere incorporar nuevos indicadores estratégicos como métricas ESG (Environmental, Social, Governance), KPIs financieros y operativos, y criterios sobre el cumplimiento de los Objetivos de Desarrollo Sostenible (ODS), fortaleciendo así el vínculo entre eficiencia energética y gobernanza corporativa.

En cuanto al modelo de optimización, si bien este estudio centró su función objetivo en las emisiones de Alcance 1 —relativas a fuentes controladas directamente por la organización— se proyecta como línea de trabajo futuro la extensión del enfoque hacia emisiones de Alcance 2 y Alcance 3, mediante la formulación de funciones diferenciadas que consideren la naturaleza y los mecanismos de intervención aplicables a cada tipo de emisión.

REFERENCIAS BIBLIOGRÁFICAS

- Aguilar, J., Ardila, D., Avendaño, A. F., Macías, F., White, C., Gómez-Pulido, J. M., Gutiérrez de Mesa, J. A., & Garcés-Jiménez, A. (2020). An autonomic cycle of data analysis tasks for the supervision of HVAC systems of smart building. *Energies*, 13(12), 3103. <https://doi.org/10.3390/en13123103>
- Araujo, M., Aguilar, J., & Aponte, H. (2003). Fault detection system in gas lift well based on artificial immune system. *International Joint Conference on Neural Networks*, 3, 1673–1677. <https://doi.org/10.1109/IJCNN.2003.1223658>
- Bertolini, M., Dutillo, P., & Lisi, F. (2024). Accounting carbon emissions from electricity generation: A review and comparison of emission factor-based methods. *Applied Energy*, 350, Artículo 120123. <https://doi.org/10.1016/j.apenergy.2023.120123>
- Camargo, E. (2021). Modelado de pozos de producción por bombeo mecánico utilizando técnicas de computación inteligente. *Revista Técnica de la Facultad de Ingeniería Universidad del Zulia*, 12(2), 45–58. <https://www.redalyc.org/articulo.oa?id=507558897005>
- Chen, X., Chao, H., Shi, W., & Li, N. (2023). Towards carbon-free electricity: A flow-based framework for power grid carbon accounting and decarbonization [Preprint]. *arXiv*. <https://arxiv.org/abs/2308.03268>
- Durand, D., Aguilar, J., & Rodríguez-Moreno, M. (2022). An analysis of the energy consumption forecasting problem in smart buildings using LSTM. *Sustainability*, 14(20), Artículo 13358. <https://doi.org/10.3390/su142013358>
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras & TensorFlow* (2.^a ed.). O'Reilly Media.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2.^a ed.). Springer.
- Huang, Y., Patiño-Echeverri, D., & Cui, H. (2022). Comprehensive analysis of Scope 3 emissions in energy systems. *Energy Policy*, 161, 112752. <https://doi.org/10.1016/j.enpol.2021.112752>
- International Organization for Standardization. (2018). ISO 14064-1:2018 *Greenhouse gases — Part 1: Specification with guidance at the organization level for quantification and reporting of greenhouse gas emissions and removals*. <https://www.iso.org/standard/66453.html>
- Kephart, J. O., & Chess, D. M. (2003). The vision of autonomic computing. *Computer*, 36(1), 41–50. <https://doi.org/10.1109/MC.2003.1160055>
- Kumar, S., Singh, A., & Sharma, P. (2023). A novel hybrid machine learning model for prediction of CO₂ using socio-economic and energy attributes for climate change monitoring and mitigation policies. *Ecological Informatics*, 77, 102245. <https://doi.org/10.1016/j.ecoinf.2023.102245>
- Lacret, A., Camargo, E., Mendoza, E., Canelón, J., & Lacret, Y. (2024). *Intelligent autonomous system for electrical submersible well based on metalearning techniques*. Society of Petroleum Engineers. <https://doi.org/10.2118/219538-MS>
- Liu, J., Wang, Y., & Chen, H. (2022). Real-time corporate carbon footprint estimation methodology based on appliance identification. *IEEE Transactions on Industrial Informatics*, 18(8), 5354–5363. <https://doi.org/10.1109/TII.2022.3161717>
- Mahmood, H., & Blaabjerg, F. (2022). Autonomous power management of distributed energy storage systems in islanded microgrids. *IEEE Transactions on Sustainable Energy*, 13(3), 1507–1522. <https://doi.org/10.1109/TSST.2022.3156393>
- Manusov, V., Beryozkina, S., Nazarov, M., Safaraliev, M., Zicmane, I., Matrenin, P., & Ghulomzoda, A. (2022). Optimal management of energy consumption in an autonomous power system considering alternative energy sources. *Mathematics*, 10(3), 525. <https://doi.org/10.3390/math10030525>
- Sampaio, H. V., Koch, F., Westphall, C. B., Boing, R. do N., & Santa Cruz, R. N. (2021). *Autonomic management of power consumption with IoT and fog computing*. *arXiv*. <https://arxiv.org/abs/2105.03009>
- Sánchez, M., Exposito, E., & Aguilar, J. (2020). Implementing self-* autonomic properties in self-coordinated manufacturing processes for the Industry 4.0 context. *Computers in Industry*, 121, Artículo 103247. <https://doi.org/10.1016/j.compind.2020.103247>
- Stanford University. (2024). *Global carbon emissions from fossil fuels reached record high in 2023*. <https://sustainability.stanford.edu/news/global-carbon-emissions-fossil-fuels-reached-record-high-2023>
- Viera, J., Aguilar, J., Rodríguez-Moreno, M., & Quintero-Gull, C. (2023). Analysis of the behavior pattern of energy consumption through online clustering techniques. *Energies*, 16(4), 1649. <https://doi.org/10.3390/en16041649>
- Vizcarrondo, J., Aguilar, J., Exposito, E., & Subias, A. (2017). MAPE-K as a service-oriented architecture. *IEEE Latin America Transactions*, 15(6), 1163–1175. <https://doi.org/10.1109/TLA.2017.7932705>

