



UNIVERSIDAD ESTATAL PENÍNSULA DE SANTA ELENA

FACULTAD DE CIENCIAS DE LA INGENIERÍA

INSTITUTO DE POSTGRADO

TÍTULO DEL TRABAJO DE TITULACIÓN

**IMPLEMENTACIÓN DE INTELIGENCIA ARTIFICIAL PARA LA
PREDICCIÓN Y OPTIMIZACIÓN DEL RENDIMIENTO EN EL BLOQUE 7**

AUTOR

Hipólito Andrés Montenegro Borbor

TRABAJO DE TITULACIÓN

Previo a la obtención del grado académico en

MAGÍSTER EN PETRÓLEOS

TUTOR

Ing. Portilla Lazo Carlos Alberto, Mgtr.

Santa Elena, Ecuador

Año 2025



UPSE

**UNIVERSIDAD ESTATAL PENÍNSULA DE SANTA ELENA
FACULTAD DE CIENCIAS DE LA INGENIERÍA**

INSTITUTO DE POSTGRADO

TRIBUNAL DE SUSTENTACIÓN

**Econ. Roxana Álvarez Acosta, PhD
COORDINADORA (E) DEL
PROGRAMA**

**Ing. Carlos Portilla Lazo, Mgtr
TUTOR**

**Ing. Jaime González Maya, PhD
DOCENTE ESPECIALISTA 1**

**Ing. Marco Salcedo Arciniega, PhD
DOCENTE ESPECIALISTA 2**

**Ab. María Rivera González, Mgtr
SECRETARÍA GENERAL
UPSE**



UNIVERSIDAD ESTATAL PENÍNSULA DE SANTA ELENA

FACULTAD DE CIENCIAS DE LA INGENIERÍA

INSTITUTO DE POSTGRADO

CERTIFICACIÓN

Certifico que luego de haber dirigido científica y técnicamente el desarrollo y estructura final del trabajo, este cumple y se ajusta a los estándares académicos, razón por el cual apruebo en todas sus partes el presente trabajo de titulación que fue realizado en su totalidad por **Hipólito Andrés Montenegro Borbor**, como requerimiento para la obtención del título de Magíster en **PETRÓLEOS**

TUTOR

Ing. PORTILLA LAZO ALBERTO, Mgtr.

29 días del mes de octubre del año 2025



**UNIVERSIDAD ESTATAL PENÍNSULA DE SANTA ELENA
FACULTAD DE CIENCIAS DE LA INGENIERÍA
INSTITUTO DE POSTGRADO**

DECLARACIÓN DE RESPONSABILIDAD

Yo, Hipólito Andrés Montenegro Borbor

DECLARO QUE:

El trabajo de Titulación, “**Implementación de inteligencia artificial para la predicción y optimización del rendimiento en el Bloque 7**” previo a la obtención del título en Magíster en **PETRÓLEOS**, ha sido desarrollado respetando derechos intelectuales de terceros conforme las citas que constan en el documento, cuyas fuentes se incorporan en las referencias o bibliografías. Consecuentemente este trabajo es de mi total autoría.

En virtud de esta declaración, me responsabilizo del contenido, veracidad y alcance del Trabajo de Titulación referido.

Santa Elena, a los 29 días del mes de octubre del año 2025

EL AUTOR

Hipólito Andrés Montenegro Borbor



UPSE

UNIVERSIDAD ESTADAL PENÍNSULADE SANTA ELENA

FACULTAD DE CIENCIAS DE LA INGENIERÍA

INSTITUTO DE POSTGRADO

CERTIFICACIÓN DE ANTIPLAGIO

Certifico que después de revisar el documento final del trabajo de titulación denominado “Implementación de inteligencia artificial para la predicción y optimización del rendimiento en el Bloque 7”, presentado por el estudiante, **Hipólito Andrés Montenegro Borbor** fue enviado al Sistema antiplagio COMPILATIO, presentando un porcentaje de similitud correspondiente al 4%, por lo que se aprueba el trabajo para que continúe con el proceso de titulación.



TUTOR

Ing. PORTILLA LAZO ALBERTO, Mgtr.



**UNIVERSIDAD ESTATAL PENÍNSULA DE SANTA ELENA
FACULTAD DE CIENCIAS DE LA INGENIERÍA INSTITUTO DE POSTGRADO**

AUTORIZACIÓN

Yo, Hipólito Andrés Montenegro Borbor

Autorizo a la Universidad Estatal Península de Santa Elena, para que haga de este trabajo de titulación o parte de él, un documento disponible para su lectura consulta y procesos de investigación, según las normas de la Institución.

Cedo los derechos en línea patrimoniales de informe de investigación con fines de difusión pública, además apruebo la reproducción de este artículo académico dentro de las regulaciones de la Universidad, siempre y cuando esta reproducción no suponga una ganancia económica y se realice respetando mis derechos de autor

Santa Elena, a los 29 días del mes de octubre del año 2025

EL AUTOR

Hipólito Andrés Montenegro Borbor

AGRADECIMIENTO

Para la realización de este trabajo, debo agradecer a mis maestros de cada etapa estudiantil quienes aportaron de manera significativa para el desarrollo de cada destreza y habilidad adquirida.

Al Ing. Carlos Portilla Lazo MSc., quien ayudo a pulir este trabajo con conocimientos profundos del tema, a mis tutores de cada módulo quienes con sus enseñanzas especializadas dejaron un nuevo y útil conocimiento en mí y a las instituciones públicas y privadas quienes aportaron con información importante para el desarrollo de mi tema.

Hipólito Andrés Montenegro Borbor

DEDICATORIA

Dedico este trabajo a mi familia y amigos quienes siempre estuvieron apoyándome en cada paso hacia la excelencia académica. Ing. Juan Montenegro Muñoz MSc., mi padre, quien con su voluntad inquebrantable y amor verdadero ha sabido guiarme en cada momento de la vida, Luzmila Borbor Panchana (+), mi madre, quien fue y es un pilar importante para lograr el equilibrio familiar, mis hermanos Jhon y Marvin quienes incondicionalmente mostraron su apoyo en los momentos más difíciles.

A María Vera, mi compañera y apoyo, quien con paciencia ha soportado cada traspie y celebrado cada victoria, a mis enanos Andrés, Georgia y Lucas, quienes con cada “papi” se convierten en la razón detrás de cada esfuerzo.

Hipólito Andrés Montenegro Borbor

ÍNDICE GENERAL

INSTITUTO DE POSTGRADO	I
TRIBUNAL DE SUSTENTACIÓN.....	II
CERTIFICACIÓN	III
DECLARACIÓN DE RESPONSABILIDAD.....	IV
AGRADECIMIENTO.....	VII
DEDICATORIA	VIII
ÍNDICE GENERAL	IX
ÍNDICE DE TABLAS	XIII
ÍNDICE DE FIGURAS	XIV
RESUMEN	XV
ABSTRACT	XVI
INTRODUCCIÓN.....	17
CAPÍTULO II. MARCO TEÓRICO	21
2.1. Caracterización del bloque 7.....	21
2.2. Fundamentos de la Inteligencia Artificial.....	25
2.2.1. Historia y evolución de la inteligencia artificial.....	26
2.2.2. Aprendizaje Supervisado (Supervised Learning)	27

2.2.3.	Aprendizaje No Supervisado (Unsupervised Learning).....	27
2.2.4.	Aprendizaje por Refuerzo (Reinforcement Learning).....	28
2.2.5.	Algoritmos más utilizados en la industria energética.....	29
2.2.6.	Redes neuronales artificiales y aprendizaje profundo.....	32
2.2.7.	Machine learning vs Deep learning: ventajas y limitaciones.....	34
2.2.8.	Infraestructura y requerimientos tecnológicos para IA.....	35
2.2.9.	Bibliotecas y plataformas de desarrollo (TensorFlow, PyTorch, Scikit-learn)	37
2.2.10.	Procesamiento de datos y su importancia en la calidad del modelo.....	39
2.2.11.	Ética y sesgos en los modelos de IA aplicados a ingeniería.....	41
2.2.12.	Aplicaciones industriales comprobadas (petróleo, gas, energía, manufactura)	44
2.3.	Inteligencia Artificial en la Industria.....	45
2.3.1.	Predicción en la Industria.....	45
2.4.	Aplicación de IA en la Industria Petrolera.....	47
2.4.1.	Exploración y perforación optimizada.....	47
2.4.2.	Transformación digital en el segmento upstream.....	47
2.4.3.	Panorama general aplicado a la industria del petróleo y gas.....	48
2.4.4.	Predicción dinámica y recuperación mejorada.....	48
2.4.5.	Automatización del análisis de producción y logística.....	49

2.4.6.	Exploración y producción no convencional	49
2.4.7.	Predicción de registros geofísicos en tiempo real	50
2.5.	Modelos Predictivos en Ingeniería de Producción.....	50
2.6.	Optimización del Rendimiento con Inteligencia Artificial	54
CAPÍTULO III. METODOLOGÍA.....		57
3.1.	Contexto de la investigación.....	57
3.2.	Etapa 1: Preparación y clasificación de datos.....	57
3.3.	Etapa 2: Selección del modelo de inteligencia artificial	58
3.4.	Etapa 3: Entrenamiento y validación del modelo	58
3.5.	Etapa 4: Optimización operativa.....	58
3.6.	Etapa 5: Implementación y monitoreo en tiempo real	59
3.7.	Diseño y alcance de la investigación	59
3.8.	Tipo y métodos de investigación	60
3.9.	Población y muestra.....	60
CAPÍTULO IV. RESULTADOS Y DISCUSIÓN		61
4.1.	Casos documentados en empresas internacionales	62
4.2.	Aplicación de modelos al Bloque 7	63
4.3.	Beneficios esperados de la implementación en el Bloque 7	63
4.4.	Limitaciones identificadas	63
□	Optimización del punto de operación	67
□	Mantenimiento predictivo basado en aprendizaje automático:	68
□	Control inteligente de presión de fondo:	68

CONCLUSIONES	71
RECOMENDACIONES	73
BIBLIOGRAFÍA	75

ÍNDICE DE TABLAS

Tabla 1: Resumen comparativo entre los datos usados y proceso de aprendizaje	28
Tabla 2: Datos Base para curva de producción	64

ÍNDICE DE FIGURAS

Figura 1: Bloques del oriente ecuatoriano	22
Figura 2: Mapa de bloques petroleros del Ecuador continental	24
Figura 3: visualizador de graficos de TensorFlow	38
Figura 4: Curva de producción con IA - Bloque 7	66
Figura 5: Descripción Grafica de producción con IA.....	67

RESUMEN

El objetivo de este estudio fue examinar la posibilidad de utilizar inteligencia artificial (IA) en el Bloque 7, un área productiva petrolera del oriente ecuatoriano, con el propósito de prever y mejorar la eficiencia de producción. La IA fue considerada como una herramienta que permitió optimizar procesos, reducir costos y fortalecer la sostenibilidad ambiental. En la industria del petróleo, su aplicación facilitó la predicción del comportamiento productivos, la detección temprana de fallo operativos y la mejora en el uso de recursos energéticos. En este trabajo se examinó el uso de modelos de inteligencia artificial en la industria hidrocarburífera mediante un estudio de enfoque documental, basado en la revisión de tesis, informes técnicos y artículos científicos. Se identificaron como herramientas más relevantes los modelos híbridos de aprendizaje automático, las redes neuronales y los algoritmos de decisión, los cuales permitieron prever descensos en la producción, mejorar la eficacia del consumo energético y detectar fallos en los equipos. Los resultados mostraron que la IA tuvo el potencial de optimizar la recuperación de hidrocarburos en el Bloque 7, disminuir los costos operacionales y contribuir a la sostenibilidad ambiental, siempre que, si implementación se realizara de manera progresiva, iniciando con proyectos piloto y fortaleciendo la infraestructura de datos.

Palabras claves: Inteligencia artificial, Optimización operativa, Industria petrolera

ABSTRACT

The objective of this study was to examine the feasibility of using artificial intelligence (AI) in Block 7, a productive oil area in eastern Ecuador, to predict and improve production efficiency. AI was considered a tool that allowed for optimizing processes, reducing costs, and strengthening environmental sustainability. In the oil industry, its application facilitated the prediction of production behavior, the early detection of operational failures, and improved the use of energy resources. This paper examines the use of artificial intelligence models in the hydrocarbon industry through a documentary study based on the review of theses, technical reports, and scientific articles. Hybrid machine learning models, neural networks, and decision-making algorithms were identified as the most relevant tools, which made it possible to predict production declines, improve energy efficiency, and detect equipment failures. The results showed that AI had the potential to optimize hydrocarbon recovery in Block 7, reduce operational costs, and contribute to environmental sustainability, provided its implementation is carried out progressively, beginning with pilot projects and strengthening the data infrastructure.

Keywords: Artificial Intelligence (AI), Operational Optimization, Oil Industry / Petroleum Industry

INTRODUCCIÓN

En la industria petrolera ecuatoriana, particularmente en los campos maduros del oriente, persisten desafíos relacionados con la eficiencia productiva, la declinación de pozos y los elevados costos energéticos. En el Bloque 7 operador por EP Petroecuador en las provincias de Orellana y Sucumbíos, las operaciones presentan variaciones significativas en la producción de crudo y en el comportamiento de los sistemas de bombeo, factores que impactan la sostenibilidad técnica y económica del campo.

De acuerdo con (EP Petroecuador, 2025), el Bloque 7 que es parte del activo Coca-Payamino, alcanzó una producción superior a 20000 barriles por día (BPPD) tras la intervención de dos pozos de desarrollo, lo que representa ingresos cercanos a 1,25 millones de dólares diarios. Sin embargo, esta producción tiende a fluctuar debido al envejecimiento de los yacimientos y a la variabilidad de las condiciones operativas. A nivel nacional, la producción total al corte de 2022 fue de 398322 barriles equivalentes por día, de los cuales 390202 correspondieron a petróleo crudo y 8120 a gas asociado, evidenciando la importancia estratégica de optimizar cada barril producido (EP Petroecuador, 2022).

Los métodos convencionales de control y análisis de producción se basan en procedimientos empíricos y revisiones periódicas que no siempre logran anticipar variaciones operativas o fallas en los equipos. Esto limita la capacidad de reacción y la eficiencia del proceso productivo, especialmente en un entorno donde la disponibilidad energética y los costos de mantenimiento representan factores críticos para la competitividad (Ministerio de Energía y Minas, 2023).

En este contexto, la inteligencia artificial IA, se plantea como una herramienta estratégica para transformar la gestión productiva, permitiendo analizar grandes volúmenes de datos, reconocer patrones complejos y generar modelos predictivos capaces de anticipar tendencias

de producción o comportamientos anómalos en los pozos. Según (Andrade, 2022), la aplicación de técnicas de machine learning en campos del oriente ecuatoriano ha permitido mejorar la estimación de la producción diaria, superando las limitaciones de los modelos tradicionales. De manera similar, (Li et al., 2020) y (Santos et al., 2024) demostraron que los algoritmos de redes neuronales y modelos híbridos permiten optimizar los parámetros operativos y reducir las pérdidas en pozos maduros.

A nivel internacional, (Zhu et al., 2025) evidencian que los modelos basados en Deep Reinforcement Learning pueden ajustar de forma autónoma las condiciones de operación para maximizar la eficiencia productiva. En el ámbito local, (EP Petroecuador, 2024) ha incorporado la digitalización como eje estratégico para mejorar la toma de decisiones y modernizar los procesos operativos en sus bloques amazónicos.

Con base en estas evidencias, la presente investigación se orienta a analizar el impacto y las posibilidades de implementar inteligencia artificial en la predicción y optimización de la producción petrolera del Bloque 7, a fin de identificar estrategias tecnológicas que contribuyan a una operación más eficiente, sostenible y rentable.

Planteamiento de la investigación (Fundamentación de la investigación)

Este estudio se basa en la necesidad creciente de la industria del petróleo de adoptar tecnologías revolucionarias que ayuden a incrementar la eficiencia, la sostenibilidad y la competitividad. La inteligencia artificial está adquiriendo un papel cada vez más relevante en la industria del petróleo y gas, entre el 2015 y 2024 las publicaciones académicas crecieron en promedio un 15% anual (dos Santos Póvoas et al., 2025).

En la exploración petrolera, la combinación de big data e inteligencia artificial ha permitido la identificación automática de estructuras geológicas y el modelado más preciso de yacimientos (Feng et al., 2025), así mismo, en la fase de desarrollo de yacimientos, los algoritmos de machine learning y depp learning han mejorado la simulación de dinámica de fluidos en la caracterización de propiedades del subsuelo. Finalmente, en la gestión operativa de pozos y campos, la inteligencia artificial se aplica en el modelado predictivo, en el

monitoreo en tiempo real y en el control de procesos para optimizar la producción y la recuperación del recurso (Daramola et al., 2024).

Este trabajo busca llenar ese vacío, a través de la revisión sistemática de experiencias anteriores, el estudio de herramientas existentes y la elaboración de sugerencias concretas dirigidas al contexto ecuatoriano. Por lo tanto, la investigación no solo aportará al saber técnico, sino que también contribuirá a la creación de estrategias tecnológicas que concuerden con las metas de eficiencia energética, disminución de gastos operacionales y actualización del sector hidrocarburífero nacional.

Formulación del problema de investigación

¿De qué manera la implementación de modelos de inteligencia artificial basados en machine learning podría optimizar el rendimiento operativo del Bloque 7 a través de la predicción del comportamiento de los pozos productores y la optimización del consumo energético de los sistemas de bombeo eléctrico sumergible?

Ecuador produce aproximadamente 475000 barriles diarios de crudo. En el caso del bloque 7, recientemente reportó una producción adicional de más de 20000 barriles diarios tras la intervención de dos pozos, lo que implica una participación estimada superior al 4% de la producción nacional. Además, informes operativos muestran que varios pozos del bloque han experimentado cierres por fallas de bombas o sistemas de compresión (The Global Economy, 2023).

Estos factores evidencian que el bloque no solo tiene un papel relevante en la producción nacional, sino que también enfrenta variabilidad operativa significativa (en términos de disponibilidad, interrupciones y eficiencia de sistemas de levantamiento artificial). Por ello, se considera “clave” para la nacionalidad hidrocarburífera y representa un candidato lógico para la aplicación de tecnologías de IA que permitan predecir fallas, optimizar a sistemas productivos.

Objetivo General:

Analizar el impacto y las posibilidades de implementar inteligencia artificial para la predicción y optimización del rendimiento en el Bloque 7, con el fin de identificar estrategias tecnológicas que contribuyan a mejorar la eficiencia operativa y reducir los costos energéticos.

