

APLICACIÓN DEL MANTENIMIENTO PREDICTIVO EN LA INDUSTRIA PETROLERA:
UNA REVISIÓN EXHAUSTIVA



Por:
YEKINI MATEO GUTIÉRREZ JIMÉNEZ



UNIVERSIDAD SANTO TOMÁS
FACULTAD DE INGENIERÍA MECÁNICA
VILLAVICENCIO
2025

APLICACIÓN DEL MANTENIMIENTO PREDICTIVO EN LA INDUSTRIA PETROLERA:
UNA REVISIÓN EXHAUSTIVA

Por:

YEKINI MATEO GUTIÉRREZ JIMÉNEZ

Trabajo de grado como requisito para optar al título de Especialista en Gerencia de
Mantenimiento y Gestión de Activos

Asesor

Mg. JERSON FABIAN MALDONADO MORENO

Magister En Ingeniería Mecánica

UNIVERSIDAD SANTO TOMÁS
FACULTAD DE INGENIERÍA MECÁNICA
VILLAVICENCIO

2025

Autoridades Académicas

P. Álvaro José ARANGO RESTREPO, O.P.

Rector General

P. Mauricio Antonio CORTÉS GALLEGUO, O.P.

Vicerrector Académico General

P. José Antonio BALAGUERA CEPEDA, O.P.

Rector Seccional Villavicencio

P. Adrián Mauricio GARCÍA PEÑARANDA, O.P.

Vicerrector Académico Seccional Villavicencio

Mg. Julieth Andrea SIERRA TOBÓN

Secretaria de General Seccional Villavicencio

PhD. Handel Andrés MARTÍNEZ SARACHE

Decano de la Facultad de Ingeniería Mecánica

Dedicatoria

Este trabajo se lo dedico a mis padres, Yesid Guiérrez y Marina Jiménez por su amor incondicional, por creer en mí incluso en los momentos en que yo dudé de mis propias capacidades, y por enseñarme con su ejemplo el valor del esfuerzo, la perseverancia y la humildad. Gracias por ser mi mayor inspiración y por darme siempre el impulso necesario para seguir adelante.

A mi abuelo, Leonidas Jiménez espero que, desde el más allá, pueda ver que su querido nieto ha alcanzado esta meta. Este logro lo dedico a su memoria con todo mi cariño y gratitud por haber sido una parte tan importante de mi vida.

Este trabajo es para ustedes, los pilares de mi vida. Sin ustedes, este sueño no habría sido posible.

Agradecimientos

Le agradezco a mis padres por todo lo que han hecho por mí, por su esfuerzo por una educación superior, por enseñarme y educarme, por la vida, por todo, espero poder retribuir, aunque sea una pequeña parte, de todo lo que ustedes han hecho por mí. Su confianza en mí siempre ha sido mi mayor motivación, los amo.

A mi hermano, su apoyo constante ha sido fundamental para superar los desafíos que encontré durante este proceso.

A mi director, Jerson Maldonado, por su guía y compromiso en cada etapa de este trabajo. Su conocimiento, dedicación y orientación no solo enriquecieron este proyecto, sino que también dejaron en mí valiosas lecciones para el futuro.

Y, sobre todo, a Dios, por darme la vida, la salud y la oportunidad de recorrer este camino. A Él le debo la sabiduría y la fuerza que me permitieron superar los desafíos y alcanzar esta meta. Su presencia ha sido mi guía en cada paso de este viaje, y a Él dedico con gratitud todo lo que he logrado.

Contenido

	Pág.
Resumen	9
Abstract.....	10
Glosario.....	11
1. Introducción.....	12
2. Planteamiento del Problema.....	14
3. Justificación.....	16
4. Objetivos	18
4.1. Objetivo General.....	18
4.2. Objetivos específicos	18
5. Metodología.....	19
6. Marco Teórico	22
7. Resultados	24
7.1. Árbol de Decisiones.....	24
7.2. Machine Learning	25
7.3. Redes Neuronales y Deep Learning.....	26
7.4. Máquinas de Soporte Vectorial SVM.....	32
7.5. Transfer Learning.....	36
7.6. Regresión	37
7.7. Weibull.....	38
7.8. Otros métodos	39
Tabla 1	44
Tabla 1	45
8. Analisis.....	46
9. Conclusiones	50
10. Referencias.....	52

Lista de Tablas

Pág.

Tabla 1 Tecnicas y sus Respectivas Aplicaciones.	43
--	----

Lista de Figuras

Pág.

Figura 1 Diagrama de Flujo	19
Figura 2 Distribución de Métodos de Mantenimiento Predictivo en la Industria Petrolera	49

Resumen

El mantenimiento predictivo ha revolucionado la industria petrolera al optimizar la gestión de activos y reducir los costos operativos mediante la anticipación de fallas en equipos críticos. Este trabajo revisa exhaustivamente las tecnologías aplicadas en el sector, destacando el uso de machine learning, redes neuronales, máquinas de soporte vectorial y el análisis de Weibull. Se analizan estudios recientes que han implementado estas técnicas para mejorar la confiabilidad de sistemas de bombeo, turbocompresores y otros equipos clave. Los resultados demuestran que el uso de algoritmos avanzados permite predecir fallos con alta precisión, reduciendo tiempos de inactividad y optimizando la toma de decisiones en mantenimiento. Finalmente, se identifican los principales desafíos en la implementación de estas tecnologías y se proponen futuras líneas de investigación para mejorar su adopción en la industria petrolera.

Palabras Clave: mantenimiento predictivo, industria petrolera, machine learning, redes neuronales, SVM, diagnóstico de fallas.

Abstract

Predictive maintenance has revolutionized the oil industry by optimizing asset management and reducing operational costs through the anticipation of failures in critical equipment. This article provides a comprehensive review of the technologies applied in the sector, highlighting the use of machine learning, neural networks, support vector machines, and Weibull analysis. Recent studies that have implemented these techniques to enhance the reliability of pumping systems, turbo compressors, and other key equipment are analyzed. The results demonstrate that the use of advanced algorithms enables highly accurate failure prediction, reducing downtime and optimizing maintenance decision-making. Finally, the main challenges in implementing these technologies are identified, and future research directions are proposed to improve their adoption in the oil industry.

Key Words: Predictive maintenance, oil industry, machine learning, neural networks, SVM, fault diagnosis.

Glosario

Árbol de Decisión: Modelo de machine learning utilizado para clasificar datos y tomar decisiones basadas en múltiples variables, aplicado en el diagnóstico de fallas en la industria petrolera.

Deep Learning: Subcampo del aprendizaje automático basado en redes neuronales profundas, utilizado para analizar datos complejos y mejorar la precisión en la predicción de fallas.

Industria Petrolera: Sector económico dedicado a la exploración, extracción, refinamiento, transporte y comercialización de petróleo y sus derivados.

Machine Learning (Aprendizaje Automático): Rama de la inteligencia artificial que permite a los sistemas aprender y mejorar automáticamente a partir del análisis de grandes volúmenes de datos sin ser programados explícitamente.

Mantenimiento Predictivo: Estrategia de mantenimiento basada en el monitoreo continuo de equipos y el análisis de datos para predecir fallas antes de que ocurran, permitiendo intervenciones oportunas.

Máquinas de Soporte Vectorial (SVM, por sus siglas en inglés): Algoritmos de aprendizaje automático utilizados para la clasificación y análisis de datos, empleados en el mantenimiento predictivo para la detección de fallas.

Optimización de Activos: Estrategia que busca maximizar la eficiencia y vida útil de los equipos mediante el uso de técnicas avanzadas de mantenimiento predictivo y gestión de datos.

Redes Neuronales: Modelos computacionales inspirados en el funcionamiento del cerebro humano, utilizados para procesar información, reconocer patrones y hacer predicciones en aplicaciones de mantenimiento predictivo.

Regresión: Técnica estadística utilizada para predecir valores futuros basados en datos históricos, comúnmente empleada en la evaluación del desgaste y la vida útil de los equipos.

Transfer Learning (Aprendizaje por Transferencia): Técnica de aprendizaje automático que reutiliza modelos preentrenados para mejorar la precisión en nuevas aplicaciones con menor cantidad de datos.

1. Introducción

La industria petrolera es una de las bases fundamentales de la economía mundial, ya que es la encargada de suministrar la energía necesaria para impulsar una amplia variedad de actividades industriales, comerciales y domésticas. Sectores como el transporte, la energía, la química, la manufactura, la agricultura, el textil, la farmacéutica, la aeronáutica y espacial dependen crucialmente del petróleo y sus derivados para su funcionamiento en la sociedad moderna (Navarro, 2023). De esta manera, esta industria es una fuente significativa de empleo, de forma directa en trabajos como extracción, refinación y distribución de petróleo, y de forma indirecta en trabajos de los otros sectores que dependen de esta misma (Navarro, 2023). Por lo tanto, la estabilidad y eficiencia en la producción de petróleo influyen directamente en aspectos que van desde la economía cotidiana, como los precios de la energía, hasta la economía global en su conjunto (Navarro, 2023).

En la industria petrolera, la confiabilidad y eficiencia de los equipos son esenciales para garantizar una producción continua y rentable. La interrupción no planificada de estos sistemas debido a fallas mecánicas puede resultar en pérdidas significativas, tanto en términos de producción como de costos de reparación. En este contexto, el mantenimiento predictivo ha emergido como una solución efectiva para mitigar estos riesgos (Paredes, 2020). El mantenimiento predictivo se basa en la utilización de datos en tiempo real y análisis avanzados para predecir cuándo es probable que ocurra una falla en un equipo, permitiendo intervenciones antes de que se materialice el problema. Este enfoque no solo minimiza el tiempo de inactividad, sino que también optimiza los recursos y extiende la vida útil de los equipos. Entre las principales técnicas de procesamiento de la información relacionada con el mantenimiento predictivo, se resalta el aprendizaje automático y el análisis de datos; las cuales permiten una mejora significativa en la precisión de las predicciones, permitiendo el desarrollo de modelos avanzados que analicen grandes volúmenes de datos para identificar patrones complejos y prever eventos futuros (Silveira et al., 2024).