La revista **Petrolia**, órgano divulgativo de la Universidad Venezolana de los Hidrocarburos, establece un conjunto riguroso de directrices para la consignación de manuscritos que busquen contribuir significativamente al conocimiento tecnocientífico. El propósito fundamental de esta publicación trasciende la difusión informativa, funcionando como un filtro de seguridad y motor de avance para la industria que valida y certifica el conocimiento. Mediante el arbitraje, expertos externos aseguran la calidad técnica y originalidad de las propuestas, evitando que sesgos o errores lleguen a la comunidad profesional y garantizando que cada avance se transforme en un insumo público confiable. Este rigor no solo eleva la reputación institucional al alinear el capital intelectual con estándares globales, sino que también genera un impacto tangible al servir de base para el desarrollo de patentes, nuevas normativas técnicas y análisis de uso de tecnologías que permitan la toma de decisiones estratégicas en políticas energéticas.

Dentro de las exigencias se requiere que el contenido sea original e inédito, evaluando aspectos como el valor científico, la vigencia de la información y la coherencia discursiva. Los autores interesados deben consignar, junto a su propuesta, una serie de recaudos legales y administrativos que incluyen una constancia de originalidad, una carta de acuerdo entre coautores y la cesión de derechos de difusión a la universidad.

En cuanto a la tipología de los documentos, la revista admite artículos de investigación, artículos de revisión, ensayos y reseñas bibliográficas. Cada formato posee exigencias estructurales y de extensión específicas; por ejemplo, los artículos de investigación deben seguir una estructura clásica de metodología y resultados con un límite de quince cuartillas, mientras que las reseñas bibliográficas se centran en obras recientes con una extensión máxima de dos mil palabras. Un aspecto técnico fundamental es que los archivos deben ser remitidos exclusivamente en formato de software libre ODT, cumpliendo así con la Ley de Infogobierno.

El proceso de arbitraje se rige por un sistema de doble ciego, donde tres especialistas evalúan el manuscrito de forma anónima tras una revisión preliminar del Comité Editorial. La decisión final de publicación depende de la coincidencia de al menos dos de los tres dictámenes. Respecto al formato de edición, se exige el uso de la tipografía Liberation Serif tamaño 12, con interlineado simple y márgenes de dos centímetros y medio. Los títulos deben presentarse de forma bilingüe, en castellano e inglés, al igual que el resumen y las cinco palabras clave requeridas.

Finalmente, la normativa adopta los estándares de la American Psychological Association (APA) para la gestión de citas referenciadas. Se permite un máximo de cinco coautores y se enfatiza que cualquier opinión emitida es responsabilidad exclusiva de quienes firman el trabajo. Los elementos gráficos como tablas y figuras deben insertarse en formato PNG con sus respectivas notas aclaratorias y créditos de fuente. Por último, el uso de expresiones en idiomas extranjeros está limitado a veinticinco palabras en todo el texto, asegurando así la preeminencia del castellano en el discurso académico de la revista.



PRODUCCIONEDITORIAL.UVH@GMAIL.COM

@UVHVZLA

WWW.UVH.EDU.VE