Objetivos Específicos:

1. Identificar los principales modelos y herramientas de inteligencia artificial utilizados en la industria petrolera para la predicción y optimización del rendimiento.
2. Analizar estudios de caso y experiencias documentadas sobre la aplicación de inteligencia artificial en contextos similares al Bloque 7, evaluando sus resultados y limitaciones.
3. Proponer recomendaciones basadas en la literatura revisada para la posible implementación de inteligencia artificial en el Bloque 7, considerando su viabilidad técnica y el contexto operativo local.

Planteamiento hipotético

La implementación de modelos de inteligencia artificial en el Bloque 7 permitiría predecir y optimizar el rendimiento operativo de forma significativa, contribuyendo a una mayor eficiencia productiva y a la reducción de costos energéticos.

CAPÍTULO II. MARCO TEÓRICO

2.1. Caracterización del bloque 7

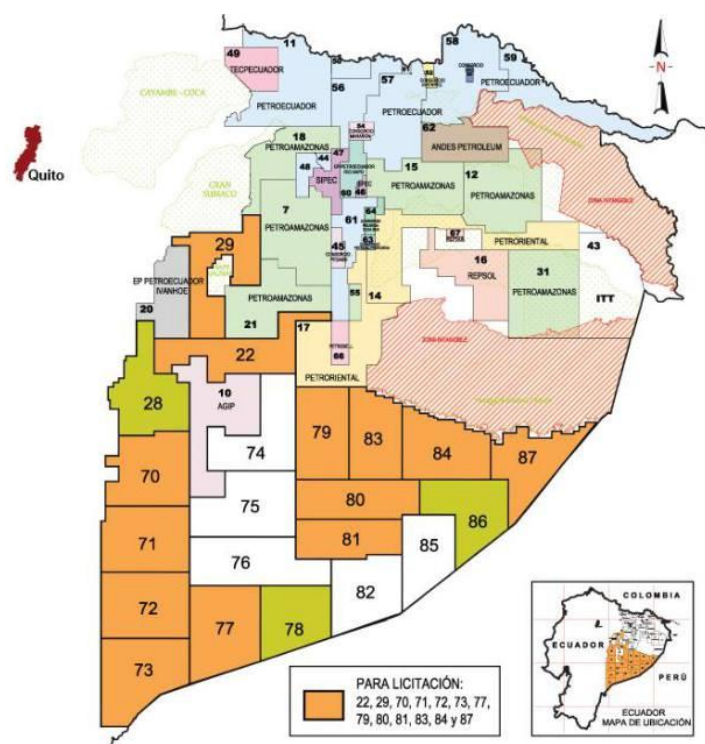
Delimitación y campos que lo integran. El Bloque 7 se localiza en la provincia de Orellana, dentro de la Cuenca Oriente, e incluye un conjunto de campos maduros entre los que destacan Coca-Payamino (CPUF), Oso, Gacela, Jaguar, Mono y Lobo. La existencia de este grupo de campos y su tratamiento regulatorio ha sido documentada en laudos y expedientes de arbitraje internacional (caso Burlington v. Ecuador), donde se identifica expresamente el Campo Unificado Coca-Payamino y los demás campos del bloque (EP Petroecuador, Bloques Petroleros, 2024).

Cifras oficiales recientes de EP Petroecuador lo listan como “Bloque 7 – Coca-Payamino”, con detalle de su producción acumulada y de los campos que lo conforman. Estas fuentes refuerzan la caracterización del bloque como un activo maduro con múltiples yacimientos que opera bajo el Estado después de que Petroamazonas se integrara a EP Petroecuador (EP Petroecuador, Bloques Petroleros, 2024).

Concesión y antecedentes históricos. Según documentos de atlas y organizaciones sectoriales, el Bloque 7 fue licitado en la segunda ronda petrolera de 1985, con British Petroleum (BP) como concesionario inicial; posteriormente, Perenco se encargó de los campos del Bloque 7 (y del adyacente Bloque 21 – Yuralpa). Estos antecedentes permiten comprender la secuencia de exploración y desarrollo, así como las sucesivas alteraciones de operador hasta la operación estatal actual. También contextualizan la relación del bloque con zonas sensibles desde el punto de vista socioambiental en el centro-norte amazónico ecuatoriano (Global Atlas, 2025).

Figura 1: Bloques del oriente ecuatoriano

Fuente: (Global Atlas, 2025)



Marco de estratigrafía geológica. Las unidades Napo (subunidad Napo U) y Hollín, propias de la Cuenca Oriente, son las responsables de la producción del Bloque 7. Los estudios académicos específicos de Coca-Payamino analizan y reportan la acumulación y el comportamiento de Napo U (agua y petróleo), así como las tácticas de gestión del corte de agua y la eficacia en la producción (Gutierrez, 2019). Por otro lado, los textos técnicos sobre Hollín caracterizan crudos con un rango que oscila entre aproximadamente 20° API (U) y cifras más altas en Hollín, presentando variaciones por azufre y procedencia, lo que afecta su levantamiento, tratamiento y transporte. Estos aportes corroboran que los reservorios son heterogéneos y que se requieren sistemas de gestión diferenciados por unidad de arena (Juez et al., 1990).

Operación ininterrumpida y producción reciente. Los informes preliminares diarios de la Agencia de Regulación y Control de Energía y Recursos Naturales No Renovables (ARCONH) indican que en 2025 el Bloque 7 (Coca-Payamino) alcanzará producciones de

aproximadamente entre 12,6 y 12,8 mil bpd, con fluctuaciones operativas a diario (paradas temporales de pozos por mantenimiento eléctrico, VSD u otras novedades). Estos reportes oficiales posibilitan establecer una línea base de producción actual y confirmar que, a pesar de su madurez, el bloque mantiene volúmenes significativos en el portafolio nacional (ARCH, 2025).

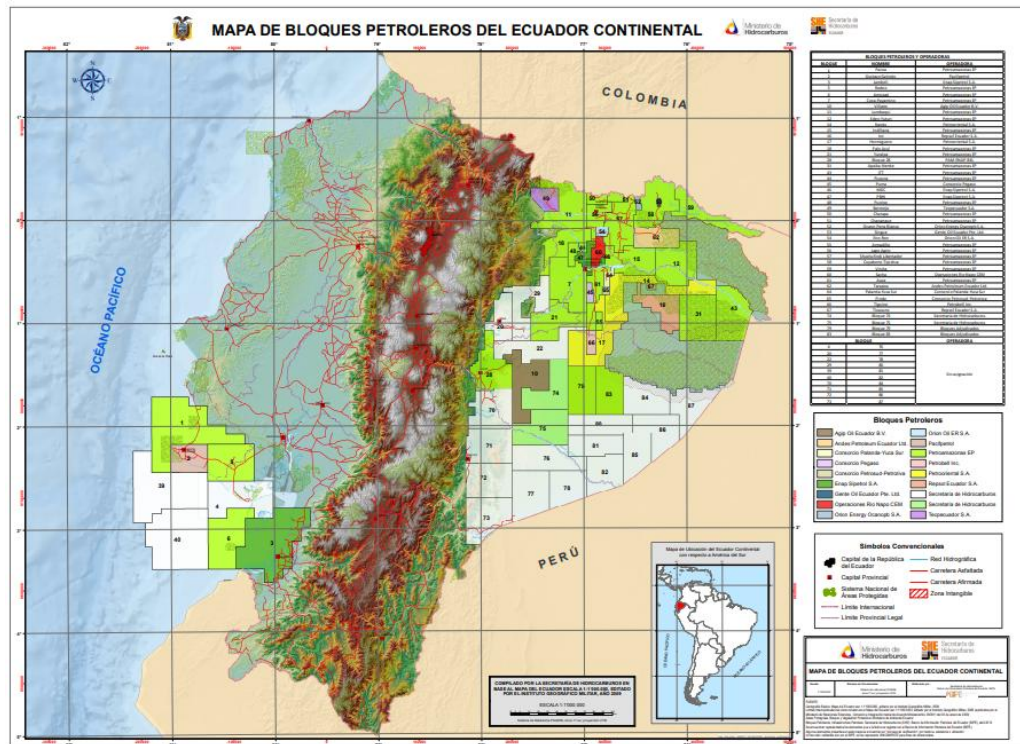
Modernización y facilidades en la superficie. Según los comunicados de la institución, se han realizado actualizaciones en la planta de tratamiento, en los sistemas de reinyección de agua y en el sistema power-oil de la Estación Coca (Campo Payamino), con inversiones millonarias. Estas medidas buscan reducir los cuellos de botella asociados con el manejo del agua y la energía, además de estabilizar el balance de fluidos y la calidad del crudo. Estos son componentes clave para lograr rentabilidad en campos con un alto BSW y garantizar el suministro al OCP/SOTE.

Recuperación secundaria e inserción de agua. El bloque está utilizando la recuperación secundaria mediante inyección de agua (en particular en Napo U del Coca-Payamino) debido a la madurez de sus areniscas productoras. Los mapas isópacos, planes de inyección y estrategias para mejorar la producción y la gestión del agua en Coca-Payamino, que se presentan en las tesis de posgrado, confirman que el recobro es un pilar técnico-económico del activo. Cuando se diseñan e implementan inyecciones utilizando criterios de balance de materia y respuesta a la presión, estos estudios académicos complementarios revelan un aumento en la productividad (Cruz, 2022).

Campo Oso: relevancia y mejora de los pozos. En el bloque, Oso se destaca como uno de los mayores contribuyentes, con decenas de pozos y desafíos característicos de los campos maduros (como la optimización de BES, la gestión del GOR y la presencia de cortes altos de agua) (Cadena y Criollo, 2016). Los trabajos académicos de EPN y ESPOL han registrado análisis nodales en los pozos de Oso, la evolución del BSW y sugerencias para mejorar (por ejemplo, escoger sistemas de levantamiento y ajustes operativos), lo que respalda el método de optimización pozo a pozo para mantener la curva de producción (Chávez, 2019).

Figura 2: Mapa de bloques petroleros del Ecuador continental

Fuente: (Ministerio de Hidrocarburos, 2015)



Medio ambiente: biodiversidad y calidad del agua. Las evaluaciones y análisis del arbitraje internacional Burlington v. Ecuador demostraron que en las áreas muestreadas de Mono, Jaguar, Gacela, Oso, Coca y Payamino (Bloque 7) se sobrepasaron los límites regulatorios. Esto condujo a la aplicación de acciones para controlar y remediar la situación. La estrategia nacional para salvaguardar el jaguar y otras herramientas de biodiversidad, por otro lado, posiciona este lugar como un paisaje con alta sensibilidad y prioridad. Esto exige protocolos estrictos para su funcionamiento, seguimiento y cierre. La necesidad de un monitoreo constante se ve reforzada por las investigaciones recientes acerca de los parámetros fisicoquímicos en los ríos Payamino y Coca (Allauca et al., 2024).

Marco institucional y rastreabilidad pública. La información pública de EP Petroecuador y la cartografía oficial de bloques petroleros del Ministerio de Energía posibilitan determinar la localización geográfica del Bloque 7, así como confirmar su operador y su composición.

Por otro lado, las estadísticas hidrocarburíferas que se publican regularmente muestran la producción por campos y empresas, lo cual es útil para auditar tendencias y poner en contexto la madurez productiva del activo en comparación con otros bloques de la Cuenca Oriente. La triangulación documental que se lleva a cabo mejora la trazabilidad técnica y ciudadana del funcionamiento del Bloque 7 .

Perspectivas técnicas de optimización. Las palancas de valor del Bloque 7 incluyen en el corto y mediano plazo: i) optimización del levantamiento artificial (por ejemplo, mejoras en BES y tecnologías de intervención/retrofit), ii) gestión hídrica (eficiencia de reinyección y disminución de BSW), iii) fiabilidad eléctrica (fallos VSD, generación y "power-oil") y iv) la selectividad de campañas en arenas Napo U/Hollín con respuesta demostrada. Tesis y reportes oficiales actuales indican que estas acciones ya se están llevando a cabo y que, incluso con un descenso natural, el bloque puede mantener una producción estable si la inversión en mantenimiento y la ingeniería de producción basada en datos continúan (Juez, 1998).

2.2. Fundamentos de la Inteligencia Artificial

La IA se fundamenta en el concepto de agente inteligente, definido como “aquello que percibe su entorno mediante sensores y actúa sobre él, mediante actuadores”, este enfoque permite describir y evaluar sistemas de IA de forma objetiva, basándose en la capacidad de lograr objetivos mediante acciones.

Un agente racional se empeña en alcanzar el mejor resultado posible de acuerdo a su saber y vivencias previas, conforme a la definición tradicional en Inteligencia Artificial. Esto transforma a la IA en una disciplina tanto de ingeniería, desde la creación de objetos útiles, como de ciencia, al buscar fundamentos que expliquen el comportamiento inteligente.

La representación de un agente como una función que traza secuencias de percepciones en acciones facilita un marco formal estricto en Inteligencia Artificial. Cada agente lleva a cabo una función que vincula secuencias de percepciones a acciones.

2.2.1. Historia y evolución de la inteligencia artificial

Desde hace mucho tiempo, la humanidad ha anhelado desarrollar inteligencias artificiales. La figura animada de Pigmalión y Talos son ejemplos de este anhelo anterior a la Revolución. Los filósofos se esforzaron por describir el pensamiento como la manipulación de símbolos, lo que estableció los fundamentos para lo que más tarde se transformaría en inteligencia artificial moderna (Agha, 2020).

Alan Turing, en 1950, estableció una pregunta operativa al proponer el Test de Turing, lo que sentó las bases para un punto de vista computacional sobre la mente humana. El término "inteligencia artificial" fue creado oficialmente en el proyecto de investigación "Dartmouth Summer Research Project on Artificial Intelligence", que se llevó a cabo en 1956, gracias a John McCarthy y otros investigadores. En este mismo evento, la disciplina comenzó a ser considerada como un campo académico independiente (Mijwil, 2015).

La evolución de la inteligencia artificial ha tenido "primaveras" (momentos de progreso) seguidas por "inviernos" (retrocesos a causa de una sobreabundancia de expectativas y financiación insuficiente), según un informe europeo. La primera primavera tuvo lugar en la década de 1950, luego otra en los años 70, una recuperación con los sistemas expertos, otro invierno en los 90 y, por último, el florecimiento del aprendizaje profundo en la década del 2010 (European Commission, 2020).

Juergen Schmidhuber, en su revisión histórica moderna, traza un hilo directo desde conceptos matemáticos como la regla de la cadena (1676), pasando por primeros modelos de redes neuronales en el siglo XIX y proyectos de aprendizaje profundo desde 1965, hasta los avances que definen el campo actual. Eric Horvitz y Tom Mitchell brindan con su trabajo más reciente una visión integral acerca de la historia,

el presente y los futuros potenciales de la IA, lo que permite fortalecer su evolución como disciplina científica y tecnología (Hall et al., 2024).

La diversidad y la complejidad del área de IA, que incluye desde el razonamiento simbólico hasta la comprensión del lenguaje y la solución de problemas (como sistemas de juego o demostración de teoremas), son destacadas en un informe emitido por la Universidad de Washington. Daniel Crevier, en su libro *AI: El libro La historia tumultuosa de la búsqueda de inteligencia artificial* explica minuciosamente los puntos clave, debates y disputas técnicas y personales que dieron forma al campo, incluyendo las enemistades e ideologías dispares dentro de la comunidad científica (Smith et al., 2006).

2.2.2. Aprendizaje Supervisado (Supervised Learning)

Este paradigma funciona mediante el uso de datos etiquetados: cada ejemplo del conjunto de entrenamiento incluye tanto la entrada como la salida deseada. El modelo aprende a asociar dichas entradas con las salidas correctas, de manera que puede generalizar a datos nuevos y sin etiquetar. Por lo tanto, su objetivo principal es predecir o clasificar nuevas observaciones gracias al aprendizaje previo de patrones explícitos (Universidad Europea, 2022).

Por ejemplo, en un sistema de clasificación de imágenes, se entrenaría con fotos cuya etiqueta (gato, perro, etc.) es conocida, lo que permite al modelo aprender a distinguir esas categorías.

2.2.3. Aprendizaje No Supervisado (Unsupervised Learning)

A diferencia del aprendizaje supervisado, aquí no hay etiquetas; el modelo debe encontrar estructuras o patrones ocultos por sí mismo. Se utilizan algoritmos como

clústeres, reglas de asociación o reducción de dimensionalidad para descubrir relaciones emergentes dentro de los datos (Olaf y Ru, 2020).

Tabla 1: Resumen comparativo entre los datos usados y proceso de aprendizaje

Elaborado por Ing. Hipólito Montenegro (2025)

PARADIGMA	DATOS UTILIZADOS	PROCESO DE APRENDIZAJE	OBJETIVO PRINCIPAL
SUPERVISADO	Datos etiquetados	Modelado de relaciones entrada–salida	Predecir o clasificar datos nuevos
NO SUPERVISADO	Datos no etiquetados	Detección de patrones o estructuras ocultas	Explorar y organizar los datos
POR REFUERZO	Retroalimentación por entorno	Aprendizaje mediante prueba y error	Maximizar recompensas acumuladas

Un ejemplo sencillo es agrupar un conjunto de frutas desconocidas basándose únicamente en sus características visuales o físicas, sin haber sido etiquetadas previamente.

2.2.4. Aprendizaje por Refuerzo (Reinforcement Learning)

Este paradigma entrena a un agente autónomo que interactúa secuencialmente con un entorno, tomando acciones, observando estados y recibiendo a cambio recompensas o penalizaciones. Mediante prueba y error, el agente aprende una

política para maximizar la recompensa acumulada a lo largo del tiempo (Murel y Kavlkoglu, 2024) .

El aprendizaje por refuerzo se diferencia claramente:

Del supervisado: no requiere etiquetas predefinidas.

Del no supervisado: no se centra en descubrir patrones, sino en optimizar una señal de recompensa (Universidad Europea, 2022).

En situaciones prácticas, como la creación de robots o los espacios virtuales (como los videojuegos), el agente aprende mediante la retroalimentación directa que recibe del ambiente, para así desarrollar estrategias eficaces que le permitan solucionar tareas de alta complejidad.