Uno de los principales beneficios del mantenimiento predictivo es que al realizar un monitoreo continuo se aseguran de que los elementos de máquinas sean reemplazados solo cuando realmente es necesario, reduciendo el desperdicio y optimizando el uso de los recursos disponibles, minimizando tiempo de paradas, incrementando la confiabilidad y disponibilidad de

los equipos, mejorando la seguridad al identificar problemas antes de que se conviertan en riesgos graves, y garantizándose realizar un mantenimiento de manera oportuna y basado en el estado real del equipo. En un entorno tan complejo y exigente como el de la industria petrolera, donde se emplean una amplia variedad de equipos críticos como bombas, compresores, turbinas y plataformas de perforación. La implementación de estrategias predictivas puede marcar una diferencia significativa en la eficiencia operativa. En conjunto, contribuyen a una mayor rentabilidad y competitividad al minimizar el tiempo de inactividad y los costos imprevistos (Paredes, 2020).

En este trabajo se recopilarán y analizarán diversos artículos relacionados con el mantenimiento predictivo en la industria petrolera. Inicialmente, se llevará a cabo una búsqueda exhaustiva para identificar investigaciones relevantes, las cuales serán filtradas conservando únicamente aquellas con mayor impacto y resultados sólidos. Posteriormente, se analizarán en detalle los estudios seleccionados, evaluando qué realizaron, cómo lo hicieron y cuáles fueron sus hallazgos. A continuación, se realizará un análisis general para identificar los modelos predictivos más utilizados, los equipos más estudiados, las regiones de origen de los trabajos y se compararán las precisiones obtenidas en los enfoques presentados. Finalmente, se destacarán las tecnologías y herramientas empleadas y los beneficios que el mantenimiento predictivo ofrece a la industria.

2. Planteamiento del Problema

En la industria petrolera, los equipos esenciales como bombas, compresores, turbinas y plataformas de perforación son sometidos a condiciones operativas extremas, lo que los hace vulnerables a fallas inesperadas. Estas fallas no solo interrumpen las operaciones y generan pérdidas económicas significativas, sino que también pueden causar problemas de seguridad y medioambientales (Eyoh & Kalawsky, 2018). A pesar de la implementación de estrategias de mantenimiento preventivo, muchas veces estas fallas ocurren sin previo aviso, lo que pone en evidencia la necesidad de adoptar enfoques más avanzados para la gestión y el mantenimiento de estos equipos (Eyoh & Kalawsky, 2018).

Tradicionalmente, las estrategias de mantenimiento en la industria petrolera se han basado en modelos reactivos y preventivos (Eyoh & Kalawsky, 2018). El mantenimiento reactivo se enfoca en reparar equipos solo después de que han fallado, lo que conlleva altos costos y tiempos de inactividad (F. A. Pérez, 2021). Por otro lado, el mantenimiento preventivo, aunque programado regularmente, no siempre es eficiente para prevenir fallas imprevistas, ya que no tiene en cuenta las condiciones reales y el desgaste de los equipos en tiempo real (Calderon, 2021).

A pesar del creciente interés y la adopción de tecnologías de mantenimiento predictivo, aún existen desafíos importantes en su implementación efectiva. Estos incluyen la integración de grandes volúmenes de datos generados por sensores en tiempo real, la necesidad de modelos de análisis de datos avanzados y el desarrollo de algoritmos de aprendizaje automático que puedan proporcionar predicciones precisas y accionables (Gupta et al., 2024). También la falta de estandarización en las prácticas y la resistencia al cambio en algunas organizaciones son limitantes a la adopción generalizada de estas tecnologías (Gupta et al., 2024).

Aunque el interés en el mantenimiento predictivo ha ido en aumento, la información relacionada con estas prácticas a menudo está fragmentada en múltiples fuentes sin una estructura coherente, lo que dificulta la recopilación y análisis sistemático de las mejores prácticas y avances en el campo. Esta falta de cohesión en los artículos disponibles impide una comprensión integral y complica la identificación de enfoques efectivos y áreas de mejora. Por lo tanto, esta revisión busca abordar este problema al proporcionar una recopilación sistemática y exhaustiva de la literatura relevante, identificando estrategias, limitaciones y oportunidades para mejorar la

implementación del mantenimiento predictivo en la industria petrolera analizando proyectos y casos específicos de los últimos 18 años.

3. Justificación

El mantenimiento predictivo se ha vuelto cada vez más importante en la industria petrolera debido a su impacto directo en la continuidad de las operaciones. Dado que el petróleo sigue siendo una de las principales fuentes de energía a nivel mundial, cualquier interrupción en su producción puede afectar los mercados energéticos y la economía global (Abdou et al., 2024). Las fallas inesperadas en equipos críticos no solo interrumpen las operaciones, sino que también pueden causar reparaciones costosas, pérdidas de producción, riesgos de seguridad, e incluso daños ambientales (Abdou et al., 2024).

Investigar sobre el mantenimiento predictivo en este sector es esencial porque permite anticipar y prevenir fallas antes de que ocurran, mejorando así la eficiencia, seguridad, y sostenibilidad de las operaciones. A medida que la tecnología de análisis de datos y aprendizaje automático avanza, se ha vuelto posible predecir fallas con mayor precisión, lo que ayuda a optimizar la gestión de los recursos. Esto incluye recursos humanos ya que la planificación y programación de mantenimientos basados en datos permite utilizar de manera más eficiente el personal especializado, también repuestos y materiales, pues al predecir cuales, y cuantas piezas podrían necesitar reemplazo en el futuro cercano, se puede gestionar mejor el inventario de piezas de repuesto, evitando la sobrecompra y el desabastecimiento (Maya, 2018).

La implementación de tecnologías predictivas en la industria petrolera enfrenta varios desafíos significativos. La complejidad de la industria, caracterizada por una gran variedad de equipos operando en condiciones extremas como temperaturas extremas, altas presiones y ambientes corrosivos, dificulta la recolección y el análisis precisos de datos. Estas condiciones pueden afectar la precisión y durabilidad de los sensores, complicando la interpretación de los datos necesarios para prever fallas. Además, la falta de estandarización en las técnicas de mantenimiento predictivo lleva a una gran variabilidad en los métodos utilizados, lo que puede causar problemas de interoperabilidad y dificultar la comparación e integración de nuevas tecnologías (Nunes et al., 2023). Finalmente, la resistencia al cambio dentro de las empresas, impulsada por la preferencia por métodos tradicionales y la necesidad de capacitación y adaptación a nuevas herramientas, puede ralentizar la adopción de tecnologías avanzadas y limitar sus beneficios potenciales (Nunes et al., 2023). Debido a estos retos, resulta esencial realizar un análisis exhaustivo y una recopilación de la información disponible sobre las tecnologías

predictivas en la industria petrolera. Esto brindaría una comprensión profunda de los desafíos actuales, además de recopilar las prácticas más eficaces y las estrategias clave para enfrentarlos, favoreciendo una adopción más eficiente y acertada de estas tecnologías en el sector, también facilitaría el acceso a mejores prácticas y lecciones aprendidas, permitiendo a los profesionales del sector tomar decisiones más informadas.

Dado el impacto crucial del mantenimiento predictivo en la continuidad operativa en la industria petrolera, es esencial revisar cómo se está implementando actualmente esta práctica en el sector. Esta revisión proporcionará una base sólida para optimizar las estrategias de mantenimiento, contribuirá a mejorar la eficiencia y sostenibilidad de las operaciones, y ofrecerá perspectivas valiosas para futuras investigaciones en el campo.

4. Objetivos

4.1. Objetivo General

Revisar exhaustivamente la aplicación del mantenimiento predictivo en la industria petrolera.

4.2. Objetivos específicos


- Revisar las principales tecnologías y herramientas utilizadas en el mantenimiento predictivo dentro de la industria petrolera, incluyendo el análisis de datos en tiempo real y el aprendizaje automático.
- Identificar los beneficios específicos que el mantenimiento predictivo puede aportar en comparación con los enfoques tradicionales de mantenimiento reactivo y preventivo en la industria petrolera.
- Investigar casos de estudio y ejemplos de empresas petroleras que han implementado con éxito estrategias de mantenimiento predictivo, destacando las mejores prácticas y lecciones aprendidas.

5. Metodología

El proceso para la elaboración de este artículo de revisión sobre el mantenimiento predictivo en la industria petrolera se llevó a cabo como se ilustra en la Figura 1.

Figura 1

Diagrama de Flujo



Búsqueda de la información: Se realizó una búsqueda exhaustiva de la literatura científica y técnica que tenga relación al tema de interés, mantenimiento predictivo en la industria petrolera. Para ello, se utilizaron bases de datos académicas como IEEE Xplore, Scopus, SciencDirect, SciELO, Springer y Google Scholar. Se priorizó la obtención de artículos recientes y relevantes para garantizar la actualidad y relevancia de la revisión.

Caracterización de la información: Una vez se recopila la información, se procede a la clasificación y organización de los documentos según su enfoque, metodología utilizada y resultados obtenidos. Se categoriza la información de diferentes temas como técnicas de análisis de datos, aplicaciones de aprendizaje automático, entre otros.

Selección de los documentos principales: De la información recopilada, se identificaron y seleccionaron los documentos más relevantes y de mayor impacto para la revisión. Se priorizaron aquellos estudios que ofrecían una visión clara de las tendencias actuales y aportaban datos empíricos sólidos o revisiones críticas sobre el tema.

Lectura y profundización: Se lleva a cabo una lectura detallada y crítica de los documentos ya seleccionados, con el fin de extraer los aspectos más significativos e importantes para el tema

de la revisión. Durante este proceso se profundiza en los métodos utilizados en los estudios y en los resultados obtenidos, enfocándose en las conclusiones y sugerencias presentadas por los autores.

Redacción: Con base en la información analizada, se procede a la redacción del artículo, estructurando el contenido de manera coherente y lógica. Se integran las diferentes fuentes de información para proporcionar una visión completa y crítica del estado actual del mantenimiento predictivo en la industria petrolera.

Se realizó una búsqueda de artículos utilizando palabras clave como Predictive Maintenance (mantenimiento predictivo), Rod Pump (bombas de varilla), Oil and Gas (petróleo y gas), Machine Learning (aprendizaje automático) y Neural Networks (redes neuronales), se hicieron diferentes ecuaciones de búsqueda como "Predictive Maintenance" AND "Rod Pump", "Machine Learning" AND "Rod Pump", ("Neural Networks" OR "Deep Learning") AND "Rod Pump", entre otros. La búsqueda se enfocó principalmente en inglés, ya que en este idioma se obtuvieron más resultados relevantes. Inicialmente, se identificaron cerca de 70 artículos provenientes de diversas bases de datos, siendo las principales Google Scholar y ScienceDirect, mientras que las demás bases contribuyeron con un menor número de resultados. Posteriormente, los artículos fueron filtrados primero por la fecha, solo se tuvieron en cuenta artículos a partir del año 2007, es decir de los últimos 18 años, después según su contenido, descartándose aquellos que no presentaban resultados sólidos. Otros artículos fueron descartados por ser de acceso restringido o de paga, lo que imposibilitó su consulta completa.

Para evaluar que los proyectos citados fueran los de mayor impacto, se consideraron múltiples criterios, en primer lugar, se priorizaron los artículos publicados en revistas y conferencias de la industria petrolera, verificando su índice de citaciones como indicador de relevancia dentro de la comunidad científica. Además, se evaluó la aplicabilidad y robustez de las metodologías propuestas, dando mayor peso a aquellos estudios que presentaban validaciones experimentales o implementaciones en entornos industriales reales. Se consideró también la innovación tecnológica en los enfoques utilizados, privilegiando investigaciones que integraran herramientas avanzadas como el aprendizaje automático y las redes neuronales para la optimización del mantenimiento de bombas de varilla. Finalmente, se revisó la alineación de los estudios con los desafíos actuales del sector, seleccionando aquellos que aportaran soluciones

escalables y eficientes para mejorar la confiabilidad y disponibilidad de los activos en la industria del petróleo

6. Marco Teórico

Para realizar mantenimiento predictivo se usan diferentes métodos, a continuación, se mencionarán algunas de ellas y su respectivo funcionamiento.

Machine learning o aprendizaje automático es un subcampo de la inteligencia artificial que permite a los sistemas aprender y mejorar automáticamente a partir de los datos, sin ser explícitamente programados. En mantenimiento predictivo, se utiliza para analizar grandes cantidades de datos históricos y operativos, identificar patrones y predecir fallas futuras en los equipos. Las técnicas más utilizadas son regresión, clasificación, algoritmos de agrupamiento (clustering) y redes neuronales (Pérez, 2024b).

Las redes neuronales son modelos computacionales inspirados en el funcionamiento del cerebro humano, diseñados para procesar información y reconocer patrones complejos. En el contexto del mantenimiento predictivo, las redes neuronales pueden analizar múltiples parámetros simultáneamente, como temperatura, presión y vibración, para detectar anomalías (Pérez, 2024a).

Los algoritmos genéticos utilizan técnicas inspiradas en la evolución natural, como la selección, cruzamiento y mutación, para optimizar el rendimiento de los equipos y predecir fallas complejas. Estos algoritmos crean soluciones iniciales (poblaciones) que representan diferentes configuraciones de operación, evaluando su eficiencia a través de una función de aptitud. Al iterar el proceso, se identifican configuraciones óptimas que minimizan el riesgo de fallas (Garduño, 2018). Este enfoque es especialmente útil en sistemas industriales complejos, como los de la industria petrolera, ya que permite resolver problemas no lineales y descubrir patrones ocultos en grandes volúmenes de datos.

La Big Data se refiere a la gestión y análisis de grandes volúmenes de datos generados a alta velocidad y en formatos diversos, como datos estructurados, semiestructurados y no estructurados. En el contexto del mantenimiento predictivo, Big Data permite recopilar información en tiempo real de sensores distribuidos en los equipos, identificar patrones y anomalías, y predecir fallos de manera precisa (M. Chen, 2024). Esto resulta esencial en la industria petrolera, donde la optimización de recursos, la reducción de tiempos de inactividad y la mejora de la confiabilidad de los sistemas dependen de la capacidad para transformar datos masivos en decisiones estratégicas.

Los algoritmos de clasificación y agrupamiento son técnicas de análisis de datos utilizadas para organizar información en categorías o grupos con características similares. En el mantenimiento predictivo, los algoritmos de clasificación permiten categorizar estados de los equipos, como "óptimo", "en riesgo" o "fallo inminente", mientras que los de agrupamiento (clustering) identifican patrones comunes entre conjuntos de datos, como equipos con comportamientos operativos similares (Manrique, 2020). Estos métodos son útiles para segmentar grandes volúmenes de datos y detectar anomalías o tendencias que ayudan a prever fallos. En la industria petrolera, estas técnicas facilitan la priorización de acciones de mantenimiento al identificar equipos críticos con mayor riesgo de falla.

7. Resultados

7.1. Árbol de Decisiones

Una de las aplicaciones más interesantes del mantenimiento predictivo en la industria petrolera es el uso de árboles de decisión para la detección de fallas en sistemas de levantamiento artificial. En el estudio “Diagnostic of Operation Conditions and Sensor Faults Using Machine Learning in Sucker-Rod Pumping Wells” de Nascimento et al. (2021) se emplearon árboles de decisión junto con bosques aleatorios y XGBoost para diagnosticar condiciones operativas y fallas en sensores de bombas de varilla de succión. Mediante el análisis de más de 50,000 tarjetas de dinamómetro provenientes de 38 pozos en Brasil, los modelos lograron clasificar con precisión las condiciones de los pozos y detectar fallas en sensores. En particular, el uso de árboles de decisión, optimizados con técnicas de ajuste de hiperparámetros, permitió alcanzar una precisión del 99.84% en la clasificación de tarjetas, demostrando su efectividad para mejorar la gestión de activos y reducir los costos operativos en la industria petrolera.

El uso de árboles de decisión también ha sido fundamental en la optimización del rendimiento de sistemas de levantamiento artificial. En el trabajo sobre “Detecting Failures and Optimizing Performance in Artificial Lift Using Machine Learning Models” de Pennel et al. (2018) se aplicaron árboles potenciados por gradiente, bosques aleatorios y redes neuronales para analizar datos operativos de 800 pozos en la formación Bakken. Estos modelos fueron entrenados con datos recopilados durante un año a través de sensores y controladores en la nube, lo que permitió diagnosticar fallas en tuberías y bombas, así como identificar configuraciones subóptimas en sistemas de gas lift y bombas de varilla. El uso de árboles de decisión dentro de este enfoque alcanzó una precisión superior al 99% en la detección de fallas, con un margen de error promedio de 31 días en activos cuya vida útil oscila entre 100 y 600 días, lo que permitió reducir tiempos de inactividad y mejorar la eficiencia operativa.

El uso del mantenimiento predictivo con árboles de decisión también ha sido aplicado de forma destacada en la investigación de Bangert y Sharaf (2019), donde se implementó un modelo basado en árboles de decisión potenciados por gradiente (GBDT) para diagnosticar fallas en bombas de varilla. En este caso, se analizaron 35,292 tarjetas dinamométricas, previamente clasificadas por expertos en 11 categorías de fallas. La combinación de árboles de decisión con

técnicas de extracción de características, como coeficientes de Fourier y coordenadas del centroide de las tarjetas, permitió que el modelo lograra una precisión del 99.9% en la clasificación de fallas, con solo siete errores en el conjunto de prueba. La implementación de este modelo en campo posibilitó la automatización del monitoreo en tiempo real de cientos de bombas, alertando de manera precisa sobre fallas específicas y reduciendo la necesidad de supervisión manual, lo que resultó en una disminución del tiempo de inactividad y un aumento en la producción de petróleo.

Finalmente, los árboles de decisión también han sido utilizados en combinación con otros algoritmos para mejorar la predicción de fallas en sistemas de levantamiento artificial tal como se presenta en “Failure Prediction for Rod Pump Artificial Lift Systems” de Y. Liu et al. (2010) donde implementaron árboles de decisión alternativos (ADTree) junto con máquinas de soporte vectorial (SVM) y redes bayesianas para predecir fallas en bombas de varilla. A partir de datos de sensores recopilados en tiempo real, el modelo empleó técnicas avanzadas de minería de datos, como la extracción de características mediante ventanas deslizantes y reducción de ruido con suavizado Lowess. Los resultados mostraron que el modelo basado en SVM alcanzó una precisión destacada, con un error del 1.7% en pozos fallidos y del 0.2% en pozos normales. En pruebas de validación realizadas en 42 pozos, la metodología predijo correctamente 5 de 6 fallas con hasta 60 días de anticipación. El uso de árboles de decisión en este contexto permitió mejorar la capacidad de toma de decisiones en mantenimiento predictivo, superando significativamente los enfoques tradicionales basados en reglas estáticas y reduciendo la carga operativa en la industria petrolera.

7.2. Machine Learning

El uso de técnicas de aprendizaje automático ha demostrado ser una herramienta eficaz para el diagnóstico predictivo en sistemas de bombeo de varilla de succión. Como se expone en el trabajo de Tran (2022) que desarrolló un modelo basado en machine learning para anticipar anomalías operativas en estos sistemas, combinando un enfoque experimental con análisis de datos. A través de un diseño experimental en la Universidad de Oklahoma, se recolectaron datos utilizando un sistema de adquisición y se aplicaron modelos de procesamiento de señales para convertir tarjetas dinamométricas de superficie en tarjetas de fondo de pozo. Posteriormente, se entrenaron y validaron modelos predictivos que lograron una precisión del 92% en la clasificación de estados operativos clave. Además, el modelo fue capaz de predecir fallas incipientes en las

bombas, lo que permite una detección temprana de problemas y una optimización en la toma de decisiones para el mantenimiento de estos sistemas.