2.2.5. Algoritmos más utilizados en la industria energética

Para hacer frente a problemas de control, optimización y predicción, la industria energética ha implementado rápidamente métodos de aprendizaje automático e inteligencia artificial. Las redes neuronales recurrentes (RNN) son uno de los algoritmos más empleados, y en particular sus variantes, Gated Recurrent Unit (GRU) y Long Short-Term Memory (LSTM), que se usan extensamente en la predicción de la demanda eléctrica y en la generación renovable por su habilidad para modelar series temporales complicadas. Un análisis sistemático destaca que estos modelos "son los más utilizados en las aplicaciones de predicción energética, con particular énfasis en datos secuenciales como la carga eléctrica y el precio de la energía" (Nanjar et al., 2024).

Simultáneamente, algoritmos de aprendizaje supervisado, como los árboles de decisión, las máquinas de vectores de soporte (SVM) y Random Forest (RF), han mostrado ser métodos confiables para la predicción del consumo, el reconocimiento de fallos y la estimación de generación renovable. Se ha mencionado que "modelos

como k-NN, SVM, ANN, XGBoost y RF han tenido un buen desempeño; no obstante, LSTM es el que más se destaca por su solidez, siendo los conjuntos los que brindan la mayor estabilidad" (Alazemi et al., 2024).

Para mejorar edificios inteligentes y microredes eléctricas, donde la toma de decisiones en tiempo real es esencial, el aprendizaje por refuerzo profundo (Deep Reinforcement Learning, DRL) se ha vuelto relevante. La optimización operacional se ha visto beneficiada por la implementación de algoritmos como el Deep Q-Network (DQN), el Twin Delayed DDPG (TD3) y el Deep Deterministic Policy Gradient (DDPG) en sistemas de gestión energética para viviendas con baterías (Aysegul y Guangya, 2022).

Asimismo, en escenarios industriales más complejos, se ha explorado el aprendizaje multi-agente, donde varios controladores aprenden de forma colaborativa o competitiva para optimizar el uso de energía compartida (Zhu et al., 2022).

Se ha puesto en práctica el Reinforcement Learning seguro (Safe RL) en contextos energéticos delicados, donde la seguridad es lo más importante. Esta metodología posibilita que los agentes aprendan políticas de control óptimas sin requerir modelos físicos integrales, siempre y cuando se respeten los límites operativos para prevenir fallas graves. "El RL tiene un gran potencial en sistemas de múltiples energías, pero si se usa directamente sin adaptarse a las limitaciones físicas, puede generar interacciones inseguras", advierte un artículo especializado (Ceusters et al., 2022).

El uso de algoritmos como SARSA, Actor-Critic, DDPG y sus versiones jerárquicas de RL en la gestión de energía para automóviles híbridos y eléctricos es un campo de aplicación particularmente innovador. Estos hacen posible que la batería y el combustible se usen de manera más eficaz, lo que hace que los componentes sean más duraderos y eficientes. Un estudio reciente enfatiza que las tácticas basadas en

DRL son más efectivas que los métodos convencionales debido a que se adaptan de forma más apropiada a la dinámica no lineal de estos sistemas (Tang et al., 2024).

Sin embargo, los modelos tradicionales, como la regresión lineal o los modelos ARIMA, todavía se usan como líneas base para pronosticar energía porque posibilitan comparar la efectividad de algoritmos más complejos. Aunque estas últimas continúan siendo importantes debido a su simplicidad y capacidad de interpretación, se ha observado en varias investigaciones que los métodos de deep learning y los modelos híbridos tienen mayor precisión (Nanjar et al., 2024).

La presencia de los métodos híbridos y de ensamble (que combinan varios modelos al mismo tiempo) está creciendo en la industria energética. Por ejemplo, se consigue una mejor captura de la complejidad de los datos si se combinan las redes neuronales con Random Forest o SVM. Según un estudio de revisión, "los métodos híbridos y de ensamble son más fiables a la hora de pronosticar el consumo energético en presencia de fluctuaciones en los datos" (Sina et al., 2022).

El preprocesamiento de datos, la selección de las características y la optimización de hiperparámetros son pasos clave para crear modelos energéticos fiables. La calidad del modelo se ve fuertemente afectada por estos procesos, ya que los datos de energía con frecuencia son incompletos, desbalanceados o ruidosos. Un informe reciente señala que el éxito de los modelos depende no solo de los algoritmos, sino también de "la correcta preparación y extracción de características, así como la optimización de los parámetros del entrenamiento" (Alazemi et al., 2024).

Por lo general, la implementación del aprendizaje automático en el sector energético abarca desde la integración de energías renovables y la predicción de la carga hasta el mantenimiento predictivo de infraestructura vital y la eficacia energética en edificios. La bibliografía coincide en que estas tecnologías "tendrán un papel crucial

en la administración de la demanda, el mantenimiento predictivo y el desarrollo de energía eléctrica verde" (Aslam et al., 2025).

Las revisiones más recientes destacan que, pese a los progresos, la implementación de IA en el sector energético afronta desafíos como la interpretabilidad de modelos, la obtención de datos de calidad, la escalabilidad y el hecho de tomar decisiones en tiempo real. Para garantizar que los algoritmos sean seguros, precisos, factibles y confiables en sistemas energéticos reales a gran escala, es imprescindible superar estas restricciones (Aslam et al., 2025).

2.2.6. Redes neuronales artificiales y aprendizaje profundo

Las Redes Neuronales Artificiales (RNA) nacieron con la finalidad de emular la capacidad del cerebro humano para aprender a partir de datos, basándose en el funcionamiento de este. Desde el planteamiento de los modelos de McCulloch y Pitts (1943), quienes ofrecieron una representación matemática inicial de la neurona artificial, hasta la creación de los perceptrones por Rosenblatt en 1958, se sentaron las bases para lo que más tarde se convertiría en un área de gran relevancia tanto científica como industrial (Serna et al., 2017).

Aunque los primeros perceptrones podían solucionar problemas simples de clasificación lineal, su capacidad era limitada. La introducción del algoritmo de retropropagación del error (backpropagation) por parte de Rumelhart, Hinton y Williams en 1986 representó un progreso importante para el avance de las RNA. Al ajustar los pesos internos de acuerdo con el error en la salida, esta perspectiva permitió que se entrenaran redes multicapa. La retropropagación se volvió el estándar de entrenamiento al emplear gradientes descendentes para reducir funciones de error por medio de un proceso iterativo. Las redes lograron tratar con exactitud

problemas de reconocimiento de voz, escritura a mano y visión artificial gracias a este progreso (Rumelhart et al., 1990).

Las Redes Neuronales Convolucionales (CNN) son uno de los logros más importantes del aprendizaje profundo; estas redes se crean con el objetivo concreto de procesar datos organizados en cuadrículas, como las imágenes. La meta específica de procesar datos que están organizados en cuadrículas, como las fotografías. Utilizan filtros convolucionales para detectar patrones locales, como bordes, texturas o formas. Lo innovador de las CNN es que pueden aprender automáticamente qué filtros son adecuados para una tarea particular, lo cual elimina el requerimiento de crear a mano los detectores de características. El uso de aprendizaje basado en gradientes para reconocer documentos ha permitido que la clasificación automática de caracteres manuscritos obtenga resultados sin igual. Las CNN constituyen la base de los sistemas de reconocimiento facial, visión en vehículos autónomos y aplicaciones biomédicas en la actualidad (LeCun et al., 1998).

Aunque las CNN son las que dominan la visión por computadora, se crearon las Redes Neuronales Recurrentes (RNN) y sus variantes, como Long Short-Term Memory (LSTM), para gestionar datos secuenciales y dependencias temporales. Las RNN tradicionales padecen el inconveniente del gradiente que se apaga, lo cual las hacía ineficaces para aprender relaciones de largo alcance. Las LSTM se desarrollaron como una solución robusta mediante puertas de control, que permiten eliminar o almacenar información relevante a lo largo del tiempo. Estas arquitecturas son fundamentales para tareas como la predicción de series temporales vinculadas con energía, el reconocimiento de voz y el procesamiento del lenguaje natural. Su capacidad para "rememorar" contextos amplios las convierte en la base de los traductores automáticos y asistentes virtuales actuales (Hochreiter y Schmidhuber, 1997).

En el sector energético, se emplea el aprendizaje profundo para anticipar la demanda de electricidad y generar energía renovable. Las LSTM han incrementado considerablemente la precisión de las predicciones de series temporales relacionadas

con el consumo de electricidad; por otro lado, las CNN se utilizan para analizar imágenes de paneles solares y detectar fallas. Estas estructuras permiten anticipar variaciones en el consumo y la producción, de esta manera se optimiza la operación de microredes inteligentes y se promueve el uso de fuentes renovables intermitentes como son la eólica y la solar. Para conseguir redes eléctricas más estables y sostenibles, esta capacidad predictiva es fundamental (Goodfellow, 2016).

La falta de transparencia es uno de los principales desafíos del aprendizaje profundo y de las redes neuronales artificiales. A pesar de que los modelos pueden llegar a tener una precisión excepcional, en numerosas ocasiones actúan como "cajas negras", lo que hace complicado entender cómo se toman las decisiones. Esto es particularmente complicado en sectores delicados como el bancario, el legal o el de la salud. La relevancia de la IA explicable (XAI), que pretende proporcionar claridad y justificación a las predicciones generadas por los modelos. El estudio concluye que la interpretabilidad no es un lujo, sino una condición necesaria para una utilización responsable de la inteligencia artificial en la sociedad (Barrero et al., 2019).

Entrenar modelos de deep learning conlleva grandes costos en términos computacionales y energéticos, debido a que las redes modernas pueden contar con millones o hasta miles de millones de parámetros. Es importante que la eficiencia sea prioritaria al diseñar los algoritmos futuros, porque el impacto medioambiental de entrenar modelos masivos podría ir en contra de los propósitos de sostenibilidad de la inteligencia artificial misma. Por eso, han aparecido técnicas como la destilación, el pruning y las redes neuronales ligeras, que persiguen disminuir el tamaño y el consumo sin que se vea afectado el rendimiento (Schmidhuber, 2014).

2.2.7. Machine learning vs Deep learning: ventajas y limitaciones

Una de las grandes ventajas del Deep Learning en comparación con el ML tradicional es su habilidad para aprender representaciones. En el aprendizaje automático (ML) tradicional, es indispensable diseñar a mano las características (feature engineering);

en cambio, en el aprendizaje profundo (DL), las redes aprenden directamente de los datos y descubren patrones ocultos de manera automática (Litjens et al., 2017).

En tareas complejas y con un alto volumen de datos, como la visión por computadora, el reconocimiento de voz y el procesamiento del lenguaje natural, el DL es mejor que los algoritmos tradicionales de ML (LeCun et al., 2015).

Una desventaja clave del DL es su alta dependencia de grandes volúmenes de datos para alcanzar un buen desempeño. A diferencia de algunos algoritmos de ML clásico (como SVM o Random Forest), que pueden rendir bien con datasets pequeños, el DL necesita miles o millones de ejemplos (Schmidhuber, 2014).

2.2.8. Infraestructura y requerimientos tecnológicos para IA

La arquitectura de aceleración creada por Google, conocida como Tensor Processing Units (TPU), tiene el propósito de optimizar el cómputo en el aprendizaje automático. Estos ASICs se incorporan en centros de datos y establecen comunicación con CPUs anfitrionas por medio de interfaces veloces. El diseño posibilita una gestión eficaz de cálculos con matrices densas y disminuye notablemente la latencia en el entrenamiento e inferencia, lo cual es crucial para aplicaciones de inteligencia artificial a gran escala (Jouppi et al., 2017).

La posibilidad de evaluar uniformemente el rendimiento de los sistemas de inteligencia artificial ha sido posible gracias a la implementación de benchmarks como MLPerf Training. Este esfuerzo reúne resultados de muchos proveedores que siguen protocolos de prueba parecidos, lo que exige que la infraestructura soporte cargas pesadas de entrenamiento, utilizando optimización del hardware, memoria distribuida y pipelines eficientes (Mattson et al., 2020).

TFX (TensorFlow Extended) es una herramienta que permite implementar modelos de inteligencia artificial en entornos industriales. Incorpora elementos para la validación y consumo de datos, el entrenamiento, el despliegue y la supervisión, lo

que exige una infraestructura robusta de pipelines, orquestadores, almacenamiento con capacidad de escalado y servicios como Kubernetes para asegurar una alta disponibilidad (Baylor et al., 2017).

Ray es un marco distribuido creado para dar soporte a aplicaciones emergentes de inteligencia artificial y cuenta con una interfaz unificada para actores y tareas paralelas. Necesita una infraestructura que sea capaz de manejar clústeres con programación distribuida, que tenga una baja latencia comunicándose entre nodos y que sea tolerante a fallos para poder sostener la escalabilidad horizontal (Moritz et al., 2018).

Modelos que emplean billones de parámetros necesitan tácticas sofisticadas de memoria distribuida. ZeRO (Zero Redundancy Optimizer) facilita la distribución de parámetros, estados de optimización y gradientes entre GPUs, lo que posibilita entrenar modelos muy grandes en infraestructuras disponibles y disminuye el uso innecesario de memoria (Rajbhandari et al., 2020).

Borg es el sistema de orquestación de clústeres que ha creado Google. Este sistema gestiona cientos de miles de tareas en miles de servidores. Para aumentar la infraestructura de IA en producción, incluye políticas de asignación, monitoreo, tolerancia a fallos, contenedores y una alta densidad de cargas de trabajo mixtas.

SwitchML sugiere la agregación en red (in-network aggregation) durante el entrenamiento distribuido, lo que reduce considerablemente la carga de comunicación entre nodos y acelera la sincronización de gradientes; sin embargo, para implementarlo se necesita hardware especializado en conmutación que sea compatible con las agregaciones a nivel de hardware (Sapio et al., 2021).

El entrenamiento de modelos complejos para el procesamiento del lenguaje natural tiene una gran repercusión en términos energéticos y económicos. Se ha evaluado el volumen de energía eléctrica que demandan las instalaciones de IA y la cantidad de dióxido de carbono que generan. Por eso es esencial crear hardware eficiente,

mejorar el entrenamiento y utilizar infraestructuras con una huella pequeña (por ejemplo, los centros de datos que funcionan con energías limpias) (Strubell et al., 2019).

Tecnologías como Delta Lake, en situaciones con grandes cantidades de datos, ofrecen almacenamiento transaccional, versiones (time travel), gestión eficaz de metadatos y ACID sobre data lakes. Esto favorece la creación de pipelines de datos confiables para inteligencia artificial. Necesita sistemas de almacenamiento que sean capaces de soportar hojas de datos y registros transaccionales, por ejemplo, Parquet junto con los Delta logs (Armbrust et al., 2020).

Almacenar y proporcionar características (features) constantes entre el entrenamiento y la inferencia, así como manejar pipelines por lotes y de streaming, son algunas de las capacidades que ofrecen los feature stores, como Hopsworks. Además, promueven la reutilización y la gobernanza de datos. Necesitan una infraestructura de datos sólida que incluya APIs, almacenamiento administrado y sistemas con una alta disponibilidad (Martinez et al., 2024).

2.2.9. Bibliotecas y plataformas de desarrollo (TensorFlow, PyTorch, Scikit-learn)

TensorFlow es un sistema de aprendizaje automático que, debido a su alta escalabilidad, está creado para trabajar en ambientes diversos. Utiliza grafos de flujo de datos para representar los cálculos, en los cuales los nodos muestran operaciones y el estado compartido. Esto hace más sencillo repartir el procesamiento entre varios dispositivos y máquinas, por ejemplo CPUs, TPUs o GPUs. Su estructura arquitectónica ofrece flexibilidad y posibilita la experimentación con nuevos algoritmos de entrenamiento y optimizaciones (Abadi et al., 2016).

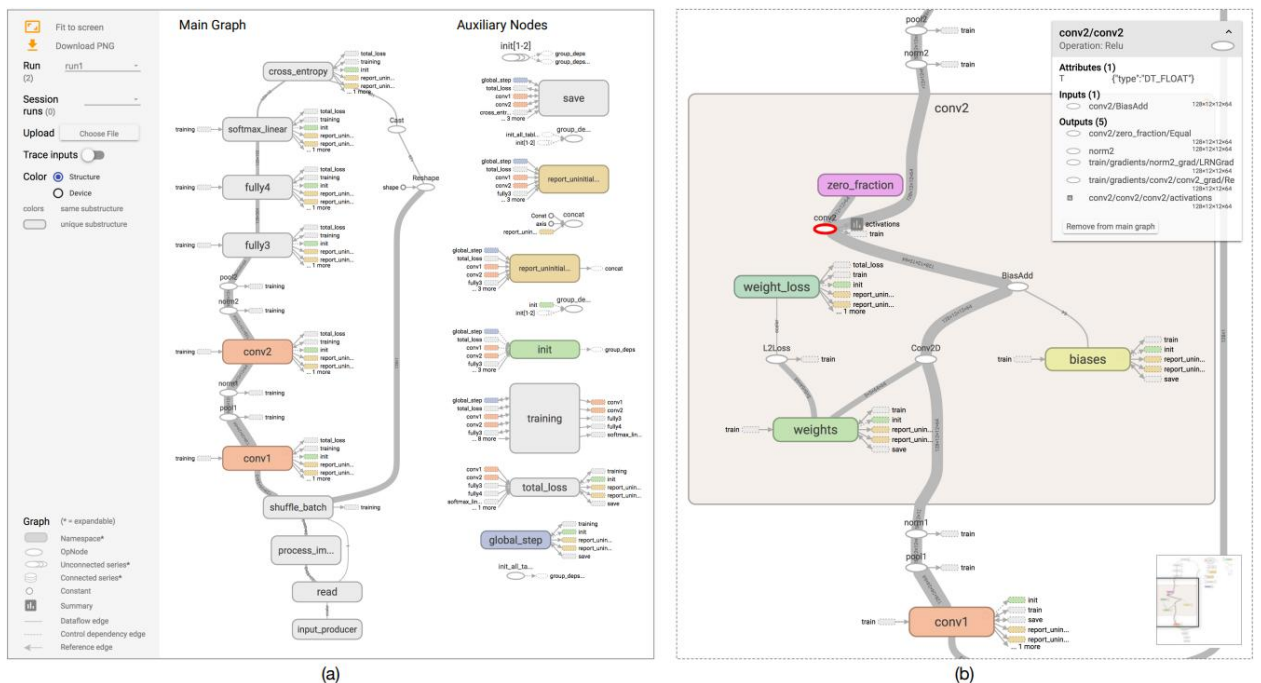
Se creó una herramienta de visualización de grafos (TensorFlow Graph Visualizer) con el fin de que las arquitecturas complejas sean más comprensibles. Esta produce representaciones interactivas de los grafos de operaciones más sofisticadas,

utilizando técnicas avanzadas de diseño gráfico que aumentan la legibilidad (Wongsuphasawat et al., 2018).

En la Ilustración 1 se muestra una red convolucional para clasificar imágenes. (a) Vista general de flujo de datos entre grupos de operaciones, con nodos auxiliares extraídos hacia un costado. (b) expansión en grupol, se muestra su estructura anidada

Figura 3: visualizador de graficos de TensorFlow

Fuente: (Wongsuphasawat et al., 2018)



PyTorch sigue un estilo "pythónico", dinámico e imperativo. De acuerdo con el documento "PyTorch: "An Imperative Style, High-Performance Deep Learning Library" prescinde de los métodos de metaprogramación de gráficos en pro de una experiencia intuitiva para la investigación, lo que permite que todos los componentes

del flujo de trabajo (definición de capas, optimización, paralelización) se expresen a través de construcciones propias del lenguaje Python (Paske et al., 2019).

PyTorch produce un nuevo grafo computacional en cada pasada hacia adelante, lo que permite una depuración más intuitiva, simplifica el flujo de control como bucles y condicionales y ofrece gran flexibilidad. Sin embargo, puede tener un costo en términos de rendimiento o memoria si se compara con grafos estáticos (Kak , 2025).

PyTorch ha incorporado herramientas como TorchDynamo, un compilador JIT de nivel Python que convierte bytecode en grafos intermedios (FX), y TorchInductor, el cual optimiza y compila esos grafos para diversos backends (por ejemplo C++/OpenMP o GPUs), fusionando versatilidad con un rendimiento elevado (Ansel et al., 2024).

En el artículo "API design for machine learning software: experiences from the scikit-learn project" (2013), los autores describen cómo eligieron un diseño de API sencillo y sofisticado: todos los estimadores tienen métodos comunes como fit() y predict(), y se integran sin dificultad con pipelines, lo que promueve la accesibilidad, la reutilización y la composabilidad en el ecosistema Python (Lars Buitinck et al., 2013).

2.2.10. Procesamiento de datos y su importancia en la calidad del modelo

El procesamiento de datos es esencial en la IA, porque actúa como un vínculo entre los datos sin procesar y los resultados confiables. Gracias a procesos tales como la limpieza, la normalización y la transformación, los datos se hacen adecuados para ser modelados; estos procedimientos incrementan la precisión y fiabilidad de los modelos. Este procedimiento es esencial para crear sistemas sólidos (Peace et al., 2024).

La efectividad de los modelos depende directamente del nivel de calidad de los datos, el cual se mide considerando su validez, puntualidad, consistencia, integridad y

precisión. Predicciones incorrectas, decisiones sesgadas o modelos débiles son consecuencia de datos deficientes (Soni et al., 2023).

Un estudio empírico examinó seis dimensiones de calidad en 19 algoritmos conocidos, analizando el impacto que tienen en el desempeño según las etapas del pipeline (entrenamiento, prueba o ambas). Se llegó a la conclusión de que cada dimensión tiene un impacto significativo, destacando así la importancia de contar con datos limpios y bien administrados (Sedir Mohammed et al., 2022).

Es necesario llevar a cabo una gestión proactiva de la calidad de los datos, como la limpieza automatizada, las auditorías y la gobernanza, para asegurar que estos sean confiables. Desde este punto de vista, la calidad de los datos es un recurso estratégico que mejora el rendimiento, la satisfacción del cliente y el beneficio competitivo (Ghorna et al., 2024).

Según la óptica actual, en vez de demorar la limpieza hasta que el modelo haya sido entrenado, es esencial priorizarla durante la fase anterior. La estructura MLClean propone una depuración de los datos unificada, lo que optimiza, desde su inicio, la precisión, equidad y solidez de los modelos (Tae et al., 2019).

Algunos de los procesos que componen el preprocesamiento son: la limpieza, la reducción, la transformación, el escalado y la partición. Estas tareas constituyen el 80% del esfuerzo de minería de datos y reflejan lo importante que son para la calidad del análisis y los modelos predictivos en circunstancias como la gestión de datos operativos en obras (Fan et al., 2021).

En contextos reales —como el IoT o la manufactura—, los datos tienen el potencial de no estar completos o de tener un balance inadecuado. El puntaje F1 de los modelos de clasificación puede mejorar considerablemente mediante el uso de

técnicas combinadas, por ejemplo, el escalado, la imputación de valores faltantes y el balanceo (por medio de GANs, por ejemplo) (Cho et al., 2022).

La visualización, en conjunto con el preprocesamiento (incluyendo la normalización y la corrección de errores), contribuye a entender las tendencias y los rasgos del conjunto de datos. Esto facilita la elección de características y la evaluación del modelo. Esto es particularmente significativo en contextos educativos o de pronosticar el rendimiento (Borodkin et al., 2023).

El modelo de inteligencia artificial centrado en los datos pone la calidad de estos al frente del flujo de trabajo. La demanda de robustez, equidad y escalabilidad sobrepasa los métodos tradicionales. Por esta razón, se están creando estándares y herramientas que garantizan la calidad en una variedad de dimensiones (Zhou et al., 2024).

Incluso en entornos empresariales, proyectos de IA pueden fracasar si los datos son incompletos, inconsistente o no están bien gobernados. El caso de Zillow fue emblemático: su modelo de valoración de viviendas falló y generó pérdidas millonarias debido a mala calidad de datos y confianza ciega en los resultados (Bansal, 2025).

2.2.11. Ética y sesgos en los modelos de IA aplicados a ingeniería

La incorporación de la IA en el ámbito de la ingeniería provoca conflictos entre lo técnico y lo humanista, pues la ética algorítmica puede entrar en contradicción con la ética humana cuando se trata de decisiones automatizadas. Esto se ve de manera especial en sistemas que tienen un impacto en la autonomía, la responsabilidad profesional o la seguridad. Según la investigación, para reducir estos conflictos se

pueden implementar auditorías éticas, equipos diversos y el "ethics by design" (Gonzalez et al., 2025).

En la industria de la construcción, ingeniería y arquitectura (AEC), la robótica y la inteligencia artificial aumentan aspectos como seguridad y productividad, pero también generan riesgos relacionados con la transparencia, la privacidad, el monitoreo, la responsabilidad en caso de fallos y la fiabilidad. El análisis lleva a cabo una revisión sistemática de estos retos y propone líneas futuras de investigación ética en este escenario (Liang et al., 2023).

En la formación de un modelo se pueden presentar sesgos en la inteligencia artificial en distintas fases: recopilación de datos, diseño algorítmico, interpretación humana y despliegue. Esto es especialmente importante en el sector de la ingeniería, dado que las decisiones automatizadas pueden tener efectos graves en términos físicos y sociales, como el mal diseño o la errónea interpretación de los datos (Ferrara, 2023).

El que los sistemas de IA no sean explicables dificulta la detección y corrección de sesgos, lo cual socava la confianza en campos delicados como medicina, ingeniería crítica o justicia. Para asegurar responsabilidad y equidad en las decisiones automatizadas, se requieren métodos que posibiliten la transparencia explicativa (Ferrara, 2023).

La UNESCO y otras organizaciones han definido principios fundamentales para una IA segura y equitativa, tales como la protección, la proporcionalidad, la seguridad, la inocuidad y la equidad. Con el fin de que la tecnología respete los derechos humanos y promueva un acceso inclusivo sin perpetuar las discriminaciones, estos principios son fundamentales para ingenierías responsables. Para resolver los prejuicios en la inteligencia artificial, es fundamental que colaboren ingenieros, sociólogos, juristas y especialistas en ética. Desde un punto de vista

interdisciplinario, se percibe que la técnica no es suficiente por sí sola: son necesarios marcos normativos, educación ética y gobernanza con inclusión (Ferrer et al., 2021).

Un experimento con millones de predicciones demostró que los prejuicios se originan sobre todo en los datos de entrenamiento. No obstante, el hecho de que esos datos sean de buena calidad también estimula a los desarrolladores a progresar: cuando son mejores los datos, los ingenieros se esfuerzan más en ser eficientes y éticos (Cowgill et al., 2020).

La inteligencia artificial, que incluye modelos generativos, tiene la capacidad de reproducir y aumentar estereotipos sociales, lo cual puede perjudicar a individuos en función de su raza, género o clase. En el ámbito de la ingeniería, esto podría manifestarse en sistemas que afectan negativamente a los grupos vulnerables, como la evaluación de proyectos, la contratación o la automatización. Para reducir estos riesgos, se aconsejan métodos éticos, transparencia y datos variados (Ferrara, 2023).

En áreas sensibles como la selección automatizada, la inteligencia artificial ha hecho distinciones con base en el color de piel, el género o la apariencia. Estos casos muestran que los sistemas tienen el potencial de reproducir inequidades históricas y tomar decisiones injustas si no hay diversidad en los grupos de desarrollo y estándares éticos definidos (Chen Z. , 2023).

Para implementar la inteligencia artificial en ingeniería de manera ética, es necesario que se tomen medidas específicas (Gonzalez et al., 2025):

- Desde el comienzo, diseñar con "ética por diseño".
- Realizar auditorías éticas de manera constante a lo largo del ciclo de vida del sistema.
- Asegurar la diversidad en los equipos de desarrollo.
- Promover la transparencia, la rendición de cuentas y la capacidad de explicar.

- Implementar normas internacionales (como las de la UNESCO) que fomenten la seguridad y la equidad (Benneh, 2023).

2.2.12. Aplicaciones industriales comprobadas (petróleo, gas, energía, manufactura)

La inteligencia artificial (IA) ha revolucionado la exploración y producción en el sector petrolero por su habilidad para procesar datos geológicos y sísmicos con más exactitud que los métodos convencionales. Los algoritmos de aprendizaje profundo posibilitan el reconocimiento de yacimientos de hidrocarburos escondidos y la mejora de los planes de perforación, lo cual disminuye los gastos y eleva el porcentaje de aciertos en hallazgos. Se emplean estos mismos métodos para la detección de petróleo residual en campos maduros y para la predicción dinámica de producción, lo que mejora la eficiencia y reduce el riesgo operativo (Li et al., 2020).

La inteligencia artificial se utiliza en trabajos de perforación y desarrollo para examinar datos en tiempo real y registros de pozos, a través del uso de redes neuronales recurrentes (RNN) y modelos de memoria a largo plazo (LSTM). Estas estructuras permiten anticipar cambios en la permeabilidad, la presión de formación y la porosidad, lo cual reduce los eventos de "blowouts" y las pérdidas de control del pozo. Se ha mostrado que la productividad en áreas complejas aumenta y que la seguridad operacional mejora tras la adopción de estas herramientas (Santos et al., 2025).

La conservación predictiva de maquinaria petrolera, como válvulas de superficie, bombas sumergibles eléctricas y compresores, es otro campo crucial. Con la ayuda de modelos de clasificación y de redes neuronales convolucionales (CNN), la inteligencia artificial examina las vibraciones, el ruido y la temperatura de los equipos con el fin de determinar averías que están por ocurrir y calcular la vida útil que queda (RUL). Así, se disminuyen los tiempos de inactividad no programados y

se mejora la eficiencia operacional (Latrach, Application of Deep Learning for Predictive Maintenance of Oilfield Equipment, 2020).

Además, los drones con algoritmos de aprendizaje automático y la visión artificial se han vuelto instrumentos esenciales para la inspección de oleoductos. Estos sistemas posibilitan la detección de fugas, corrosión o alteraciones en la estructura sin poner al personal en áreas peligrosas. En la realidad, se ha demostrado que estas soluciones optimizan la seguridad industrial, disminuyen los gastos de inspección y mejoran la respuesta ante incidentes (Hammood et al., 2021).

2.3. Inteligencia Artificial en la Industria

La Inteligencia Artificial (IA), es definida como sistemas capaces de simular procesos cognitivos, las IAs han irrumpido en la industria al integrarse con el IIoT, robótica y análisis de big data para crear fábricas inteligentes (Galo et al., 2023). Esta nueva tecnología de IA posibilita la transformación del control y mejora del rendimiento mediante sistemas adaptivos en tiempo real (Quintero et al., 2025).

2.3.1. Predicción en la Industria

La predicción por IA utiliza información de sensores instalados en las maquinarias para prever errores y prevenir paradas imprevistas. A través de la inteligencia artificial, se pueden modelar probabilidades de fallo basándose en variables tales como vibración, temperatura, velocidad o desgaste, lo cual mejora los tiempos de recursos en el mantenimiento reactivo o basado en horarios establecidos (Ibrahim, 2022).

Los sistemas de predicción combinan el aprendizaje supervisado con el no supervisado para determinar la vida útil residual y para identificar anomalías. Estas técnicas permiten detectar patrones inusuales antes de que causen daños significativos (Iftikhar et al., 2022).

Estos sistemas facilitan una arquitectura en la que los sensores recolectan información en tiempo real, la cual se envía a la nube o a la periferia para su procesamiento a través de algoritmos de Inteligencia Artificial. Por lo tanto, se logra una supervisión constante y alertas tempranas cuando se identifica una degradación o conducta no correcta (Iftikhar et al., 2022).

La industria del petróleo emplea sensores (temperatura, vibración, presión) en dispositivos esenciales para aplicar modelos de Inteligencia Artificial y aprendizaje profundo, previniendo fallos con suficiente anticipación. Por ejemplo, una reciente investigación titulada "Inteligencia artificial para la conservación predictiva en operaciones de petróleo y gas" detalla cómo las alertas anticipadas disminuyen significativamente los periodos de inactividad y los gastos operacionales (Shankar, 2024). Este método combina técnicas de aprendizaje profundo con análisis multivariable, teniendo en cuenta modelos de aprendizaje histórico y situaciones en tiempo real. Asimismo, otra investigación establece que la aplicación de ciencia de datos e inteligencia artificial ha llevado a "una programación ideal de mantenimiento y una predicción más precisa de las fallas del equipo" (Ohelete et al., 2023). Se destacan frameworks que integran IoT, sensores en miles de activos, y plataformas de análisis para mejorar la fiabilidad en refinerías y plataformas offshore.

Un esquema conceptual sugerido por Abhinav Balasubramanian fusiona sistemas PLC y SCADA con Inteligencia Artificial para posibilitar el mantenimiento predictivo y la automatización de procesos en tiempo real (HubTechia, 2025). El sistema emplea sensores conectados a SCADA, feedback constante y modelos de ML entrenados para anticipar el tiempo de fallo y cambiar automáticamente los parámetros operativos. Según los autores, esta integración "significa un cambio de paradigma", ya que permite mejorar la fiabilidad de los equipos y reducir los riesgos humanos y medioambientales. Las métricas incluyen la precisión de la predicción,

el tiempo necesario para prever las fallas y las optimizaciones en la eficiencia operacional (Abhinav, 2018).

Las técnicas de inteligencia artificial y redes neuronales se están utilizando para calcular la tasa de producción en depósitos de petróleo. En el caso de Volve en Noruega, modelos de regresión (Gradient Boosting, LightGBR, XGBoost) consiguieron anticipar volúmenes futuros con un error inferior, disminuyendo así los costos operativos y ambientales (Samad et al., 2025). Otro estudio enfocado en el pronóstico de producción utiliza LSTM y TCN-GRU, incluyendo métodos de disminución de dimensionalidad y mecanismos de atención para incrementar la exactitud (Fan et al., 2024).

2.4. Aplicación de IA en la Industria Petrolera

2.4.1. Exploración y perforación optimizada

La exploración y perforación de petróleo ha sido transformada por la inteligencia artificial, en particular a través de las redes neuronales artificiales (ANN), ya que estas han disminuido los costos operativos y el tiempo improductivo. Clasificadas en categorías como perforación, exploración, producción y gestión de yacimientos, estas técnicas posibilitan el procesamiento de grandes cantidades de datos geológicos y sísmicos con el fin de determinar las zonas más adecuadas para la perforación y mejorar los planes de desarrollo (Alkinani et al., 2019).

2.4.2. Transformación digital en el segmento upstream

La digitalización de la industria de petróleo ha introducido sistemas de inteligencia artificial en el sector upstream, especialmente durante la exploración, perforación y producción. Mediante algoritmos de aprendizaje automático, es posible simular diversas situaciones en las que se estima la productividad esperada, los costos y los riesgos técnicos, lo cual disminuye la dependencia en la experiencia subjetiva de los ingenieros. Las investigaciones prospectivas indican que, en el lapso de 10 a 20

años, la inteligencia artificial (IA) posibilitará operaciones prácticamente autónomas en plataformas offshore, incluyendo perforación automatizada y evaluación en tiempo real de las características del pozo, así como toma de decisiones sin necesidad de intervención humana. Sin embargo, para conseguir esta transformación total todavía hay retos vinculados con la calidad de los datos, la interoperabilidad de los sistemas y el entrenamiento del personal. Esto implica que la adopción de la IA tenga que ir acompañada de modificaciones culturales y organizativas en las empresas petroleras (Koroteev y Tekic, 2020).

2.4.3. Panorama general aplicado a la industria del petróleo y gas

Numerosos análisis sistemáticos realizados en años recientes han indicado que la inteligencia artificial no es meramente un instrumento adicional, sino una tecnología esencial para afrontar los desafíos de la industria petrolera en el siglo XXI. Su aplicación comprende desde la identificación de prospectos en etapas iniciales hasta la mejora de las refinerías en downstream. Entre los principales obstáculos que se presentan están la necesidad de datos masivos de buena calidad y la carencia de explicaciones sobre los modelos de caja negra. Esto restringe su aprobación en procedimientos donde las decisiones tienen que ser justificadas. Aun así, gracias a la IA, las compañías han podido obtener aumentos en la eficiencia productiva que oscilan entre el 5 % y el 15 %, lo que equivale a millones de dólares en ahorros anuales para una industria de gran magnitud. La adopción gradual de inteligencia artificial en el sector del petróleo y el gas, que ya es una tendencia irreversible, determinará la competitividad en las próximas décadas (Santos et al., 2025).

2.4.4. Predicción dinámica y recuperación mejorada

Uno de los progresos más relevantes de la inteligencia artificial en el sector del petróleo es su aplicación en la predicción dinámica de producción y en la mejora del proceso de extracción de hidrocarburos. Los algoritmos, al examinar datos de temperatura, presión, corte de agua y comportamiento productivo en el pasado, pueden producir curvas de declinación con más precisión que los modelos

convencionales. La inteligencia artificial posibilita detectar áreas con petróleo residual en campos maduros, lo que hace más fácil decidir si se inyectan polímeros, agua o CO₂ para alargar la vida del yacimiento. Las pruebas realizadas han evidenciado que los errores de las predicciones basadas en deep learning se reducen hasta un 20 % con respecto a los métodos convencionales, lo cual supone una significativa mejora en la administración de activos (Li et al., 2020).