La predicción y prevención de eventos de “flaring” en la industria petrolera es un desafío crucial para la seguridad operativa y la eficiencia energética. Tal como lo plantea Giuliani et al. (2019), desarrolló un sistema basado en Big Data y aprendizaje automático para anticipar estos eventos antes de que ocurran. El modelo se estructuró en cuatro módulos principales: diseño conceptual, procesamiento de datos, selección de características y desarrollo del modelo predictivo. A través del uso de redes neuronales artificiales, el sistema logró una precisión del 94% en la predicción de eventos de “flaring”, con una reducción significativa de falsos positivos. Además, se probó con datos operativos reales de un campo petrolero en el sur de Europa, alcanzando una precisión del 71.4% en la detección de eventos de venteo. La implementación de este modelo no solo ha mejorado la seguridad operativa, sino que también ha reducido en un 20% el impacto ambiental derivado de la quema no planificada de gases.

El diagnóstico de fallas en medidores de flujo multifásico (MPFM) es esencial para garantizar la precisión en la medición de petróleo, gas y agua en tiempo real. Como se muestra en la publicación de Barbariol et al. (2020), el cual desarrolló un sistema basado en aprendizaje automático para la detección de anomalías en sensores de MPFM. Se emplearon algoritmos de detección de anomalías no supervisados, como el método de desvío absoluto mediano (MAD), el bosque de aislamiento (IF) y el puntaje de histograma de anomalías (HBOS), complementados con análisis de causa raíz (RCA) para identificar el sensor responsable de la falla. Los resultados demostraron que el método MAD fue el más eficiente, logrando una precisión del 98% en la detección de anomalías y reduciendo el tiempo de cálculo en un 60% en comparación con otros métodos. La capacidad de este sistema para identificar fallas sin necesidad de datos históricos lo convierte en una solución altamente efectiva para mejorar la confiabilidad de los MPFM en aplicaciones industriales.

7.3. Redes Neuronales y Deep Learning

Uno de los métodos más destacados del mantenimiento predictivo es la implementación de redes neuronales para la predicción de fallas en la industria petrolera, ya que han permitido optimizar la gestión de fallas en turbocompresores dentro de este sector. Villegas y Pérez (2023)

desarrollaron un modelo de aprendizaje automático en la plataforma WEKA, utilizando redes neuronales artificiales para clasificar el estado de operación de turbocompresores en la planta compresora Muscar de PDVSA. El modelo fue entrenado con datos de sensores en campo, considerando variables como temperatura, presión y vibración. Para mejorar la toma de decisiones, se complementó el modelo con una base de conocimiento experto mediante lógica difusa en MATLAB. Como resultado, el sistema alcanzó una precisión del 99.965%, identificando correctamente fallas críticas y estados de alarma con un margen de error mínimo. La implementación de este modelo ha demostrado su efectividad en la reducción de tiempos de inactividad no programados, mejorando la confiabilidad operativa y optimizando la planificación del mantenimiento.

El Deep Learning (DL) es una rama del aprendizaje automático que utiliza redes neuronales profundas para modelar y resolver problemas complejos, y se ha destacado en la mejora de tareas de mantenimiento predictivo al automatizar la extracción de características de datos. En este contexto, el artículo “Predictive maintenance for offshore oil wells by means of deep learning features extraction” de Gatta et al. (2024) explora el uso de un Autoencoder Convolutacional 1D (CNN) para la extracción de características de datos multivariados en pozos petroleros “offshore”. Este enfoque, combinado con el algoritmo Random Forest, superó a las técnicas estadísticas tradicionales, logrando una mayor precisión en la predicción de fallas en los pozos. La aplicación de redes neuronales en este caso demostró ser más efectiva que los métodos convencionales, destacando así la efectividad de las técnicas de Deep Learning (DL) para mejorar el mantenimiento predictivo.

En la actualidad, el mantenimiento predictivo basado en Deep Learning ha emergido como una herramienta esencial en la industria petrolera, permitiendo optimizar la operación de equipos críticos mediante el análisis de datos complejos. Un ejemplo destacado de esta tendencia se encuentra en el análisis de tarjetas dinamométricas en sistemas de bombeo de varilla de succión (SRP). Estas tarjetas, que registran la dinámica del sistema de bombeo, pueden ser utilizadas para identificar fallas operativas. El uso de modelos de aprendizaje profundo ha permitido clasificar estas tarjetas en diferentes categorías, mejorando significativamente la precisión en el diagnóstico. Un estudio realizado por Martinović et al. (2023) se entrenaron varios modelos de redes neuronales profundas, como ResNet y DenseNet, para clasificar tarjetas en 11 categorías operativas. La combinación de estos modelos con técnicas interpretativas, como Grad-CAM, facilitó la

visualización de las decisiones del modelo, lo que aumentó su aplicabilidad y confiabilidad. El modelo ResNet34, en particular, logró una precisión del 94.5%, superando la capacidad de los analistas menos experimentados. Esta integración de aprendizaje profundo y visualización interpretativa no solo mejora la precisión en el diagnóstico, sino que también permite a los ingenieros realizar intervenciones más oportunas, reduciendo los costos operativos y aumentando la eficiencia del proceso.

El diagnóstico automatizado de fallas en sistemas de bombeo de varilla de succión también se ha visto beneficiado por el uso de redes neuronales auto-organizadas. Estos modelos, que aprenden de los datos sin supervisión explícita, son capaces de identificar patrones complejos en los datos de operación. En un estudio pionero de Xu et al. (2007), se utilizó una red neuronal auto-organizada para clasificar más de 7,000 tarjetas dinamométricas en cinco categorías de fallas. El modelo demostró una precisión impresionante del 99.97%, mucho más alta que la de modelos convencionales basados en retropropagación. Este enfoque no solo permitió realizar diagnósticos de fallas en tiempo real, sino que también redujo la dependencia de los expertos humanos, lo que facilitó una mayor automatización del proceso. La capacidad de las redes neuronales auto-organizadas para generalizar patrones de fallas operativas de manera eficiente ha hecho que esta tecnología sea particularmente útil en la optimización del mantenimiento predictivo en pozos petroleros, mejorando la seguridad y reduciendo los tiempos de inactividad no planificados.

Una tendencia creciente en el análisis de datos para mantenimiento predictivo es el uso de grandes volúmenes de datos, particularmente en sistemas que requieren mediciones continuas. En el contexto de los pozos de bombeo de varilla de succión (SRP), los avances en Big Data y aprendizaje profundo están transformando la forma en que se mide la producción de los pozos. Un estudio reciente de S. Chen et al. (2023) ha demostrado cómo el análisis de parámetros eléctricos en tiempo real, como la potencia y la corriente, puede predecir con alta precisión la producción de los pozos. Utilizando dispositivos IoT para recopilar datos de más de 300 pozos, el equipo entrenó un modelo basado en redes neuronales LSTM que procesó las curvas de potencia para estimar la producción de fluidos. Los resultados mostraron que este enfoque superó a las técnicas tradicionales, con errores inferiores a 0.5 m³/d en pozos de baja producción y menores al 10% en pozos de alta producción. Además, este enfoque no solo mejora la precisión de las mediciones, sino que también optimiza la gestión de los pozos en tiempo real, permitiendo a los operadores realizar ajustes más rápidos y eficientes. Este uso de Big Data y aprendizaje profundo ofrece una

solución económica y automatizada, reduciendo la necesidad de mediciones manuales y mejorando la eficiencia operativa en campos petroleros.

Además, el reconocimiento de patrones en tarjetas dinamométricas también se ha visto beneficiado por el uso de redes neuronales artificiales (ANN), que permiten clasificar las condiciones operativas de los pozos con alta precisión. Como se muestra en la publicación de Bezerra et al. (2009) implementó un sistema basado en ANN para analizar tarjetas dinamométricas y clasificarlas en diferentes estados operativos. Utilizando una combinación de datos artificiales y reales, el modelo alcanzó una precisión del 100% en la validación y un error de clasificación del 1.31% en pruebas con datos reales. La capacidad de generar datos artificiales para el entrenamiento de redes neuronales permite reducir la dependencia de grandes bases de datos reales, lo que facilita la implementación de sistemas de diagnóstico automático en la industria petrolera. Esta metodología no solo mejora la precisión del diagnóstico, sino que también ofrece un enfoque escalable y eficiente para la automatización en la gestión de pozos, reduciendo el tiempo de inactividad y mejorando la toma de decisiones operativas.

El mantenimiento predictivo en la industria petrolera ha dado un paso significativo con el uso de métodos de aprendizaje automático (ML) para predecir la vida útil de componentes críticos, como las varillas de succión. La vida útil de estas varillas, particularmente aquellas con defectos, es fundamental para evitar fallas inesperadas y costosos tiempos de inactividad. Un estudio realizado por Yuandeng et al. (2023) propuso un enfoque innovador que integra pruebas experimentales, simulaciones por elementos finitos (FEM) y varios modelos de ML, como redes neuronales de retropropagación (BPNN), redes neuronales Elman y máquinas de soporte vectorial para regresión (SVR). La metodología se basó en la recopilación de datos clave, como el diámetro de la varilla, tamaño y profundidad de defectos, carga axial y ciclos de fatiga, a partir de pruebas experimentales con varillas de acero bajo cargas alternas. Los resultados mostraron que el modelo BPNN superó a los otros métodos, alcanzando una precisión excepcional para predecir la vida útil por fatiga, lo que proporciona una herramienta eficaz para la monitorización y optimización de los sistemas de bombeo en la industria petrolera. Este enfoque subraya la importancia de la integración de simulaciones y modelos de ML para mejorar la fiabilidad y reducir los riesgos operativos en condiciones reales de funcionamiento.