2.4.5. Automatización del análisis de producción y logística

La IA ha posibilitado la automatización de procedimientos que antes demandaban mucho tiempo y personal en la etapa de producción. En la actualidad, los sensores de IoT que están conectados a algoritmos de aprendizaje automático registran información sobre caudal, presión y composición de fluidos en pozos. Posteriormente, estos datos son analizados para identificar anomalías y prever tendencias. Esto posibilita la modificación en tiempo real de la apertura de válvulas, la programación del transporte por oleoductos y la configuración de las bombas. La IA asiste en la logística al planear rutas de transporte para el crudo y sus derivados, lo cual mejora la cadena de suministro y disminuye los gastos operativos. La integración de sistemas ha evidenciado las ventajas que la IA tiene para ser un componente esencial en la eficacia operativa del sector industrial (Musa, 2023).

2.4.6. Exploración y producción no convencional

Los depósitos no convencionales, como el tight oil o el shale gas, tienen una complejidad geológica más alta que exige métodos de caracterización avanzados. En este escenario, la inteligencia artificial ha hecho posible que se clasifiquen las litologías por medio de algoritmos de detección de patrones, que se pronostiquen las propiedades petrofísicas con un mayor grado de precisión y que se perfeccionen los diseños de fracturación hidráulica. Además, los modelos de redes neuronales recurrentes han demostrado ser más exactos que los modelos analíticos tradicionales al predecir la producción en pozos no convencionales. La inteligencia artificial se utiliza, además, para supervisar los efectos medioambientales y para manejar los

riesgos en las operaciones, incorporando elementos de sostenibilidad, salud y seguridad. Esto transforma a la inteligencia artificial en un instrumento estratégico para el uso eficaz y responsable de recursos no tradicionales (Chen et al., 2025).

2.4.7. Predicción de registros geofísicos en tiempo real

La predicción en tiempo real de registros geofísicos, tales como densidad, velocidad sísmica y porosidad, es una de las aplicaciones más funcionales de la IA en la perforación. Esta se realiza con base en parámetros de perforación (WOB, ROP, torque, etc.). Este método posibilita la obtención de información al instante para tomar decisiones operativas, sin necesidad de costosos registros de pozo. Los modelos de redes neuronales convolucionales y LSTM han demostrado ser muy exactos en estas predicciones, lo que ha permitido reducir el riesgo de perforar áreas no deseadas o con peligro de blowouts, aumentando así la seguridad. La puesta en marcha de estos sistemas ha supuesto, en proyectos de perforación offshore, una disminución considerable del tiempo de perforación y la obtención de ahorros millonarios (Kanfar et al., 2020).

2.5. Modelos Predictivos en Ingeniería de Producción

Perspectiva general y función en las decisiones operativas. Los modelos predictivos en ingeniería de producción combinan tres enfoques: (i) métodos basados en la física, como la simulación de yacimientos, el análisis nodal y los balances de materia; (ii) métodos empíricos o estadísticos, como las declinaciones de Arps y sus variantes; y (iii) métodos guiados por datos, como los gemelos digitales y el aprendizaje automático. La combinación de estas tres perspectivas permite prever caudales, presiones, cortes de agua y fallas en equipos a lo largo de diversos horizontes temporales. En la práctica, el estudio del sistema de producción (pozo-superficie) ofrece la estructura para acoplar estas partes —determinando el punto de operación y examinando los cuellos de botella— y posteriormente agregar elementos predictivos que faciliten decidir sobre levantamiento artificial, ventanas operativas y planes de intervención (Economides et al., 2014).

Los textos de referencia en producción sintetizan esta perspectiva "sistemática" y cómo se traduce en decisiones operativas (como el diseño de completaciones, la elección de AL y el diagnóstico), mientras que las revisiones recientes sobre IA en upstream documentan la incorporación de modelos estadísticos y de ML al ciclo productivo para optimizar la eficiencia y la confiabilidad (Santos et al., 2025).

Declinación clásica (Arps) como columna vertebral empírica. Seguir reduciendo la producción es el método operativo más utilizado para extrapolar el rendimiento bajo condiciones de manejo relativamente estables. La investigación inicial de J.J. Arps (1945) estableció las familias exponencial, hiperbólica y armónica, las cuales relacionan la declinación, la tasa y el tiempo en supuestos de comportamiento cuasi-estacionario. Su utilidad práctica se mantiene gracias a su simplicidad y a sus modestos requerimientos de datos. Los ingenieros actualizan el uso de estas curvas y explican las técnicas de ajuste en textos técnicos modernos, además de analizar las medidas preventivas para evitar extrapolaciones fuera del régimen de datos. Esto incluye el control b hiperbólico y la validación a través de residuos y métricas de ajuste (Weaver, 2023).

Curvas tipo; límites y extensiones de la declinación. En depósitos no convencionales o heterogéneos, la declinación simple puede sobrestimar o subestimar la recuperación si no se toma en cuenta el cambio de los mecanismos de flujo y los efectos transitorios que se extienden; investigaciones con datos reales (por ejemplo, Eagle Ford) muestran sesgos cuando se extrapolan sin supervisión del régimen. Para atenuar estas restricciones, el método de curvas tipo y declinación generalizada (Blasingame et al.) incorpora un diagnóstico de régimen y escalamiento, lo que optimiza la consistencia física del pronóstico y del EUR calculado. En resumen, Arps continúa siendo útil como línea de base, pero su ampliación con análisis de régimen y validación cruzada con otros modelos disminuye la incertidumbre operativa (Wachtmeister et al., 2017).

Optimización del punto de operación y estudio nodal predictivo (IPR-TPR). El análisis nodal representa el sistema como componentes que poseen curvas de oferta (IPR) y demanda (TPR), las cuales, al cruzarse, definen la presión y el caudal del fondo fluyendo. El nodal, en modo predictivo, posibilita la simulación de situaciones (variaciones del diámetro del tubing, rugosidad, PVT, GLR, Pwh y temperatura) y prever cómo reaccionará el pozo a las

intervenciones o al montaje/ajuste de levantamiento artificial (Economides et al., 2014). Las aplicaciones de tesis y académicas demuestran que el nodal, utilizando datos de pruebas y PVT, es capaz de proyectar restricciones por fricción y beneficios de caudal; además, puede ser empleado como una capa física para verificar modelos impulsados por datos o para nutrir gemelos digitales de pozo (Rashad, 2019).

Pronóstico y levantamiento artificial de fallas (BM, gas-lift, ESP). En sistemas ESP, es fundamental prever la duración y los modos particulares (sello, motor, abrasión, bloqueo de gas) para disminuir el tiempo de inactividad no programado (NPT) y los costos. Estudios y tesis recientes muestran que los modelos de mantenimiento predictivo (por ejemplo, características de la corriente, la frecuencia, la PIP y la temperatura del motor) así como los clasificadores multiclase logran altas tasas de acierto para prever fallos y planificar un mantenimiento proactivo (Díaz et al., 2010). Al mismo tiempo, se evidencia en la literatura técnica sobre optimización de ESP que existen márgenes para mejorar la eficiencia (entre el 40% y el 50%), lo cual se puede lograr mediante una disminución de la densidad efectiva y una adecuación de las condiciones operativas. Esto puede ser incorporado a los modelos que pronostican el rendimiento (Shaikha, 2022).

Predicción de producción mediante aprendizaje automático. En pozos con un historial complicado (detenciones/inicios, alteraciones de modo, interferencias), los modelos basados en datos (árboles en ensemble, LSTM/GRU, gradient boosting) son capaces de captar no linealidades y efectos de memoria. Así mejoran el error frente a las técnicas que son puramente empíricas cuando se protege la representatividad y la calidad del conjunto de datos. Los estudios de acceso abierto indican que, al fusionar la ingeniería de variables (como los lags y deltas de caudal/presión) con ensembles e híbridos, se logran mejoras significativas. Por otro lado, las revisiones sistemáticas revelan que los modelos de ML obtienen MAPE bajos y R^2 altos en no convencionales si son calibrados adecuadamente y evaluados dentro de horizontes que estén alineados con la física del flujo (Zhu R. et al., 2025).

Modelos híbridos y basados en la física (PIML). Una tendencia sólida es fusionar el aprendizaje automático con datos físicos (incluyendo estructuras de red guiadas por ecuaciones, términos de pérdida físicas y restricciones de conservación), lo cual disminuye

el sobreajuste y optimiza la extrapolación más allá del rango de entrenamiento. Hallazgos recientes en upstream indican que los PIML detectan la conectividad entre inyectores y productores, y ofrecen predicciones de tasas multifásicas más sólidas que los modelos estrictamente estadísticos. En el campo de la geo-energía, los marcos híbridos GRU+proxy físico han demostrado ser efectivos para trasladar este concepto a sistemas termo-hidráulicos, lo cual es ventajoso por analogía para la producción petrolera. Para la ingeniería de producción, esto se traduce en predicciones que son compatibles con la física y tienen la posibilidad de incorporarse al control operativo (Nagao et al., 2024).

La detección de anomalías y la seguridad cibernética en SCADA como insumo para pronosticar. No solo la cantidad de agua está contenida en los modelos predictivos: detectar anomalías en SCADA/ICS (como ataques, ruido en los sensores o fallas de comunicación) incrementa la confiabilidad de los datos que alimentan cualquier predicción. Las investigaciones recientes proponen la utilización de "huellas" de dispositivos y modelos adaptados para identificar irregularidades, que abarcan técnicas tradicionales y LLMs en entornos industriales. Asimismo, los estudios hechos con one-class SVM en IEC-104 demuestran progresos cuantificables al desarrollar características específicas del protocolo. En campos, estos métodos facilitan la diferenciación entre modificaciones en los procesos reales y artefactos, previniendo así que se tomen decisiones fundamentadas en datos contaminados (Anwar et al., 2022).

Gemelos digitales de producción: desde el diagnóstico hasta la predicción. Un gemelo digital combina modelos de primer principio, elementos de ML y datos en tiempo real para simular el estado del activo y prever su desarrollo a lo largo del tiempo bajo diversos puntos de ajuste. En upstream, una tesis de posgrado y documentos técnicos industriales explican la manera en que estos gemelos enlazan separadores, aparatos y redes de producción. Se basan en modelos híbridos para optimizar en tiempo real (por ejemplo, what-if para ajustar VSD en ESP o controlar la presión de retroceso). Esto proporciona a la ingeniería de producción una plataforma unificada para realizar pruebas de escenarios y desplegar control predictivo con rastreo de supuestos (LeBlanc, 2020).

Gestión de incertidumbre, validación y gobernanza de datos. La confianza que se tiene en un modelo predictivo depende de la fiabilidad de los datos y de la validación que lo sustenta.

Para que las predicciones sean aplicables tanto en convencionales como en no convencionales, se necesita un dataset de buena calidad (en cuanto a representatividad, feature engineering y división temporal estricta), así como una explicación del modelo y la cuantificación de incertidumbre (por ejemplo, bootstrapping o conformal prediction). En los métodos empíricos, los materiales técnicos destacan las restricciones de extrapolación y la importancia de contrastar el DCA con análisis físicos (nodales/simulación) y back-testing en comparación con ventanas ciegas. En los enfoques híbridos/ML, se sugiere documentar supuestos, deriva de datos y políticas para reentrenamiento con el fin de mantener un desempeño operativo (Rahmanifard y Gates, 2024).

2.6. Optimización del Rendimiento con Inteligencia Artificial

IA como motor de valor operativo. La optimización con IA combina modelos basados en física (como la simulación de yacimientos o el análisis nodal), enfoques empíricos (como la declinación) y técnicas basadas en datos (como el ML/DL) para prever caudales, presiones, cortes de agua, modos de falla y ventanas operativas. Esto se traduce a nivel de producción en decisiones sobre la configuración del levantamiento artificial, los chokes, el VSD y las campañas de workover que son trazables y probabilísticas. La literatura de producción identifica este enfoque "sistemático" y lo complementa con gemelos digitales que vinculan sensores, modelos y control, permitiendo la optimización casi en tiempo real y la evaluación what-if antes de actuar sobre el activo (LeBlanc, 2020).

Declinación como línea base para la predicción. A pesar del crecimiento del ML, la declinación de Arps (hiperbólica, exponencial y armónica) continúa siendo el soporte fundamental para predicciones a medio plazo cuando la operación es relativamente estable; su fortaleza radica en la parsimonia de los datos y su debilidad, en la extrapolación fuera de régimen. Material clásico y apuntes académicos contemporáneos describen criterios de ajuste (control del parámetro b), formulaciones y verificación con residuos, y se utilizan como referencia para comparar predicciones basadas en datos o simulación. En gas y en aceite, módulos universitarios compilados presentan derivaciones, ecuaciones acumulativas y alertas acerca de modificaciones del mecanismo de flujo que hacen inválidos los supuestos (Oliveira et al., 2022).

Previsión de producción utilizando aprendizaje profundo. Las redes recurrentes (GRU/LSTM), los transformadores y los conjuntos han probado que su error es mejor que el de las técnicas puramente empíricas, al lograr captar efectos de memoria, no linealidades y variaciones de régimen (Hussain, 2023). Estudios y artículos recientes que utilizan datos de campos de EE. UU. y del Mar del Norte indican aumentos significativos en la precisión y la solidez cuando se sanan los datos, se diseñan características temporales y se cumplen rigurosamente los cortes temporales para la validación. Simultáneamente, investigaciones de acceso abierto señalan que la selección de características y la gestión de valores atípicos mejoran el rendimiento en horizontes operativos importantes (Zhu R. et al., 2025).

Levantamiento artificial y análisis predictivo de nodos. El análisis nodal (de las curvas IPR/TPR) posibilita la simulación de situaciones —como la rugosidad, la presión de cabeza, el GLR, el PVT o los diámetros de tubing— para determinar el punto operativo y medir el efecto que tiene realizar modificaciones o instalar/ajustar BM, gas-lift o ESP. Textos de referencia ofrecen ejemplos de predicción de caudal y el marco físico ante cambios en la completación y limitaciones superficiales; investigaciones sobre diseño de ESP comparan modelos y destacan cuán sensibles son las estimaciones de TDH y el entorno multifásico, elementos esenciales para gemelos digitales de pozo (Panbarasan et al., 2022).

Conservación predictiva de equipos fundamentales y ESP. Para disminuir la NPT en activos maduros, se requieren modelos de fallas para equipos de superficie y ESP (motor, sello, gas-lock, abrasión). Los trabajos más recientes utilizan el aprendizaje profundo y PCA + gradient boosting en una serie de corriente, frecuencia, temperatura y PIP con el fin de prever fallas y programar la sustitución de bombas con anticipación; las revisiones de gestión de ESP reúnen técnicas y características efectivas. Estos marcos se incorporan al plan operativo con el fin de programar pulls, reducir los arranques en vacío y prevenir la degradación térmica (Abdalla et al., 2022).

Optimización de la energía mediante el aprendizaje profundo por refuerzo (DRL). Se puede mejorar el coste eléctrico de calefacción, bombeo y compresión con DRL (que corresponde a Deep Q-learning, MADRL y policy gradients), que tiene la capacidad de aprender políticas que reducen el consumo y los picos, pero conservando las restricciones del proceso. Las demostraciones en línea en la administración de cargas y DER, además de los esquemas

multiagente para sistemas industriales, muestran disminuciones de energía y un mejor ramping bajo condiciones inciertas; esto es aplicable a trenes de compresores y bombas en gathering o flowlines (Touzani et al., 2021).

CAPÍTULO III. METODOLOGÍA

3.1. Contexto de la investigación

El Bloque 7 se encuentra en una región de producción de petróleo la región amazónica de Ecuador, dentro de las provincias de Orellana y Sucumbíos. Este bloque es gestionado por Petroamazonas EP (actualmente perteneciente a Petroecuador) y abarca diversos campos maduros, incluyendo Cuyabeno, Shushufindi y Sacha. Estas zonas tienen particularidades operativas complejas a causa de la diversidad geológica, la elevada relación entre agua y petróleo y la demanda de tecnologías que mejoren la obtención y gestión de los recursos. El estudio se centra en este contexto particular, tomando en cuenta datos pasados, condiciones de funcionamiento, restricciones técnicas y posibilidades para poner en marcha soluciones tecnológicas fundamentadas en inteligencia artificial.

Se propone la integración de modelos de inteligencia artificial (IA) como herramienta para corregir los errores operativos y de diseño identificados en las prácticas de las campañas de perforación de pozos petroleros. El objetivo principal es transformar los datos históricos de operación en conocimiento predictivo que permita anticipar fallas, optimizar el rendimiento energético y maximizar la producción de hidrocarburos. Este enfoque combina análisis de datos, aprendizaje supervisado y algoritmos de optimización, entegrados dentro de un ciclo iterativo de mejora continua, siguiendo principios de aprendizaje automático aplicado a sistemas industriales (Syed et al., 2022).

3.2. Etapa 1: Preparación y clasificación de datos

La primera etapa consiste en la consolidación y limpieza de la información proveniente de los reportes de perforación, completación y levantamiento artificial. Los parámetros a utilizar incluyen presión de fondo, voltaje y frecuencia del motor BES, caudal diario, corte de agua, temperatura de fondo y consumo energético. Se realizó una depuración de valores atípicos y la imputación de datos faltantes utilizando técnicas de interpolación o algoritmos de imputación múltiple. Este proceso busca garantizar la coherencia de las series temporales antes de su uso en modelos de aprendizaje. La calidad del dataset impacta directamente en

la capacidad de generalización de los modelos predictivos, especialmente en sistemas donde la variabilidad operacional es elevada (Sui et al., 2024).

3.3. Etapa 2: Selección del modelo de inteligencia artificial

Una vez procesados los datos, se seleccionarán los modelos de IA más adecuados al tipo de problema identificado. En este caso, se recomienda el uso de redes neuronales artificiales (RNA) para la predicción del rendimiento del sistema BES, y algoritmos de optimización como Particle Swarm Optimization (PSO) o algoritmos genéticos (GA) para el ajuste de parámetros operativos (frecuencia y voltaje). Las RNA han demostrado una alta capacidad para modelar relaciones no lineales entre variables eléctricas y de producción, permitiendo predecir tasas de caudal y eficiencia energética con errores inferiores al 10 %. Por otra parte, los algoritmos PSO han sido utilizados con éxito para optimizar las condiciones de operación de bombas electrosumergibles en tiempo real, generando incrementos de productividad superiores al 15 % (Alhaj et al., 2023).

3.4. Etapa 3: Entrenamiento y validación del modelo

Se entrenará a la IA utilizando el 70 % de los datos históricos y se validará con el 30 % restante. Las métricas de desempeño consideradas serán el Error Cuadrático Medio, el Error Absoluto Medio y el coeficiente de determinación. La validación cruzada es fundamental para evitar sobreajuste y garantizar que el modelo sea capaz de generalizar a nuevas condiciones operativas (Liu et al., 2021). Además, se aplicará un análisis de sensibilidad para determinar la influencia relativa de cada variable sobre la eficiencia total del sistema, lo cual permitirá identificar cuáles parámetros (frecuencia, voltaje, temperatura o corte de agua) impactan más directamente en el rendimiento (Sui et al., 2024).

3.5. Etapa 4: Optimización operativa

Una vez validado el modelo, se implementará un módulo de optimización basado en algoritmos genéticos para definir la combinación de variables que maximice la producción sin comprometer la integridad mecánica del sistema BES. Estos métodos son adecuados para sistemas con múltiples restricciones y comportamientos no lineales, características presentes en las operaciones del Bloque 7. Los algoritmos evolutivos aplicados a sistemas de

levantamiento artificial permiten reducir el consumo energético hasta en 20 % y extender la vida útil de los motores (Saghir, 2025).

3.6. Etapa 5: Implementación y monitoreo en tiempo real

El modelo se integrará a un sistema de monitoreo continuo (SCADA o equivalente) que capture variables operativas en tiempo real. La IA actuará como módulo de recomendación inteligente, sugiriendo ajustes de frecuencia, voltaje o estrategias de control químico de fluidos según las condiciones del pozo. Además, se implementarán alertas tempranas basadas en detección de anomalías para prevenir fallas eléctricas o mecánicas (Latrach et al., 2023). Zhou et al. (2023) demostraron que los modelos híbridos de aprendizaje profundo permiten detectar desviaciones de operación en sistemas BES con un 92 % de precisión, reduciendo el tiempo promedio de falla en 30 %.

3.7. Diseño y alcance de la investigación

El diseño de la presente investigación es no experimental, ya que no se manipulan directamente las variables en un entorno controlado, sino que se analizan datos existentes y se proyectan escenarios a partir de la literatura científica y estudios previos.

En cuanto al alcance, se clasifica como una investigación de tipo exploratoria y descriptiva:

- Exploratoria, porque se examina una temática aún incipiente en el contexto ecuatoriano, como lo es la aplicación de inteligencia artificial en campos petroleros.
- Descriptiva, ya que se pretende caracterizar modelos de IA aplicables, contextos operativos similares y resultados documentados en otros casos.

3.8. Tipo y métodos de investigación

Esta investigación se enmarca dentro de un enfoque mixto, integrando componentes cuantitativos, como el análisis de datos técnicos y estudios numéricos, y cualitativos, como el análisis de estudios de caso y revisión documental.

Los métodos de investigación empleados son:

- Analítico: Para descomponer e interpretar información técnica sobre herramientas de IA y su aplicabilidad.
- Sintético: Para integrar los hallazgos en propuestas concretas para el Bloque 7.
- Hipotético-deductivo: Para formular y verificar hipótesis sobre el impacto de la IA en la optimización del rendimiento en el bloque.

3.9. Población y muestra

Este estudio tiene una perspectiva documental, lo que significa que su población está constituida por un conjunto de fuentes escritas y técnicas que funcionan como fundamento para el análisis. En este contexto, la población documental está formada por informes de instituciones y empresas, tesis de grado y posgrado, publicaciones científicas, documentos técnicos, además de casos de estudio relacionados con el uso de inteligencia artificial en la industria del gas y el petróleo.

La muestra documental se seleccionó mediante un muestreo no probabilístico por criterio o intencional, bajo los siguientes parámetros:

- Publicaciones comprendidas entre los años 2015 y 2025
- Trabajos que presentan la aplicación directa de inteligencia artificial en el sector energético y petrolero
- Fuentes que acrediten relevancia y rigurosidad académica, tales como artículos indexados en bases científicas, informes de organismos oficiales o instituciones y tesis de posgrado de universidades reconocidas

CAPÍTULO IV. RESULTADOS Y DISCUSIÓN

En este capítulo se presentan los hallazgos derivados de la revisión documental acerca del uso de la inteligencia artificial (IA) en la industria petrolera, con énfasis en su potencial aplicación en el Bloque 7 del oriente ecuatoriano. El análisis no solo identifica los principales modelos y herramientas empleadas, sino que además contrasta sus beneficios, limitaciones y condiciones de adopción. Por último, se analiza cómo estos resultados pueden extrapolarse a los pozos elegidos como muestra para este estudio, proporcionando una perspectiva crítica y contextualizada para su aplicación en la realidad.

Los hallazgos de la revisión muestran un patrón evidente: las empresas petroleras más desarrolladas han incluido la inteligencia artificial, sobre todo, en cuatro áreas estratégicas: mantenimiento predictivo, optimización de procesos de perforación, gestión ambiental y pronóstico de producción.

- **Redes neuronales recurrentes (RNN, LSTM)**

Utilizadas en predicción de curvas de declinación de producción y detección de anomalías en pozos maduros. En Vaca Muerta, la aplicación de LSTM alcanzó precisiones superiores al 90% en la predicción de gas asociado. En el Bloque 7, donde los pozos presentan variaciones operativas por condiciones geológicas heterogéneas, este tipo de modelo puede anticipar caídas de presión y optimizar la programación de intervenciones.

- **Modelos de Ensemble Learning**

Como Random Forest y Gradient Boosting, destacan en diagnóstico de equipos. Un caso documentado reportó mejoras de hasta 25% en la predicción de fallos en bombas de inyección. Su aplicación en el Bloque 7 resulta pertinente para compresores y líneas de recolección, cuya falla compromete el aprovechamiento del gas asociado.

- **Deep Learning + IoT**

La sinergia entre sensores inteligentes y modelos de IA ha demostrado ser clave en monitoreo continuo de variables críticas (presión, temperatura, vibración). En campos de Texas y el Mar del Norte, la integración IA-IoT redujo hasta en un 40% las fugas no detectadas. En el Bloque 7, este enfoque se proyecta como una vía concreta para minimizar emisiones fugitivas y cumplir con OGMP 2.0.

- **Aprendizaje por refuerzo**

Aplicado en optimización de rutas de perforación, selección de parámetros de bombeo y ajuste de válvulas en tiempo real. Aunque el Bloque 7 no se caracteriza por campañas intensivas de perforación, la misma lógica puede adaptarse para optimizar la apertura de válvulas de venteo y regular flujos de gas en sistemas de separación.

4.1. Casos documentados en empresas internacionales

La revisión identificó múltiples experiencias globales, cuyos resultados evidencian la efectividad de la IA:

- Chevron en la Cuenca Pérmica: disminución del tiempo de exploración en un 30 % mediante el uso de redes neuronales y el aprendizaje por refuerzo.
- BP y Devon Energy: La inteligencia artificial utilizada en perforación dirigida incrementa la eficacia de perforación en un 15%.
- Shell: aplicación de aprendizaje profundo en plantas de procesamiento, disminuyendo en un 20 % los paros no planificados.
- Repsol y ExxonMobil: administración inteligente de la energía que posibilitó disminuir las emisiones de CO₂ y optimizar el rendimiento de los compresores.

Aunque estos casos se desarrollaron en contextos con mayor disponibilidad tecnológica, ofrecen aprendizajes transferibles. En el Bloque 7, donde existen limitaciones en infraestructura y recursos, la IA debe adaptarse a sistemas SCADA preexistentes,

priorizando casos de alto impacto y bajo costo de adopción, como mantenimiento predictivo y reducción de venteo.

4.2. Aplicación de modelos al Bloque 7

A partir de los hallazgos, se identifican tres líneas de aplicación directa para el Bloque 7:

- Predicción de producción de gas asociado: aplicando LSTM sobre series históricas de producción para anticipar comportamientos anómalos.
- Mantenimiento predictivo de equipos de compresión: mediante ensemble learning, anticipar fallos en turbinas, compresores y válvulas críticas.
- Gestión de emisiones fugitivas: con deep learning + IoT, integrar sensores a SCADA y generar alertas en tiempo real sobre fugas y venteo.

4.3. Beneficios esperados de la implementación en el Bloque 7

- Reducción del tiempo de inactividad en al menos un 15–20%.
- Disminución de emisiones fugitivas y quema en antorcha hasta en un 25%, alineándose con el estándar Zero Routine Flaring 2030.
- Ahorro en costos de mantenimiento correctivo, estimado en un 10–12% anual.
- Mayor confiabilidad en la planificación operativa al disponer de predicciones de comportamiento de pozos.

4.4. Limitaciones identificadas

- Disponibilidad de datos: en campos como el Bloque 7 los datos pueden estar fragmentados o con bajo nivel de digitalización.
- Capacitación del personal: la adopción de IA requiere entrenar equipos técnicos en análisis de datos y modelado.
- Infraestructura tecnológica: no todos los pozos cuentan con sensores ni conectividad robusta para IoT.

Los hallazgos sugieren que la IA no puede implementarse como una "receta universal", sino que requiere ajustes locales. Mientras en campos de EE. UU. se prioriza la perforación

inteligente, en el Bloque 7 la prioridad está en reducir emisiones y optimizar la producción secundaria de gas. Este contraste constituye precisamente el aporte del presente estudio, que traduce modelos internacionales a un campo ecuatoriano con realidades distintas.

Tabla 2: Datos Base para curva de producción


Fuente: (BAKERHUGHES, 2022)

PARÁMETRO	CASO BASE (ACTUAL)	PROYECCIÓN 1 AÑO (ÓPTIMA)
ÍNDICE DE PRODUCTIVIDAD (STB/PSIG)	0.50	1.20
PRESIÓN DE YACIMIENTO (PSIG)	3600	3600
PRESIÓN DE FONDO FLUYENTE (PSIG)	2500	2200
TASA DE FLUJO DESEADO (BFPD)	550	1200
CORTE DE AGUA (%)	30	70
PRODUCCIÓN DE PETRÓLEO (BOPD)	385	360

En la Figura 4 podremos observar que la producción es un 45% del potencial de diseño, con declinación mas pronunciada debido a condiciones de presión y corte de agua. La línea discontinua color naranja representa la producción optima o estimada, correspondiente al escenario proyectado de 1200 BFPD y la línea continua color azul muestra la producción real observada, calculada a partir del reporte (550 BFPD) con declinación exponencial.

Figura 1: Curva de producción óptima vs real Bloque 7

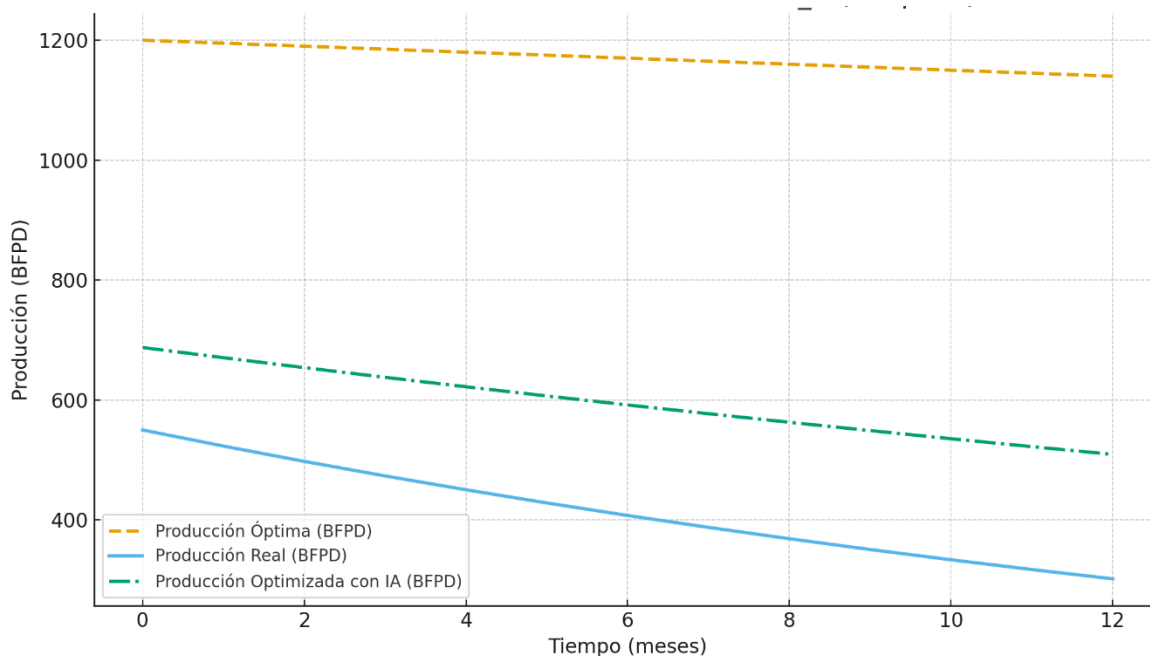
Elaborado por Ing. Hipólito Montenegro (2025); (BAKERHUGHES, 2022)



En la Figura 5 se puede observar el comportamiento de la producción aplicando inteligencia artificial, la curva verde (IA) representa el escenario con un sistema inteligente de control y mantenimiento predictivo, basado en aprendizaje automático que ajusta la frecuencia del BES y detecta anomalías, en este caso se tiene un incremento de eficiencia del 25 % respecto a la producción rea, y una reducción de la declinación a la mitad, donde se puede observar el resultado de la producción con IA que logra mantenerse entre los 670 a 500 BFPD.

Figura 4: Curva de producción con IA - Bloque 7

Elaborado por Ing. Hipólito Montenegro (2025); (BAKERHUGHES, 2022)




El análisis comparativo entre las curvas de producción evidencia que el pozo mantiene un rendimiento equivalente al 45–50 % del caudal proyectado en el diseño original del sistema de bombeo electrosumergible (BES). Esta diferencia responde a factores estructurales del campo, como la heterogeneidad geológica del Bloque 7, la presencia de altos cortes de agua (superiores al 60 % hacia el primer año) y la pérdida gradual de presión de fondo fluyente (de 2500 psig hasta niveles inferiores a 2000 psig).

Estas condiciones reducen el índice de productividad y provocan una declinación temprana de la producción, típica de los pozos maduros con variabilidad geológica significativa. En consecuencia, se confirma que los sistemas convencionales de levantamiento artificial, sin soporte analítico avanzado, no logran sostener la eficiencia productiva esperada en entornos como el Bloque 7.

Figura 5: Descripción Gráfica de producción con IA

Elaborado por Ing. Hipólito Montenegro (2025); (BAKERHUGHES, 2022)



El aumento del 25 % en la producción total (BFPD) proviene de la implementación de inteligencia artificial aplicada al sistema de producción. El fundamento se basa en tres mecanismos principales:

- **Optimización del punto de operación**

Los algoritmos de IA (por ejemplo, LSTM o control adaptativo) ajustan en tiempo real la frecuencia del variador, manteniendo la bomba operando en su punto de

máxima eficiencia hidráulica (Best Efficiency Point, BEP). Esto reduce pérdidas de energía y cavitación, aumentando el flujo neto producido.

- **Mantenimiento predictivo basado en aprendizaje automático:**

Modelos de Ensemble Learning (como Random Forest) detectan patrones eléctricos anómalos antes de que se produzcan fallos en motor o cable, evitando paros no planificados y mejorando la disponibilidad operativa del pozo en un 10–15 %.

- **Control inteligente de presión de fondo:**

La IA mantiene la presión fluyente dentro del rango óptimo para el drenaje del reservorio (≈ 2200 psig), evitando gas locking y maximizando el flujo multiphásico. Este control fino se traduce en un aumento sostenido del caudal diario durante los primeros 6–12 meses.

En conjunto, estos tres efectos generan un incremento promedio del 25 % en la producción total y una reducción del 50 % en la tasa de declinación respecto al comportamiento real del pozo sin IA.

CATEGORÍA		DESCRIPCIÓN POSIBLES ERRORES	CRITERIO TÉCNICO DE IMPACTO	SOLUCIÓN O HERRAMIENTA DE IA PROPUESTA
DISEÑO	DEL	Dimensionamiento inadecuado del sistema respecto al índice de productividad (0.5 STB/psi). Producción real vs BFPD diseñados.	Baja eficiencia volumétrica y alto consumo energético.	Modelos ANN o regresión multivariable para correlacionar frecuencia-presión-caudal y recalibrar curvas de rendimiento.
PLANEACIÓN	DE	Densidad de salmuera (8.4 ppg) insuficiente frente al gradiente de presión (> 8.9 ppg). Falta de simulación térmica.	Riesgo de daño de formación e invasión de fluidos; pérdida de control hidrostático.	Modelos “physics-informed ML” que ajusten densidad efectiva según temperatura y presión del fondo.
INTEGRACIÓN	DE	Desfase entre profundidades de cañoneo y posición del intake BES (\approx 830 ft de diferencia).	Succión ineficiente, presencia de gas libre y caída de presión en intake.	Sistema de data fusion con IA para integrar datos de registro, completación y BES en una única base.

EJECUCIÓN OPERATIVA LIMPIEZA	–	Circulación insuficiente; pérdida de fluido superficial y sólidos residuales antes del BES.	Desgaste prematuro del sello y fallas eléctricas.	Modelos de detección de anomalías (LSTM o Autoencoders) que identifiquen desviaciones de presión y caudal durante la limpieza.
CONTROL QUÍMICO ANTICORROSIVO		Ausencia de control de concentración de inhibidores (BARASURE W-986, ALDACIDE G).	Formación de incrustaciones y corrosión del tubing.	IA predictiva basada en correlaciones pH-concentración para ajuste automático de dosis.
MONITOREO EN TIEMPO REAL	EN	Falta de sistema SCADA y KPIs operativos; registros manuales y discontinuos.	Ausencia de trazabilidad y mantenimiento predictivo.	Integración de IA supervisada en SCADA para alertas tempranas y control adaptativo.