La predicción precisa de la vida útil remanente (RUL) de los equipos es una de las aplicaciones más relevantes del aprendizaje automático en la industria petrolera, ya que permite

optimizar el mantenimiento y reducir los costos asociados a fallas inesperadas. Un trabajo realizado por Fauzi et al. (2019) desarrolló un modelo basado en redes neuronales artificiales (ANN) para estimar el RUL de equipos utilizando un conjunto de datos multivariado proporcionado por una empresa petrolera. La metodología incluyó la preparación de datos con herramientas como Alteryx y la visualización de resultados a través de Power BI, lo que facilitó la interpretación de las predicciones. El modelo de tipo Feedforward ANN, entrenado con diferentes particiones de datos, logró una precisión superior al 98% en la predicción del RUL, lo que demuestra su capacidad para mejorar la eficiencia operativa y minimizar el tiempo de inactividad. Este enfoque no solo optimiza la toma de decisiones, sino que también resalta la importancia de integrar herramientas de análisis y visualización en la industria petrolera para mejorar la confiabilidad de las predicciones y reducir costos operativos.

El uso de aprendizaje profundo para el pronóstico de la salud de los activos físicos está transformando la gestión de activos en la industria petrolera, ofreciendo nuevas perspectivas sobre la manera de abordar la monitorización y predicción de fallas. Figueroa et al. (2022) propusieron un marco basado en redes neuronales profundas para predecir anomalías en sistemas complejos como plantas de tratamiento de gas natural y bombas de inyección de agua. El modelo autoencoder basado en LSTM y el modelo CNN-LSTM aplicados en estos casos lograron una precisión destacada para detectar estados anómalos en concentraciones de CO₂ y clasificar el estado de salud de las bombas con una precisión superior al 99%. Este enfoque no solo ha demostrado su efectividad para predecir fallas, sino que también resalta la importancia de mejorar la interpretabilidad de los modelos y abordar problemas como las clases desbalanceadas, lo que promete fortalecer aún más las soluciones de mantenimiento predictivo en la industria petrolera. Estos avances abren nuevas oportunidades para la gestión proactiva de activos físicos, reduciendo fallas inesperadas y mejorando la eficiencia operativa.

En cuanto al RUL o vida útil remanente de equipos industriales, otro ejemplo innovador se encuentra en el campo de la perforación, donde la predicción precisa de la vida útil remanente de bombas de perforación es crucial para evitar costosos mantenimientos imprevistos, Guo et al. (2023) presentaron un modelo híbrido que combina redes neuronales convolucionales (CNN), módulos de atención (CBAM) y Transformers para predecir el RUL de bombas de perforación, utilizando señales de tensión procesadas en el dominio tiempo-frecuencia. El modelo CA-Transformer mejoró significativamente la precisión en comparación con modelos tradicionales,

reduciendo el error cuadrático medio (RMSE) en un 23.3% y el error absoluto medio (MAE) en un 46.1%. Este enfoque permitió predecir de manera más precisa las trayectorias de degradación en condiciones reales de operación, lo que es esencial para el mantenimiento predictivo en operaciones de perforación. Al integrar tecnologías avanzadas como atención adaptativa y análisis multispectral, el modelo también ofreció una mayor capacidad de generalización, lo que lo convierte en una herramienta valiosa para la optimización de la seguridad y confiabilidad en la industria petrolera. Este enfoque puede extenderse a otros equipos en la industria energética, abriendo nuevas oportunidades para mejorar la eficiencia operativa y reducir costos asociados a fallas no planificadas.

La implementación de modelos de aprendizaje automático en la predicción de la producción en proyectos de inyección de agua en la industria petrolera se ha convertido en una herramienta clave para optimizar la eficiencia operativa y reducir los costos computacionales. Un ejemplo destacado de esta tendencia es el modelo proxy basado en redes neuronales generativas adversarias profundas condicionales (cDC-GAN) propuesto por Zhong et al. (2020). Este enfoque permite predecir la distribución de fluidos en reservorios de manera precisa y con un ahorro significativo de tiempo respecto a las simulaciones numéricas tradicionales. Utilizando parámetros clave como la permeabilidad y el tiempo de pronóstico, el modelo genera mapas de saturación de agua que ayudan a calcular las tasas de producción de petróleo y agua, aplicando el principio de balance de materiales. A través de la validación de sus predicciones, el modelo demostró una precisión destacable en la predicción de tasas de producción con un error promedio global de solo el 10.2%. Además, su capacidad para reducir el tiempo de cálculo de horas a minutos, en comparación con simulaciones complejas, lo posiciona como una herramienta altamente efectiva para la optimización de proyectos de recuperación secundaria, aunque se recomienda seguir evaluando su capacidad en escenarios más complejos y tridimensionales.

Las redes neuronales han emergido como una herramienta clave en la optimización de la gestión de activos, particularmente en la mejora de la confiabilidad y eficiencia de los equipos industriales esenciales. Bangert (2017) describe un enfoque avanzado que utiliza redes neuronales para analizar datos históricos de sensores en equipos rotativos y no rotativos, como compresores, bombas, turbinas e intercambiadores de calor. Este sistema elimina la necesidad de definir límites estáticos para cada sensor, lo que reduce de manera considerable las falsas alarmas y permite una detección más precisa de problemas en tiempo real. En la industria petrolera, donde la

disponibilidad continua de equipos es crucial, la implementación de este sistema en instalaciones industriales ha demostrado una reducción del 90% en falsas alarmas y una mejora del 10% en la disponibilidad de los equipos. Además, la transición de un enfoque de mantenimiento reactivo a predictivo ha permitido reducir los costos de mantenimiento en un 50%, optimizando la planificación de reparaciones y evitando paradas no programadas, lo que a su vez reduce las pérdidas operativas y mejora la eficiencia.

La capacidad de predecir fallas antes de que ocurran en equipos clave de la industria petrolera también ha sido notablemente mejorada con la incorporación de redes neuronales recurrentes (RNN). En el estudio de Bangert (2019), se desarrolló un sistema avanzado para monitorear y diagnosticar fallas en equipos como compresores de hidrógeno y turbinas de gas. El modelo se basa en datos históricos para crear perfiles de funcionamiento saludable de los equipos, comparándolos constantemente con los datos operativos en tiempo real. El modelo logró detectar fallas críticas con anticipación, como en el caso de un compresor de hidrógeno, donde la falla se predijo 30 días antes, permitiendo realizar reparaciones sin interrumpir las operaciones. La integración de este sistema en la industria petrolera ha demostrado una notable reducción de las falsas alarmas en un 90% y ha mejorado la disponibilidad de los equipos en un 10%, mientras que los costos de mantenimiento se redujeron en un 50%. El estudio concluye que la implementación de aprendizaje automático en los sistemas de monitoreo de condiciones transforma la gestión del mantenimiento, optimizando la operación y reduciendo costos, con potencial para extender el modelo a otros tipos de fallas y sistemas complejos en el futuro.

7.4. Máquinas de Soporte Vectorial SVM

El mantenimiento predictivo en la industria petrolera ha evolucionado con el uso de algoritmos avanzados de aprendizaje automático, entre los cuales las máquinas de soporte vectorial (SVM) han demostrado ser una herramienta altamente efectiva para la detección y diagnóstico de fallas en sistemas de bombeo de varilla. Estos sistemas, esenciales en la extracción de petróleo, pueden sufrir diversas fallas operativas que afectan su eficiencia y vida útil. La capacidad de SVM para clasificar patrones complejos mediante la identificación de un hiperplano óptimo de separación entre distintas condiciones operativas ha permitido mejorar la precisión en la detección de anomalías. Uno de los principales desafíos en el diagnóstico de fallas en pozos de bombeo de

varilla radica en el análisis de los diagramas indicadores, que representan gráficamente el comportamiento mecánico del sistema. Para mejorar la precisión del diagnóstico, se han desarrollado técnicas de preprocesamiento avanzadas, como la binarización, la detección de bordes y la normalización de tamaño, que permiten extraer características clave de estos diagramas. La integración de estas características en modelos SVM ha resultado en una clasificación más precisa de diversas fallas, incluyendo pérdida de válvula, insuficiencia de suministro de líquido y contacto irregular entre los componentes de la bomba. Un estudio basado en esta metodología alcanzó una precisión del 90.63% en la clasificación de 11 condiciones operativas de pozos de bombeo de varilla, lo que representa una mejora considerable frente al 78.13% obtenido sin preprocesamiento de los datos. No obstante, se identificaron limitaciones en la capacidad del modelo para diagnosticar fallas combinadas, como la producción de arena junto con insuficiencia de suministro de líquido, debido a la similitud en los patrones de las fallas (J. Liu et al., 2021).

Para mejorar aún más la capacidad de generalización de estos modelos, se ha implementado el concepto de SVM incremental, que permite actualizar continuamente el modelo de diagnóstico a medida que se incorporan nuevos datos en tiempo real. Esta metodología ha demostrado ser particularmente útil en entornos donde la variabilidad operativa es alta y la recopilación de datos históricos es limitada. Un estudio que implementó este enfoque utilizó diagramas indicadores simulados en combinación con una SVM incremental, lo que permitió aumentar la precisión del diagnóstico en un 11.2% en comparación con los modelos tradicionales. El sistema fue evaluado con datos de 7887 diagramas indicadores de pozos operativos en el campo petrolero de Shengli, logrando una precisión del 96.4% en la clasificación de 24 condiciones operativas. Además, la SVM incremental presentó ventajas en términos de velocidad de entrenamiento y uso eficiente de memoria en comparación con redes neuronales de retropropagación y máquinas de aprendizaje extremo (Lv et al., 2021).

Otra mejora clave en la aplicación de SVM en el mantenimiento predictivo es la optimización de sus parámetros mediante algoritmos evolutivos. Técnicas como el Chicken Swarm Optimization mejorado (DACSO) han sido empleadas para ajustar dinámicamente los hiperparámetros del modelo, como el coeficiente de penalización y el parámetro del kernel, logrando una mayor precisión en la clasificación de fallas. En una investigación reciente, el uso de DACSO permitió mejorar la precisión del modelo SVM de 90.63% a 95.63%, superando significativamente a enfoques convencionales. Las mejoras en la precisión se atribuyen a la

capacidad del algoritmo de equilibrar la búsqueda global y local, evitando la convergencia prematura a soluciones subóptimas. El estudio concluyó que la combinación de SVM con técnicas avanzadas de optimización ofrece un marco sólido para la detección eficiente de fallas en pozos de bombeo de varilla, con alta precisión y adaptabilidad a distintas condiciones operativas (J. Liu, Feng, et al., 2019).