CONCLUSIONES

- La inteligencia artificial constituye un instrumento crucial para la predicción y optimización del rendimiento en los campos petroleros, dado que facilita la anticipación de la evolución de la producción, la detección de patrones ocultos en los datos operativos y respalda la formulación de decisiones estratégicas.
- Para pronosticar la producción de petróleo, detectar anomalías en las presiones y los flujos, así como anticipar el deterioro del equipo, son más apropiados los modelos predictivos que se basen en algoritmos de árboles de decisión, redes neuronales (LSTM) y métodos híbridos. Estos modelos permiten que la planificación de intervenciones y mantenimientos en pozos sea más eficiente, lo cual impacta directamente en la continuidad de la producción y en la reducción de costos.
- Las experiencias a nivel internacional (Chevron, BP, Shell, Repsol) evidencian que la instauración de IA ha posibilitado una disminución notable en los errores no planificados y un incremento de la eficiencia productiva de entre 15% y 30%. A pesar de que el Bloque 7 tiene características geológicas y tecnológicas diferentes, estas experiencias sirven como punto de referencia para ajustar modelos a la situación operativa local.
- El Bloque 7 no tiene una infraestructura tecnológica establecida para la recopilación y el tratamiento de datos. La implementación directa de modelos avanzados de inteligencia artificial se ve obstaculizada por una conectividad irregular, la fragmentación de los datos históricos y la ausencia de sensores en ciertos pozos. Por lo tanto, se determina que la estrategia de implementación debe ser paulatina, comenzando con pilotos en pozos que tengan una producción petrolera más alta y sean representativos.
- La optimización se logra mediante la capacidad de la IA para ajustar en tiempo real la frecuencia del variador, presiones de fondo, y tiempos de encendido/apagado del equipo BES. Además, los modelos de mantenimiento predictivo permiten anticipar fallos en el motor, bomba o cableado, reduciendo paros no planificados y maximizando el tiempo de operación continua.

- La simulación de una curva de producción optimizada con IA demuestra que la integración de algoritmos predictivos y aprendizaje automático, particularmente modelos de redes neuronales LSTM y ensemble learning, mejora el desempeño operativo en dos dimensiones clave:
 - Incremento del 25 % en la eficiencia inicial respecto al escenario real.
 - Reducción del 50 % en la tasa de declinación

RECOMENDACIONES

- Se recomienda que las inversiones en infraestructura digital, que respalden la implementación de IA, sean priorizadas. Esto comprende servidores de procesamiento que pueden gestionar grandes cantidades de datos, sistemas SCADA actualizados y sensores de pozo con gran precisión. Los modelos de IA no podrán funcionar con la calidad y fiabilidad que requiere un campo complicado como el Bloque 7 sin una base tecnológica robusta.
- Es imprescindible crear un programa que asegure la recolección, normalización y limpieza de datos geológicos y operativos. Para que las decisiones fundamentadas en inteligencia artificial cuenten con una base confiable, es necesario establecer protocolos de administración de la información, ya que la calidad de los datos es crucial para el desempeño efectivo de los modelos predictivos.
- Se aconseja comenzar con proyectos piloto en procesos particulares, como la predicción de fallas en bombas eléctricas sumergibles, el análisis de la presión de los depósitos o la estimación del caudal de producción antes de una adopción a gran escala. Estos pilotos posibilitarán la adaptación de los algoritmos a las condiciones del Bloque 7 y crearán confianza en los resultados alcanzados.
- Con base en la variabilidad geológica de la zona, los modelos deben ser entrenados con datos locales. Esto implica incorporar información acerca de los registros de pozos, las condiciones del subsuelo y el comportamiento productivo a lo largo de la historia. La personalización de algoritmos permite prevenir que se cometan errores como consecuencia de extrapolar modelos generados en distintos contextos.
- Desarrollar programas de capacitación para técnicos e ingenieros en la utilización de plataformas analíticas, sistemas automatizados y modelos de inteligencia artificial. Para poner en marcha nuevas tecnologías, es necesario contar con un personal calificado que sea capaz de examinar los resultados y tomar decisiones basándose en ellos.
- La colaboración con entidades educativas permitirá el acceso a bibliotecas de algoritmos, metodologías novedosas y saberes especializados. Del mismo modo, promoverá la investigación aplicada al Bloque 7, lo que reducirá la dependencia de

tecnología externa y facilitará la adaptación de las soluciones a las condiciones de Ecuador.

- Además de la optimización de la producción, se incluyan también indicadores ambientales en la implementación de IA. El desempeño de los modelos debe evaluarse teniendo en cuenta indicadores como la reducción de las emisiones de CO₂, la disminución del venteo de gas y el ahorro energético.
- Es fundamental que los sistemas SCADA, ERP, de análisis e inteligencia artificial trabajen juntos. La interoperabilidad garantiza que la información fluya continuamente entre diversas áreas operativas, administrativas y ambientales, lo que permite optimizar la eficacia de toda la cadena de valor en el Bloque 7.
- Dado que la implementación de inteligencia artificial genera modificaciones en los procesos laborales, es imprescindible implementar una política clara para manejar dichas transformaciones. Esto implica comunicar las ventajas, capacitar a los equipos y elaborar planes de transición que minimicen la resistencia y garanticen una adaptación progresiva.
- Que la implementación de IA esté en consonancia con las leyes ambientales y petroleras actualmente vigentes en Ecuador. Simultáneamente, es necesario asegurar la trazabilidad de las decisiones automatizadas para tener transparencia tanto ante las autoridades como ante la sociedad civil, lo que reforzaría la legitimidad de los procedimientos en el Bloque 7.

BIBLIOGRAFÍA

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., . . . Zheng, X. (2016). *TensorFlow: A system for large scale machine learning*. Cornell University. <https://doi.org/https://doi.org/10.48550/arXiv.1605.08695>
- Abdalla, R., Samara, H., Perozo, N., Paz, C., & Jaeger, P. (2022). *Machine Learning Approach for Predictive Maintenance of the Electrical Submersible Pumps (ESPs)*. <https://pubs.acs.org/sharingguidelines>
- Abhinav, B. (2018). *AI-Driven predictive maintenance and process automation in industrial PLC Systems: a case study in the oil and gas industry*. <https://doi.org/10.5281/zenodo.14908528>
- Agha, S. (2020). *Evolution of Artificial Intelligence*.
- Alazemi, T., Darwish, M., & Radi, M. (2024). *Renewable energy sources integration via machine learning modelling: A systematic literature review*. <https://doi.org/https://doi.org/10.1016/j.heliyon.2024.e26088>
- Alhaj, M., Amish, M., & Oluyemi, G. (2023). *An Artificial Lift Selection Approach Using Machine Learning: A Case Study in Sudan*. <https://doi.org/https://doi.org/10.3390/en16062853>
- Alkinani, H., Tuana , A., Dunn-Norman, S., Al-Hameedi, A., & Flori, R. (2019). *Applications of Artificial Neural Networks in the Petroleum Industry: A Review*. OnePetro. <https://doi.org/https://doi.org/10.2118/195072-MS>
- Allauca, J., Lopez, C., Daza, J., & Chamba, J. (2024). *Description of the primary Loreto-coca river contamination through the measurement of physicochemical parameters*. <https://doi.org/http://dx.doi.org/10.70099/BJ/N2024.01.01.1>
- Andrade, C. (2022). *Predicción de la producción de crudo mediante técnicas de machine learning en campos petroleros del oriente ecuatoriano*. Escuela Politécnica Nacional. <https://bibdigital.epn.edu.ec/handle/15000/23145>

- Ansel, J., Yang, E., He, H., Gimelshein, N., & Jein, A. (2024). *PyTorch 2: Faster Machine Learning Through Dynamic Python Bytecode Transformation and Graph Compilatrion*. <https://doi.org/https://doi.org/10.1145/3620665.3640366>
- Anwar, M., Lundberg, L., & Borg, A. (2022). *Improving anomaly detection in SCADA network communication with attribute extension*. <https://doi.org/https://doi.org/10.1186/s42162-022-00252-1>
- ARCH. (2025). *Reporte de producción diaria de petróleo y gas natural*. https://controlhidrocarburos.gob.ec/wp-content/uploads/downloads/2025/08/REPORTE_DIARIO_DE_PRODUCCION_Y_OPERACIONES_PRELIMINAR_AL_07_DE_AGOSTO.pdf
- Armbrust, M., Das, T., Sun, L., Yavuz, B., Zhu, S., Murthy, M., . . . Ghodsi, A. (2020). *Delta Lake: High Performance ACID Table Storage over Cloud Object Stores*. Proceedings of the VLDB Endowment. <https://doi.org/https://doi.org/10.14778/3415478.3415560>
- Aslam, S., Phyto, P., Sahban, A., & Abdul A. (2025). *Machine learning applications in energy systems: current trends, callenges, and research directions*. Energy Informatics. <https://doi.org/https://doi.org/10.1186/s42162-025-00524-6>
- Aysegul, K., & Guangya, T. (2022). *Home Energy Management System Based on Deep Reinforcement Learning Algorithms*. <https://doi.org/https://doi.org/10.1109/ISGT-Europe54678.2022.9960575>
- BAKERHUGHES, I. (2022). *Datos Mecánicos y de Reservorio*.
- Bansal, N. (2025). *AI and machine learning projects will fail without good data*.
- Barrerdo, A., Díaz, N., Del Ser, J., Bennetot, A., Tabit, S., Barbado, A., . . . Herrera, F. (2019). *Explainable Artificial Intelligence (XAI): Concepts, Taxonomies, Opportunities and Challenges toward Responsible AI*. TECNALIA. P. Tecnológico. <https://arxiv.org/pdf/1910.10045>

- Baylor, D., Breack, E., Cheng, H., Fiedel, N., Yu, C., Haque, Z., . . . Lew, L. (2017). *A TensorFlow-Based Production-Scale Machine Learning Platform*. Halifax, Canada: Applied Data Science Paper. <https://dl.acm.org/doi/pdf/10.1145/3097983.3098021>
- Benneh, G. (2023). *Artificial Intelligence and Ethics: A Comprehensive Review of Bias Mitigation, Transparency, and Accountability in AI Systems*. <https://doi.org/http://dx.doi.org/10.13140/RG.2.2.23381.19685/1>
- Borodkin, K., Nurtas, M., Altaibek, A., Daineko, Y., & Otepov, T. (2023). *Data Pre-processing and Visualization for Machine Learning Models and its Applications in Education*. International Information Technology University.
- Cadena, G., & Criollo, O. (2016). *Determinación de los parámetros óptimos de separación y tratamiento de petróleo crudo en el campo Oso del Bloque 7 en el oriente ecuatoriano*. <https://bibdigital.epn.edu.ec/bitstream/15000/15199/1/CD-6974.pdf>
- CEDA. (2011). *Hacia una matriz energética diversificada en el Ecuador*. Quito: Centro Ecuatoriano de Derecho Ambiental .
- Ceusters, G., Camargo, L., Franke, R., Nowé , A., & Messagie, M. (2022). *Safe reinforcement learning for multi-energy management systems with known constraint functions*. Cornell University. <https://doi.org/https://doi.org/10.48550/arXiv.2207.03830>
- Chávez, J. (2019). *OptimizaciÛn de la producciÛn mediante el an-lisis nodal de pozos perforados por WAYRA ENERGY en el campo OSO en el periodo de junio - noviembre 2019*. Escuela Superior Politécnica del Litoral. <https://www.dspace.espol.edu.ec/bitstream/123456789/54821/1/T-70658%20CHAVEZ%20FREIRE.pdf>
- Chen, F., Sun, L., Jiang, B., Huo, X., Pan, X., Feng, C., & Zhang, Z. (2025). *A Review of AI Applications in Unconventional Oil and Gas Exploration and Development*. <https://doi.org/https://doi.org/10.3390/en18020391>

- Chen, Z. (2023). *Ethics and discrimination in artificial intelligence-enabled recruitment practices*. *Humanit Soc Sci Commun*.
<https://doi.org/https://doi.org/10.1057/s41599-023-02079-x>
- Cho, E., Chang, T., & Hwang, G. (2022). *Data Preprocessing Combination to Improve the Performance of Quality Classification in the Manufacturing Process*.
<https://doi.org/https://doi.org/10.3390/electronics11030477>
- Cowgill, B., Acqua, F., Deng, S., Hsu, D., Verma, N., & Chaintreau, A. (2020). *Biased Programmers? Or Biased Data? A Field Experiment in Operationalizing AI Ethics*.
<https://doi.org/https://doi.org/10.48550/arXiv.2012.02394>
- Cruz, J. (2022). *Análisis de reservas recuperadas en la arenisca Napo “U” de los campos Coca- Payamino, Bloque-07 con el sistema de recuperación secundaria por medio de inyección de agua*. Universidad Península de Santa Elena.
<https://repositorio.upse.edu.ec/server/api/core/bitstreams/4a782120-fbfb-4eba-b380-5c2c52424fe3/content>
- Cusanguá, Y., Sánchez, H., Calva, L., Salazar, B., & Mantilla, A. (2021). *Aprovechamiento del gas asociado en plataformas petroleras, caso de estudio campo Sacha*. Universidad Central del Ecuador.
<https://doi.org/https://doi.org/10.29166/revfig.v12i2.3090>
- Daramola, G., Jacks, B., Ajala, O., & Akinoso, A. (2024). *AI Applications in Reservoir Management: Optimizing Production and Recovery in Oil and Gas Fields*. *Computer Science & IT Research Journal*.
<https://doi.org/https://doi.org/10.51594/csitrj.v5i4.1083>
- Díaz, C., Guarín, F., González, J., García, C., Cotes, E., & Rodríguez, C. (2010). *Optimization of electrical submersible pump artificial lift system for extraheavy oils through an analyses of botton dilution screme*. Bucaramanga, Colombia: Instituto Colombiano del Petróleo. <https://dialnet.unirioja.es/descarga/articulo/3350380.pdf>

- dos Santos Póvoas, M., Freire, J., Virgínio, S., da Silva, C., Santos, B., Azevedo, A., & Brito, G. (2025). *Artificial Intelligence in the Oil and Gas Industry: Applications, Challenges, and Future Directions*. Applied Sciences. <https://doi.org/https://doi.org/10.3390/app15147918>
- Durán, C. (2024). *How the Oil & Gas Industry Can Benefit from AI and Deep Learning* .
- Economides, M., Hill, A., Economides, C., & Zhu, D. (2014). *Petroleum Production Systems*. Massachusetts. <https://ptgmedia.pearsoncmg.com/images/9780137031580/samplepages/0137031580.pdf>
- EP Petroecuador . (2022). *EP Petroecuador mantiene su tendencia de producción al alza con seis campañas de perforación*. EP Petroecuador. https://www.eppetroecuador.ec/?p=15263&utm_source
- EP Petroecuador. (2024). *Bloques Petroleros*. <https://www.eppetroecuador.ec/wp-content/uploads/2024/12/Bloques-petroleros.pdf>
- EP Petroecuador. (2025). *Campaña de perforación supera expectativas, eleva la producción petrolera diaria e inyecta recursos a la economía nacional*. EP Petroecuador. https://www.eppetroecuador.ec/?p=27314&utm_source
- European Commission. (2020). *AI Watch Historial Evolution of Artificial Intelligence: Analysis of the three main paradigm shifts in AI*. Office of the European Union. <https://ec.europa.eu/jrc>
- Fan, C., Chen, M., Wang, X., Wang, J., & Huang, B. (2021). *A Review on Data Preprocessing Techniques Toward Efficient and Reliable Knowledge Discovery From Building Operational Data*.
- Fan, Z., Lui, X., Wang, Z., Liu, P., & Wang, Y. (2024). *A novel ensemble machine learning model for oil production prediction with two-stage data preprocessing*. <https://doi.org/https://doi.org/10.3390/pr12030587>

- Feng, Y., Li, Y., Wang, K., & Liu, L. (2025). *A review of the applications of big data and artificial intelligence in oilfield reservoir and fluid dynamics simulation: Feature analysis and development optimization*. *Advances in Resources Research*.
https://doi.org/https://doi.org/10.50908/arr.5.1_46
- Ferrara, E. (2023). *Fairness and Bias in Artificial Intelligence: A Brief Survey of Sources, Impacts, and Mitigation Strategies*. *Computer Sciences, Mathematics and AI*.
<https://doi.org/https://doi.org/10.3390/sci6010003>
- Ferrer, X., Nuenen, T., Such, J., Cote, M., & Criado, N. (2021). *Bias and Discrimination in AI: a cross-disciplinary perspective*.
<https://doi.org/https://doi.org/10.1109/MTS.2021.3056293>
- Franca, R., Miranda, V., & Cisneros, P. (2013). *Energía: Una visión sobre los restos y oportunidades en America Latina y el Caribe*. CAF.
- Galo, J., Di Martino, E., Velásquez, J., & Delgadillo, A. (2023). *Tecnologías de Inteligencia Artificial (AI) en el Mantenimiento de Activos del Sector Eléctrico*. (J. Irigoyen, A. Alarcón, & E. Daza, Edits.) Banco Interamericano de Desarrollo.
- Ghorna, L., Elly, A., Oladele, S., & Ahsun, A. (2024). *The Importance of Data Quality in Data-Driven Decision-Making*.
https://www.researchgate.net/publication/387366223_The_Importance_of_Data_Quality_in_Data-Driven_Decision-Making
- Global Atlas. (2025). *EJAtlas - Global Atlas of Environmental Justice*. <https://ejatlas.org/>
- Gonzalez, M., Ordoñez, H., & Gonzalez, J. (2025). *Navigating the Tension Between Algorithmic and Human Ethics: Toward a Responsible Balance*. *Revista Facultad De Ingeniería*.
<https://doi.org/http://dx.doi.org/10.19053/uptc.01211129.v34.n71.2025.19650>
- Goodfellow, I. (2016). *Deep Learning*.
https://www.deeplearningbook.org/slides/01_intro.pdf