Las bombas centrífugas desempeñan un papel crucial en la industria petrolera, ya que facilitan el transporte de fluidos en diversas etapas del procesamiento. Para mejorar la eficiencia de su mantenimiento, se han implementado modelos predictivos que analizan datos históricos de sensores y anticipan condiciones de falla. Un estudio realizado en la refinería SARLUX en Italia comparó el rendimiento de SVM con el de perceptrón multicapa (MLP) para la predicción de fallas en bombas centrífugas. Se recopilaron datos de vibración, desplazamiento axial, temperatura de bobinas y caudal de ocho sensores entre 2010 y 2014.

Para abordar el fuerte desbalance de clases (menos del 1% de los datos representaban fallas), se aplicó la técnica SMOTE para balancear los datos antes del entrenamiento. El modelo SVM optimizado mediante búsqueda en cuadrícula alcanzó una precisión del 98.1%, aunque mostró un recall bajo del 27.7% en la detección de fallas, lo que indica que tuvo dificultades para identificar correctamente eventos críticos. En comparación, el modelo MLP logró una precisión del 98.2% y un recall del 42.2%, lo que lo hizo más efectivo en la identificación temprana de condiciones de falla. Ambos algoritmos demostraron ser prometedores para el mantenimiento predictivo en entornos industriales, aunque se sugirió realizar estudios a mayor escala y explorar características adicionales para mejorar la generalización de los modelos (Orrù et al., 2020).

El reciclaje de varillas de bombeo es una estrategia utilizada para reducir costos operativos en la industria petrolera. Sin embargo, la evaluación de su integridad estructural es un desafío debido a la dispersión e incertidumbre en los datos de daño. Para abordar este problema, se ha utilizado la tecnología de memoria magnética metálica (MMM) en combinación con modelos SVM para identificar y clasificar defectos en varillas recicladas. En un estudio, se analizaron varillas de diferentes tamaños sometidas a cargas estáticas y dinámicas, utilizando un escáner TSC-1M-4 para medir variaciones en la intensidad del campo magnético. Se definieron cuatro parámetros clave para caracterizar los daños: valor pico-pico, gradiente diferencial, gradiente integral y energía de la señal. Estos parámetros fueron empleados para entrenar modelos SVM con kernel lineal y de base radial (RBF), optimizados para mejorar la precisión y evitar el sobreajuste.

El modelo SVM con kernel RBF logró una precisión del 81.25% y una similitud del 85.71%, superando significativamente al modelo con kernel lineal, que obtuvo una precisión del 68.75%. La capacidad del modelo para clasificar los daños en tres categorías (concentración de tensiones, defectos microscópicos y defectos macroscópicos) permitió mejorar la confiabilidad de los productos reciclados. Además, se observó que, al aumentar la cantidad de datos de entrenamiento, la capacidad de generalización del modelo se incrementaba, reduciendo la tasa de errores en la clasificación. Este enfoque ofrece una solución efectiva para la evaluación de calidad en la reutilización de componentes petroleros (Xing et al., 2013).

Las fugas en oleoductos representan un riesgo ambiental y económico significativo para la industria petrolera. Para mejorar la precisión en su detección, se ha desarrollado un método basado en la extracción de características de cadenas de Markov y un esquema de decisión en dos etapas, utilizando modelos SVM de mínimos cuadrados (LS-SVM). Este método convierte los datos de presión en cadenas de Markov y extrae características dinámicas que, junto con vectores de características estadísticas, se introducen en un modelo LS-SVM. La estrategia de decisión en dos etapas permite seleccionar entre modelos de detección a corto y largo plazo según las condiciones de operación. En pruebas con datos reales de un oleoducto y un campo experimental, el método logró una precisión promedio del 99.17% en la detección de fugas generales y del 92% en fugas pequeñas. Comparado con otros enfoques, como métodos estadísticos combinados con Bayes ingenuo y redes neuronales de perceptrón multicapa, el modelo basado en SVM mostró un rendimiento superior con una precisión promedio del 97.39% y un tiempo de detección aceptable de 17.06 segundos. Además, presentó una baja tasa de falsas alarmas y una capacidad robusta para diferenciar entre condiciones normales y de fuga. Este enfoque permite una detección más rápida y precisa de fugas, reduciendo pérdidas económicas y riesgos ambientales en la industria petrolera (J. Liu, Zang, et al., 2019).

Uno de los principales desafíos en el mantenimiento de sistemas de levantamiento artificial con bombas de varilla es la dependencia de modelos específicos de campo, los cuales requieren altos costos de mantenimiento y presentan un desempeño limitado en condiciones operativas diferentes. Para abordar este problema, se ha desarrollado un modelo global de predicción de fallas basado en SVM con kernel radial. El modelo se entrenó con datos recopilados de 1,947 sistemas de bombeo en cinco campos petroleros entre 2010 y 2012, utilizando sensores que monitoreaban variables clave como área de tarjeta dinamométrica, carga superficial, tiempo de operación diario

y presión de línea de flujo. Se aplicó un proceso de mediana móvil doble para extraer tendencias a largo y corto plazo antes del entrenamiento del modelo SVM. El modelo global alcanzó una precisión del 65.7% y un recall del 66.4% en la predicción de fallas a nivel general. En pruebas específicas de campo, el recall varió entre 47.1% y 88.5%, dependiendo de la calidad de los datos y los tipos de fallas predominantes en cada ubicación. Además, el modelo detectó señales de pre-falla hasta con 100 días de anticipación, permitiendo realizar intervenciones preventivas antes de fallas críticas. En comparación con modelos específicos de campo, el modelo global demostró ser más escalable, reduciendo costos de mantenimiento y mejorando la adaptabilidad a múltiples ubicaciones. Como trabajo futuro, se propone implementar el modelo en operaciones en tiempo real y evaluar su aplicación en otros sistemas de levantamiento artificial (Y. Liu et al., 2013).

7.5. Transfer Learning

El diagnóstico de fallas en sistemas de bombeo de varilla de succión (SRP) es fundamental para garantizar la eficiencia operativa en la industria petrolera. Sin embargo, los métodos convencionales de diagnóstico, que dependen de la inspección manual de datos, son costosos, propensos a errores y requieren grandes volúmenes de información para ser efectivos. En este contexto, el uso de modelos de aprendizaje automático, particularmente aquellos basados en transferencia de aprendizaje, ofrece una solución eficiente. Transfer learning permite que modelos preentrenados con grandes conjuntos de datos se adapten rápidamente a nuevas tareas con cantidades limitadas de datos específicos, mejorando la precisión en el diagnóstico y reduciendo los costos operativos. Este enfoque ha demostrado ser eficaz para optimizar la detección de fallas, lo que es crucial para prevenir pérdidas de producción en la industria petrolera. Un estudio realizado sobre sistemas SRP, se utilizó la arquitectura GoogLeNet junto con clasificadores de aprendizaje supervisado basados en ECOC para el análisis de tarjetas dinamométricas. Mediante transferencia de aprendizaje, el modelo fue preentrenado con grandes volúmenes de datos y luego ajustado a datos específicos de SRP. La comparación de diferentes clasificadores como SVM, k-NN, Árboles de Decisión (DT) y Naive Bayes (NB) reveló que el modelo con GoogLeNet y SVM alcanzó una precisión de clasificación del 96.4%, y con k-NN, un 99.4%. Estos resultados demostraron que el enfoque basado en transferencia de aprendizaje supera a los métodos

tradicionales, mejorando la fiabilidad en la detección de fallas y reduciendo costos operativos (Sreenivasan & Krishna, 2024).

Otro estudio propuso un modelo basado en meta-transfer learning para el diagnóstico de fallas en pozos de bombeo de varilla de succión con pocas muestras de datos. Este enfoque combina aprendizaje por transferencia y aprendizaje meta, utilizando redes neuronales profundas preentrenadas para optimizar el rendimiento en escenarios de clasificación con datos limitados. El modelo, basado en la arquitectura ResNet, alcanzó una precisión de clasificación del 77.23%, superando a otros métodos como MAML y DenseNet. La capacidad de este enfoque para mejorar la precisión en escenarios de pocas muestras, adaptarse rápidamente a nuevas tareas y reducir la dependencia de grandes volúmenes de datos ofrece un avance significativo en el diagnóstico predictivo en condiciones reales de operación, optimizando tiempos de diagnóstico y reduciendo la dependencia de grandes conjuntos de datos (Zhang et al., 2022).

7.6. Regresión

La implementación de modelos predictivos para fallas en equipos clave, como las bombas de agua salada, ha ganado relevancia al proporcionar soluciones más eficientes que los métodos tradicionales de mantenimiento reactivo. La regresión múltiple, al utilizar datos históricos operativos, se presenta como una herramienta valiosa para predecir fallas y optimizar los procesos de mantenimiento de manera proactiva. En el estudio de Awsan Mohammed, realizado en la King Fahd University of Petroleum and Minerals, se desarrolló un modelo basado en regresión lineal múltiple para anticipar fallas en bombas de agua salada, utilizando datos operacionales recolectados entre 2019 y 2021. El modelo se construyó a partir de seis factores clave: temperatura, presión, tiempo promedio entre fallas, pH, nivel de NH₃ y fósforo total en el agua salada.

Para validar el diseño y los factores, se realizaron entrevistas con expertos, y la metodología incluyó limpieza de datos y análisis de correlación entre variables. Utilizando 237 conjuntos de datos operativos, el modelo se entrenó y validó, optimizándose mediante regresión por mínimos cuadrados para minimizar errores residuales. El análisis de sensibilidad reveló que la presión, el fósforo total y la temperatura tienen la mayor influencia en las fallas, lo que permitió definir umbrales críticos para clasificar las condiciones operativas en "falla" o "no falla". El modelo alcanzó una precisión superior al 97% al clasificar correctamente las fallas, destacando

que un aumento en la presión por encima de 6.3 kg/cm² incrementa significativamente el riesgo de falla. El estudio concluye que este enfoque de regresión múltiple es altamente efectivo para predecir fallas en bombas de agua salada, brindando un sistema de soporte útil para la toma de decisiones en mantenimiento. Además, se destaca la capacidad del modelo para adaptarse a otros tipos de bombas y se sugieren exploraciones adicionales de técnicas avanzadas para abordar interacciones más complejas entre los factores involucrados en el proceso (Mohammed, 2023).

7.7. Weibull

El método de Weibull se ha estado empleando para ofrecer soluciones en el ámbito del mantenimiento predictivo en la industria del petróleo y gas, particularmente en la optimización de las decisiones sobre la integridad de los activos. Este enfoque se pone en evidencia en estudios como el de Raza (2018), donde se utilizó el análisis de Weibull como parte de la metodología Predict and Prevent (PnP) para predecir las necesidades de mantenimiento. La combinación de datos históricos de mantenimiento con el estado actual de los equipos permite identificar los intervalos óptimos de mantenimiento preventivo, mejorando así la confiabilidad y la disponibilidad del equipo. El estudio demuestra que este enfoque puede predecir fallas con más del 90% de precisión, lo que permite a las empresas reducir los costos en mantenimiento preventivo hasta en un 40% anualmente. Además, el análisis de Weibull contribuyó a optimizar los intervalos de intervención, maximizando la disponibilidad del equipo y reduciendo los costos operativos sin comprometer la seguridad.

El método de Weibull también ha sido aplicado en la evaluación de la vida útil de varillas de succión en sistemas de bombeo de la industria petrolera, como se muestra en el estudio de Cai et al. (2022). En este caso, se empleó un modelo de tres parámetros de Weibull para superar las limitaciones del modelo Basquin, proporcionando predicciones más precisas bajo condiciones de fatiga intensa. El modelo de Weibull considera tres parámetros clave: el parámetro de posición (α), que marca el umbral mínimo para la falla; el parámetro de escala (β), que describe la tasa de ocurrencia de fallas y la dispersión de los datos; y el parámetro de forma (γ), que ajusta la pendiente de la curva en relación con el estrés y los ciclos de fatiga. Los resultados experimentales demostraron que el modelo de Weibull alcanzó un error promedio de 4.39% en varillas HY y 1.25% en varillas HL, mientras que el modelo Basquin mostró errores mucho mayores. Este

enfoque demostró ser particularmente efectivo para predecir fallas en ciclos de ultra-alta fatiga, lo que valida su uso como una herramienta robusta y precisa en la industria petrolera para mejorar la confiabilidad operativa y reducir los riesgos asociados con fallas en componentes críticos.

7.8. Otros métodos

El método basado en la adaptación de dominio y el uso de curvas de potencia del motor ha mostrado ser una solución efectiva para la diagnosis de fallos en sistemas de bombeo de varilla de succión, como se evidencia en el estudio realizado por Hao y Gao (2022). En este caso, se aborda un problema recurrente en la industria petrolera: los altos costos y la deficiencia de rendimiento en tiempo real de los sensores de tarjetas de dinamómetro, que son esenciales para el diagnóstico de fallos en estos sistemas. En lugar de depender de los dinamómetros, el enfoque propuesto utiliza las curvas de potencia del motor, las cuales son más accesibles y tienen una fuerte correlación con el rendimiento del sistema de bombeo. Para implementar esta solución, los autores desarrollaron un modelo matemático dinámico integrado que genera las curvas de potencia bajo diversas condiciones operativas. Este modelo es complementado por una red llamada MADAN (Mecanismo-Asistido en Red de Adaptación de Dominio), diseñada para reducir la discrepancia entre las curvas de potencia generadas y las reales. Este enfoque permite una mejor alineación de las distribuciones de los datos, lo que resulta en una diagnosis más precisa de fallos. Los experimentos realizados con un dispositivo propio desarrollado por los autores validaron tanto el modelo matemático como la metodología de diagnóstico propuesta. Los resultados demostraron que la técnica ofrece una alta precisión en la detección de fallos no supervisada, subrayando la eficacia de las curvas de potencia del motor para reflejar con precisión el estado del sistema de bombeo. Además, la metodología basada en la adaptación de dominio y el aprendizaje no supervisado demuestra ser una solución valiosa para superar las limitaciones asociadas con la escasez de datos etiquetados en escenarios industriales, lo que posibilita un diagnóstico más eficiente y confiable en pozos petroleros.

El uso de Extreme Learning Machines (ELM) ha emergido como una opción eficaz y eficiente para el diagnóstico de fallas en sistemas de bombeo de varilla de succión (SRP), como se demuestra en el estudio llevado a cabo por Gao et al. (2015). Este enfoque se propone superar las limitaciones de los métodos tradicionales, como las redes neuronales artificiales (ANN) y las

máquinas de soporte vectorial (SVM), al ofrecer una mayor rapidez y eficiencia tanto en el entrenamiento como en la clasificación. En lugar de utilizar las técnicas convencionales, los autores construyeron un modelo ELM que toma como entrada cinco características extraídas de tarjetas dinamométricas, tales como el centroide, el perímetro y dos áreas específicas de las curvas. El modelo fue entrenado y probado utilizando datos de pozos operados en el campo petrolero de Yanchang, China, que contenían 330 muestras clasificadas en tres categorías: operación normal, falla de alimentación de líquido y ruptura de varilla. Después de normalizar los datos, se aplicaron fórmulas geométricas para generar los vectores de características que alimentan al algoritmo ELM. Los resultados mostraron que el modelo ELM alcanzó una precisión del 89%, superando tanto a SVM (83%) como a ANN (78%). Además, el ELM destacó por su mayor eficiencia en el entrenamiento, reduciendo significativamente el tiempo necesario para procesar los datos. Mientras que el modelo ELM tardó solo 28.7 segundos, el modelo ANN requirió 108.2 segundos y el SVM 303.1 segundos. Esta mejora en el tiempo de procesamiento, junto con la capacidad de generalización del modelo y su manejo eficiente de datos en tiempo real, lo convierte en una solución prometedora para el diagnóstico automático en campos petroleros.

El STP-Model ha sido desarrollado como un marco avanzado para el diagnóstico de fallas en sistemas de bombeo de varilla de succión (SRP), integrando técnicas semisupervisadas y auto-supervisadas. Este enfoque, propuesto por Huang et al. (2024), combina tres módulos clave: aprendizaje supervisado, asociación temporal auto-supervisada y predicción auto-supervisada, lo que permite aprovechar tanto datos etiquetados como no etiquetados. El modelo fue entrenado con 108,000 muestras recopiladas en el campo petrolero Shengli, con una proporción significativa de datos no etiquetados, lo que refuerza su capacidad para manejar situaciones con datos limitados. Con este enfoque híbrido, el STP-Model alcanzó una precisión destacada del 98.36%, superando por 7.41% a otros métodos semisupervisados y por 32.79% a enfoques como la pseudoetiquetación (65.57%) o modelos completamente supervisados (65.11%). Lo más impresionante de este modelo es su rendimiento efectivo incluso con un conjunto reducido de datos etiquetados, logrando excelentes resultados con solo 90 muestras etiquetadas, lo que resalta su eficiencia y rapidez en el aprendizaje. Este avance muestra que el STP-Model es no solo una herramienta robusta para mejorar el diagnóstico de fallas en sistemas SRP, sino también un marco altamente adaptable que puede ser aplicable en otras áreas industriales que manejan grandes volúmenes de datos no etiquetados.

Las ecuaciones de onda unidimensionales con amortiguamiento viscoso se han convertido en una herramienta clave para modelar y predecir el comportamiento dinámico en sistemas mecánicos complejos, como los sistemas de bombeo de varilla de succión (SRP). Este tipo de ecuaciones permite describir cómo las ondas de presión se propagan a través de un medio, teniendo en cuenta los efectos de la viscosidad y el amortiguamiento, que son fundamentales para modelar el desgaste y las condiciones operativas. En el contexto de los SRP, este modelo se utiliza para analizar el impacto del desgaste entre el émbolo y el barril de la bomba, lo que afecta directamente la eficiencia operativa y las condiciones de carga de la varilla. Wang y Liu, (2018) aplican esta metodología al desarrollar un modelo que simula los efectos del desgaste progresivo en las tarjetas dinamométricas de varilla pulida, proporcionando una herramienta precisa para diagnosticar y prever el comportamiento del sistema en diversas condiciones de operación.

El estudio incorporó parámetros físicos clave, como la dureza del barril, el diámetro de las partículas abrasivas, la viscosidad del fluido y la holgura generada por el desgaste, para construir un modelo realista que pudiese simular diferentes condiciones. Los datos experimentales fueron obtenidos en el pozo L2111 del campo petrolero Liao He, y las simulaciones realizaron evaluaciones sobre cómo el desgaste influye en la eficiencia operativa y las condiciones de carga de la varilla. Se observó que el desgaste progresivo genera un aumento de la holgura entre el émbolo y el barril, lo que reduce la carga de la varilla pulida en el golpe ascendente hasta en un 15%, afectando negativamente la eficiencia volumétrica del sistema. Además, el incremento en el diámetro de las partículas abrasivas aumentó el volumen de desgaste en más del 40%, acortando el tiempo operativo en un 25%. El modelo mostró una alta precisión en sus predicciones, con una correlación superior al 92% entre las simulaciones y los datos reales, lo que valida su eficacia.