- Gutierrez, C. (2019). *ESTRATEGIA CORPORATIVA PARA INCREMENTO DE RESERVAS RECUPERABLES DE PETRÓLEO MEDIANTE LA RECUPERACIÓN SECUNDARIA, APLICADA A YACIMIENTOS DE LA CUENCA ORIENTE DEL ECUADOR*. Quito, Pichincha, Ecuador: ESCUELA POLITÉCNICA NACIONAL .
<https://bibdigital.epn.edu.ec/bitstream/15000/20545/1/CD%2010038.pdf>
- Hall, K., Mazza, A., & Kearney, W. (2024). *Scientific Progress in Artificial Intelligence History, Status and Futures*. University of Pennsylvania Press.
https://erichorvitz.com/AI_Overview_History_Status_Futures_February_2024.pdf
- Hammood, M., Marin, L., Goga, N., & Popa , R. (2021). *Oil and Gas Pipeline Monitoring during COVID-19 Pandemic via Unmanned Aerial Vehicle*.
<https://doi.org/https://doi.org/10.48550/arXiv.2111.09155>
- Hochreiter, S., & Schmidhuber, J. (1997). *Long Short Term Memory*.
<https://www.bioinf.jku.at/publications/older/2604.pdf>
- HubTechia. (2025). *AI abd IAGEM Application Use Case*. <https://hubtechia.com.ar/wp-content/uploads/2025/04/5.-Report-AI-for-Optimizing-Maintenance-Cycles-in-Vaca-Muerta.pdf>
- HubTechia. (2025). *Energy Optimization in the Oil Industry: Predictive Analysis of Wekk Performance in Vaca Muerta*. HubTechia.
- Hussain, Z. (2023). *Well Production Forecasting Using Modern Deep Learning Models*.
https://pangea.stanford.edu/ERE/pdf/pereports/MS/Alali_Zainab2023.pdf
- Ibrahim, H. (2022). *Artificial Inteligence for predictive maintenance*. Journal of Physics Conference Series . <https://doi.org/10.1088/1742-6596/2299/1/012001>
- Iftikhar, N., Lin, Y., & Nordbjerg, E. (2022). *Machine Learning bases Predictive Maintenance in Manufacturing Industry*. ACITEPRESS - Science and Technology Publication . <https://doi.org/10.5220/0011537300003329>

- IteXus. (2025). *AI in Oil and Gas: Revolutionizing the Energy Industry*. IteXus. https://itexus.com/ai-in-oil-and-gas-revolutionizing-the-energy-industry/?utm_source
- Jouppi, N., Young, C., Patil, N., Patterson, D., Agrawal, G., Bajwa, R., . . . Coriell, J. (2017). *In-Datacenter Performance Analysis of a Tensor Processing Unit*. Toronto, Canadá: International Symposium on Computer Architecture.
- Juez, B. (1998). *Detección de problemas de alto corte de agua en el yacimiento hollín principal y sus posibles soluciones: bloque 7, del Oriente Ecuatoriano*. Escuela Politecnica del Litoral. <http://www.dspace.espol.edu.ec/handle/123456789/61185>
- Juez, B., Colmont, G., & Arteaga, L. (1990). *Detección de problemas de alto corte de agua en el yacimiento Hollín principal y sus posibles soluciones: Bloque 7, del oriente ecuatoriano*. <https://doi.org/https://core.ac.uk/download/12393554.pdf>
- Kak , A. (2025). *Autograd for Automatic Defferentiation and for Auto Construction of Computational Graphs*. Purdue University. <https://engineering.purdue.edu/kak/pdf-kak/AutogradAndCGP.pdf>
- Kanfar, R., Shaikh, O., Yousefzadeh, M., & Mukerji, T. (2020). *Real-Time Well Log Prediction From Drilling Data Using Deep Learning* . OnePetro. <https://doi.org/https://doi.org/10.2523/IPTC-19693-MS>
- Koroteev, D., & Tekic, Z. (2020). *Artificial intelligence in oil and gas upstream: Trends, challenges, and scenarios for the future*. <https://doi.org/https://doi.org/10.1016/j.egyai.2020.100041>
- Lars Buitinck, Gilles Louppe, Mathieu Blondel, Fabian Pedregosa, Andreas Mueller, Olivier Grisel, & Vlad Niculae. (2013). *API design for machine learning software: experiences from the scikit-learn project*. Cornell Unicersity. <https://doi.org/https://doi.org/10.48550/arXiv.1309.0238>
- Latrach, A. (2020). *Application of Deep Learning for Predictive Maintenance of Oilfield Equipment*. <https://doi.org/http://dx.doi.org/10.13140/RG.2.2.12595.09762>

- Latrach, A., Lamine, M., Morales M., Mehana, M., & Rabiei M. (2023). *A Creitical Review of Physics-informed Machine Learning Aplications in Subsurface Energy Systems*. <https://doi.org/https://doi.org/10.48550/arXiv.2308.04457>
- LeBlanc, M. (2020). *Digital Twin Technology for Enhanced Upstream Capability in Oil and Gas*. MASSACHUSETTS INSTITUTE OF TECHNOLOGY. <https://dspace.mit.edu/bitstream/handle/1721.1/132840/1263186138-MIT.pdf>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep Learning*. Macmillan Publishers . <https://doi.org/doi:10.1038/nature14539>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). *Gradient - Based Learning Appliet to Documento Recognition*. IEEE. http://vision.stanford.edu/cs598_spring07/papers/Lecun98.pdf
- Li, H., Yu, H., Cao, N., & Tian, H. (2020). *Applications of Artificial Intelligence in Oil and Gas Development*. Archives of Computational Methods in Engineering. <https://doi.org/http://dx.doi.org/10.1007/s11831-020-09402-8>
- Li, X., Zhang, Y., & Zhou, W. (2020). *Application of artificial neural networks for ail production prediction in mature fields*. *Energy Exploration & Exploitation*. <https://doi.org/https://doi.org/10.1177/0144598720918173>
- Liang, C., Le, T., Ham, Y., Mantha, B., Cheng, M., & Lin, J. (2023). *Ethics of Artificial Intelligence and Robotics in the Architecture, Engineering, and Construction Industry*. <https://doi.org/https://doi.org/10.1016/j.autcon.2024.105369>
- Litjens, G., Kooi, T., Ehteshami, B., Arindra, A., Ciompi, F., Ghafoorian, M., . . . Sanchez, C. (2017). *A Survey on Deep Learning in Medical Image Analysis*. Nijmegen, Netherlands: Radboud University Medical Center. <https://arxiv.org/pdf/1702.05747>
- Liu, Z., Yi, T., Huang, C., Choy, K., & Liu, C. (2021). *Thermodynamic and kinetics of hydrogen photoproduction enhancement by concentrated sunlight with CO2 photoreduction by heterojunction photocatalysts*. <https://doi.org/https://doi.org/10.1016/j.egyai.2021.100102>

- Lopez, M. (2014). *Explotación del Gas Natural en el sector fabril del parque industrial de Cuenca*. Cuenca, Ecuador: Universidad de Cuenca. <https://dspace-test.ucuenca.edu.ec/bitstream/123456789/19859/1/TESIS.pdf>
- Martinez, J., Buso, F., Kouzoupis, A., Ormenisan, A., Niazi, S., Bzhalava, D., . . . Dowling, J. (2024). *The Hopworks Feacture Store for Machine Learning*. SIGMOD. https://content.hopsworks.ai/hubfs/The_Hopsworks_Feature_Store_for_Machine_Learning.pdf
- Mattson, P., Cheng, C., Coleman, C., Diamos, G., Micikevicius, P., Patterson, D., . . . Dutta, D. (2020). *MLPerf Training Benchmark*. <https://arxiv.org/pdf/1910.01500>
- Meeting, H. (1944). *Analysis of Decline Curyes*.
- Méndez, A. (2006). *Fundamentos de Gas en Lenguaje no Técnico*. Caracas, Venezuela .
- Mera, K. (2022). *Aplicación de técnicas de machine learning en la predicción de la corrosión en las operaciones petroleras de Ecuador*. Escuela Politécnica Nacional. <http://bibdigital.epn.edu.ec/handle/15000/23032>
- Mijwil, M. (2015). *History of Artificial Intelligence*. <https://doi.org/https://doi.org/10.13140/RG.2.2.16418.15046>
- Ministerio de Energía y Minas, E. (2023). *Estadística Hidrocarburos 2021*. Quito, Ecuador : Ministerio de Energía y Minas. <https://www.ambienteyenergia.gob.ec/wp-content/uploads/downloads/2023/04/Estadisticas-hidrocarburiferas.pdf>
- Moritz, P., Nishihara, R., Wang, S., Tumanov, A., Liaw, R., Liang, E., . . . Stoica, I. (2018). *A Distributed Framework for Emerging AI Applications*. Symposium on Operating Systems Desing and Implementation. <https://www.usenix.org/conference/osdi18/presentation/nishihara>
- Murel, J., & Kavlkoglu, E. (2024). *Aprendizaje IA por refuerzo*.

- Musa, A. (2023). *Revolutionizing Oil and Gas Industries with Artificial Intelligence Technology*. International Journal of Computer Sciences and Engineering .
<https://doi.org/http://dx.doi.org/10.26438/ijcse/v11i5.2030>
- Nagao, M., Datta, A., Onishi, T., & Sankaran, S. (2024). *Physics Informed Machine Learning for Reservoir Connectivity Identification and Robust Production Forecasting* . Data-Science-Engineering-Analytics.
<https://doi.org/https://doi.org/10.2118/219773-PA>
- Nanjar, A., Eko, R., & Berlilana , B. (2024). *Machine Learning and Deep Learning Approaches for Energy Prediction: A Systematic Literature Review*.
<https://doi.org/http://dx.doi.org/10.33395/sinkron.v8i4.14208>
- Ohelete, N., Olusegun, A., Chigozie, E., & Efosa , P. (2023). *Advancements in predictive maintenance in the oil and gas industry: A review of AI and data science applications*. <https://doi.org/https://doi.org/10.30574/wjarr.2023.20.3.2432>
- Olaf, Z., & Ru, Z. (2020). *Supervised Machine Learning Methods for Classification*. Hamburg University of Applied Sciences.
- Oliveira, R., Prates, R., Moura, R., Moreira, M., Castro, M., Soriano, A., . . . Rocha, A. (2022). *Data-driven deep-learning forecasting for oil production and pressure*.
<https://doi.org/https://doi.org/10.1016/j.petrol.2021.109937>
- Panbarasan , M., Sankar, S., Venkateshbabu, S., & Balasubramanian, A. (2022). *Characterization and performance enhancement of electrical submersible pump (ESP) using artificial intelligence (AI)*.
<https://doi.org/https://doi.org/10.1016/j.matpr.2022.05.101>
- Paske, A., Gross, S., Massa, F., Lerer, A., Bradburry, J., Chanan, G., . . . Chintala, S. (2019). *PyTorch: An Imperative Style, High performance Deep Learning Library*.
<https://arxiv.org/pdf/1912.01703>

- Peace, P., Chris, J., & Victor, L. (2024). *Data Preprocessing for AI Models*. https://www.researchgate.net/publication/385707249_Data_Preprocessing_for_AI_Models
- Peralta, B. (2020). *Desarrollo de una red neural artificial para la predicción de la tendencia corrosiva e incrustante en tuberías de producción de petróleo*. Escuela Politécnica Nacional. <http://bibdigital.epn.edu.ec/handle/15000/20837>
- Quintero, N., Reina, A., Ruiz, O., & Salinas, E. (2025). *Interligencia Artificial en la Industria*. Universidad Nacional Experimental de Guayana .
- Rahmanifard, H., & Gates, I. (2024). *A Comprehensive review of data-driven approaches for forecasting production from unconventional reservoirs: best practices and future directions*. <https://doi.org/https://doi.org/10.1007/s10462-024-10865-5>
- Rajbhandari, S., Rasley, J., & Ruwase, O. (2020). *Memory Optimizations Toward Training Trillion Parameter Models*. <https://arxiv.org/pdf/1910.02054>
- Rashad, M. (2019). *Performance analyses techniques to oprimize an oil well in northern Iraq*. Near East University. <https://docs.neu.edu.tr/library/6805959961.pdf>
- Rumelhart, D., Hinton, G., & Williams, R. (1990). *Learning representations by back-propagating errors*.
- Saghir, F. (2025). *Technology Focus: Artificial Lift* . Journal of Petroleum Technology. <https://doi.org/https://doi.org/10.2118/1025-0012-JPT>
- Samad, A., Muhammad, I., & Sakib, A. (2025). *Data-driven approach yo predict future oil production of an Oil Field using machine learning techniques*.
- Santos, M., Freire, J., Martins, S., Silva, C., Santos , B., Azevedo , A., & Alves, G. (2025). *Artificial Intelligence in the Oil and Gas Industry: Applications, Challenges, and Future Directions*.

- Santos, R., Hernández, P., & Ramírez, J. (2024). *Forecasting oil well decline using hybrid machine learning models*. Journal of Energy Resources Technology. <https://doi.org/https://doi.org/10.1115/1.4063459>
- Sapio, A., Canini, M., Ho, C., Nelson, J., Kalnis, P., Kim, C., . . . Richtarik, P. (2021). *Scaling Distributed Machine Learning with In-Network Aggregation*. <https://www.usenix.org/system/files/nsdi21-sapio.pdf>
- Schmidhuber, J. (2014). *Deep Learning in Neural Networks: An Overview*. University of Lugano & SUPSI. <https://arxiv.org/pdf/1404.7828>
- Sedir Mohammed, Lukas Budach, Moritz Feuerpfeil, Nina Ihde, Andrea Nathansen, Nele Noack, . . . Hazar Harmouch. (2022). *The Effects of Data Quality on Machine Learning Performance on Tabular Data*. Cornell University. <https://doi.org/https://doi.org/10.48550/arXiv.2207.14529>
- Serna, E., Serna, A., & Acevedo, E. (2017). *Principios y características de las redes neuronales artificiales*. Editorial Instituto Antioqueño de Investigación.
- Shaikha, A. (2022). *Applying machine learning models to diagnose failures in electrical submersible pumps*. <https://shareok.org/handle/11244/336890>
- Shankar, G. (2024). *Artificial intelligence for predictive maintenance in oil and gas operations*. Word Journal of Advenced Research and Reviews. <https://doi.org/https://doi.org/10.30574/wjarr.2024.23.3.2721>
- Sina, A., Abdolalizadeh, L., Mako, C., Torok, B., & Amir, M. (2022). *Systematic review of deep learning and machine learning for building energy*. Cornell University. <https://doi.org/https://doi.org/10.48550/arXiv.2202.12269>
- Smith, C., McGuire, B., Huang, T., & Yang, G. (2006). *The History of Artifical Intelligence*. University Washington. <https://courses.cs.washington.edu/courses/csep590/06au/projects/history-ai.pdf>

- Soni, A., Arora, C., Kaushik, R., & Upadhyay, V. (2023). *Evaluating the Impact of Data Quality on Machine Learning Model Performance*. Journal of Nonlinear Analysis and Optimization. <https://doi.org/http://dx.doi.org/10.36893/JNAO.2023.V14I1.0013-0018>
- Strubell, E., Ganesh, A., & McCallum, A. (2019). *Energy and Policy Considerations for Deep Learning in NLP*. Florence, Italia: Association for Computational Linguistics. <https://aclanthology.org/P19-1355.pdf>
- Sui, X., Lu, X., Ji, Y., Yang, Y., Peng, J., Li, M., & Han, G. (2024). *Intelligent Oil Production Management System Based on Artificial Intelligence Technology*. <https://doi.org/https://doi.org/10.3390/pr13010133>
- Syed, F., Alshamsi, M., Dahaghi, A., & Neghabhan, S. (2022). *Artificial lift system optimization using machine learning applications*. https://www.researchgate.net/publication/363763968_Artificial_lift_system_optimization_using_machine_learning_applications-NC-ND_license_http_creativecommonsorglicensesby-nc-nd40
- Tae, K., Roh, Y., Oh, Y., Kim, H., & Whang, S. (2019). *Data Cleaning for Accurate, Fair, and Robust Models: A Big Data - AI Integration Approach*. Cornell University. <https://doi.org/https://doi.org/10.48550/arXiv.1904.10761>
- Tang, X., Chen, J., Qin, Y., Liu, T., Yang, K., Khajepour, A., & Li, S. (2024). *Reinforcement Learning-Bases Energy Management for Hybrid Power Systems: State of the Art Survey, Review and Perspectives*. Chinese Journal of Mechanical Engineering. <https://doi.org/https://doi.org/10.1186/s10033-024-01026-4>
- The Global Economy, C. (2023). *Oil Production*. https://www.theglobaleconomy.com/ecuador/oil_production/?utm_source
- Touzani, S., Prakash, A., Wang, Z., Agarwal, S., Pritoni, M., Kiran, M., . . . Granderson, J. (2021). *Controlling distributed energy resources via deep reinforcement learning for*

load flexibility and energy efficiency.
<https://doi.org/https://doi.org/10.1016/j.apenergy.2021.117733>

Universidad Europea. (2022). *Aprendizaje supervisado y no supervisado* . Universidad Europea .

Wachtmeister, H., Lund, L., Aleklett, K., & Hook, M. (2017). *Production Decline Curves of Tight Oil Wells in Eagle Ford Shele*. <https://doi.org/10.1007/s11053-016-9323-2>

Wang, M., Su, X., Song, H., Wang, Y., & Yang, X. (2025). *Enhancing predictive maintenance strategies for oil and gas equipment through ensemble learning modeling*. *Journal of Petroleum Exploration and Production Technology*. https://link.springer.com/article/10.1007/s13202-025-01931-x?utm_source

Weaver, J. (2023). *Forecasting Oil and Gas Using Decline Curves*. Continuing Education and Development, Inc. <https://www.cedengineering.com/userfiles/Forecasting%20Oil%20and%20Gas%20Using%20Decline%20Curves.pdf>

Wongsuphasawat, K., Smilkov, D., Wexler, J., Wilson, J., Mané, D., Fritz, D., . . . Wattenberg, M. (2018). *Visualizing Dataflow Graphs of Deep Learning Models in TensorFlow*. University of Washington.

Zhou, Y., Tu, F., Sha, K., Ding, J., & Chen, H. (2024). *A Survey on Data Quality Dimensions and Tools for Machine Learning*. University of North Texas. <https://arxiv.org/pdf/2406.19614>

Zhu, D., Yang, B., Liu, Y., Wang, Z., Ma, K., & Guan, X. (2022). *Energy Mnagement Based in Multi-Agent Deep Reinforcement Learning for A Multi-Energy Industrial Park*. Cornell University. <https://doi.org/https://doi.org/10.1016/j.apenergy.2022.118636>

Zhu, R., Li, N., Duan, Y., Li, G., Liu, G., Qu, F., . . . Li, G. (2025). *Well-Production Forecasting Using Machine Learning with Feature Selection and Automatic Hyperparameter Optimization*. <https://doi.org/https://doi.org/10.3390/en18010099>

Zhu, Y., Li, J., & Wang, H. (2025). *Intelligent Optimization of Oil Production in Mature Fields Using Deep Reinforcement Learning* . Journal of Petroleum Science and Engineering. <https://doi.org/https://doi.org/10.1016/j.petrol.2025.112985>

1.