Las ecuaciones de onda unidimensionales con amortiguamiento viscoso también han demostrado ser útiles para modelar el desempeño de sistemas de bombeo de varilla profunda, como se presentó en el estudio de Guo-hua et al. (2011). En esta publicación, estas ecuaciones fueron empleadas para describir las dinámicas entre el fluido y la varilla en un sistema de bombeo de varilla profunda con una bomba de flujo lateral. Al integrar la técnica de diferencias finitas con estas ecuaciones, se logró un análisis preciso de las cargas y condiciones del equipo, mejorando la predicción del comportamiento del sistema en condiciones de operación extremas, como grandes profundidades y baja presión de formación. Los resultados del modelo mostraron una producción diaria estabilizada de 8.4 m³/d de petróleo y 3.9 m³/d de agua, mejorando

significativamente el rendimiento en comparación con el sistema convencional, que producía solo 0.6 m³/d de petróleo y 0.3 m³/d de agua.

El análisis predictivo basado en aprendizaje automático distribuido se ha destacado como una herramienta clave para mejorar la confiabilidad de los sistemas de sensores, especialmente en entornos industriales extremos como los de la industria del petróleo y gas. Este enfoque, que permite procesar grandes volúmenes de datos de manera eficiente, utiliza técnicas avanzadas de aprendizaje automático para predecir valores faltantes, corregir lecturas erróneas y anticipar posibles escenarios críticos. En su estudio, Kejela et al. (2014) aplican esta metodología para mejorar la fiabilidad de sensores operando en condiciones extremas, como altas temperaturas y vibraciones. El modelo propuesto emplea la plataforma de aprendizaje automático H2O para el procesamiento en memoria y utiliza dos técnicas de modelado: Generalized Linear Models (GLM) y Gradient Boosted Models (GBM). El análisis se realiza con un conjunto de datos que contiene 135 variables y más de 500,000 puntos de datos recolectados en intervalos de un segundo. Al evaluar el rendimiento de los modelos, el GBM demostró ser superior al GLM, alcanzando un RMSE de 0.417 y un MAE de 0.2138, frente a los valores de 3.6563 y 2.5372 obtenidos por el GLM, respectivamente. Además, ambos modelos lograron clasificaciones correctas en más del 99.99% de los casos evaluados, lo que resalta la alta precisión de las predicciones.

La norma API 570 y la ley de crecimiento de grietas por fatiga de París pueden ayudar a predecir la vida útil restante (RUL) de equipos en la industria petrolera, como se demostró en el estudio de Animah y Shafiee (2018). Al integrar estas herramientas con el juicio experto, el marco desarrollado en su investigación permitió evaluar de manera más precisa la condición de los activos offshore, como los sistemas separadores de tres fases en plataformas operando en condiciones extremas. Esta combinación de métodos y experiencia facilitó la toma de decisiones sobre la extensión de vida útil y el mantenimiento de equipos críticos. El estudio fue aplicado a un sistema separador de tres fases en una plataforma offshore operando en África Occidental desde los años 70, donde se analizaron 33 subsistemas. El análisis reveló que los principales mecanismos de fallo eran la corrosión y la fatiga, y que el sistema separador podría operar de manera segura por cinco años adicionales, aunque con un RUL ajustado entre cinco y seis años. Se recomendó la implementación de estrategias activas de control de corrosión, como la inyección de inhibidores, para reducir la tasa de corrosión y mantener los componentes dentro de los límites regulatorios.

Los resultados también indicaron que otros subsistemas estaban en condiciones adecuadas para continuar operando sin necesidad de reemplazos inmediatos.

Las funciones de Fourier son herramientas clave en el mantenimiento predictivo en la industria petrolera, especialmente para analizar señales periódicas como vibraciones y fluctuaciones de presión en sistemas de bombeo. Al descomponer estas señales, las series de Fourier permiten identificar patrones y predecir fallas antes de que ocurran, mejorando la eficiencia operativa. En este sentido, el artículo "Predicting Sucker-Rod Pumping Systems with Fourier Series", de Z. Chen et al. (2018), introduce el uso de las series de Fourier para predecir y diagnosticar el comportamiento de los sistemas de bombeo de varilla en pozos petroleros. Este enfoque supera las limitaciones de los modelos tradicionales, permitiendo predecir desplazamientos y cargas en cualquier punto de la cadena de varillas sin necesidad de modelos complejos. Además, facilita la detección de fallas, como obstrucciones o desgaste en los componentes del sistema, mediante la generación de tarjetas superficiales características. El método fue validado comparando sus resultados con datos de software comercial, mostrando una alta correlación y ventajas en flexibilidad y precisión. Este enfoque también reduce el ruido en los datos y es útil tanto para diagnóstico como para simulaciones de condiciones de bombeo.

En la Tabla 1 se puede identificar diferentes técnicas utilizadas, en que equipos se usan y con que fin, y los respectivos artículos que hablan de estas técnicas.

Tabla 1

Técnicas y sus Respectivas Aplicaciones

Técnica	Aplicaciones	Artículos
Árbol de decisiones	En su mayoría, los árboles de decisión se usan para la detección y diagnóstico de fallas en bombas de varilla de succión, con el fin de mejorar la gestión operativa, reducir el tiempo de inactividad y optimizar la producción de petróleo. También se pueden usar para la optimización del rendimiento en sistemas de levantamiento artificial como gas lift, y para mejorar la capacidad predictiva al combinarse con otros algoritmos, contribuyendo así a una toma de decisiones más eficiente en el mantenimiento predictivo.	(Nascimento et al., 2021) (Pennel et al., 2018) (Bangert & Sharaf, 2019) (Y. Liu et al., 2010)
Machine Learning	El machine learning se emplea en diversos equipos de la industria petrolera, como bombas de varilla de succión, sistemas de detección de "flaring" y medidores de flujo multifásico (MPFM), con el fin de anticipar anomalías, detectar fallas incipientes, mejorar la confiabilidad de las mediciones y reducir el impacto ambiental, lo que permite optimizar el mantenimiento predictivo y la operación general del sistema.	(Tran, 2022) (Giuliani et al., 2019) (Barbariol et al., 2020)

Tabla 1*Continuación*

Redes Neuronales y Deep Learning	Los sistemas de bombeo de varilla de succión (SRP) son los más frecuentemente abordados por esta tecnología, destacando en el análisis automatizado de tarjetas dinamométricas, predicción de producción y estimación de vida útil de componentes mediante modelos como redes neuronales convolucionales, LSTM y auto-organizadas. Estas técnicas también han sido aplicadas con éxito a otros equipos, como turbocompresores, bombas de perforación e instalaciones de tratamiento. En todos los casos, se busca optimizar el diagnóstico de fallas, predecir la vida útil remanente (RUL) y reducir tiempos de inactividad, confirmando la versatilidad de las redes neuronales en el mantenimiento predictivo petrolero.	(Villegas & Pérez, 2023) (Gatta et al., 2024) (Martinović et al., 2023) (Xu et al., 2007) (S. Chen et al., 2023) (Bezerra et al., 2009) (Yuandeng et al., 2023) (Fauzi et al., 2019) (Figueroa et al., 2022) (Guo et al., 2023) (Zhong et al., 2020) (Bangert, 2017) (Bangert, 2019) (J. Liu et al., 2021)
		(Lv et al., 2021).
Máquinas de Soporte Vectorial SVM	La técnica de SVM se aplica principalmente a sistemas de bombeo de varilla, que son los equipos más abordados en los estudios revisados, donde se utiliza para diagnosticar y clasificar fallas a partir del análisis de tarjetas dinamométricas. No obstante, también se ha implementado con buenos resultados en bombas centrífugas, para predecir fallas mediante datos de sensores; en varillas recicladas, evaluando su integridad estructural; y en oleoductos, para la detección de fugas.	(J. Liu, Feng, et al., 2019) (Orrù et al., 2020) (Xing et al., 2013) (J. Liu, Zang, et al., 2019) (Y. Liu et al., 2013)
Transfer Learning	Esta técnica se utiliza principalmente para el diagnóstico de fallas, permitiendo detectar anomalías a partir del análisis de tarjetas dinamométricas con modelos preentrenados que se ajustan a los datos específicos del equipo, incluso cuando estos son limitados.	(Sreenivasan & Krishna, 2024) (Zhang et al., 2022)

Tabla 1*Continuación*

Regresión	Se utiliza principalmente para predecir fallas en bombas de agua salada, equipos críticos en la operación de plantas industriales dentro del sector petrolero. Este enfoque permite anticipar condiciones de falla a partir de variables operativas como presión, temperatura, pH, y concentración de nutrientes en el agua, optimizando así la planificación del mantenimiento. Aunque el modelo fue diseñado específicamente para bombas de agua salada, el estudio señala su potencial aplicabilidad a otros tipos de bombas, siempre que se adapten los factores de entrada a las características del nuevo equipo.	(Mohammed, 2023)
Weibull	En los equipos en general, esta técnica permite establecer intervalos óptimos de mantenimiento preventivo al combinar datos históricos y el estado actual del activo, lo que ayuda a mejorar la confiabilidad y disponibilidad operativa. En el caso de las varillas de succión, el análisis de Weibull se emplea para evaluar su vida útil bajo condiciones de fatiga intensa, permitiendo predecir fallas con alta precisión y reducir los riesgos asociados con la falla de estos componentes críticos. En ambos casos, su aplicación contribuye significativamente a optimizar las decisiones de mantenimiento y a reducir los costos operativos.	(Raza, 2018) (Cai et al., 2022)

8. Analisis

El mantenimiento predictivo en la industria petrolera ha experimentado una transformación profunda gracias a la adopción de tecnologías avanzadas que permiten un monitoreo más preciso y eficiente de los equipos críticos. Esta evolución se ha visto impulsada por la integración de inteligencia artificial (IA) y aprendizaje automático, herramientas clave para procesar y analizar grandes volúmenes de datos operativos en tiempo real. Estas tecnologías han facilitado la transición desde métodos tradicionales hacia enfoques basados en datos, mejorando la detección temprana de fallas y optimizando los procesos de mantenimiento.

Una de las aplicaciones más destacadas es el diagnóstico predictivo en sistemas de bombeo, como los pozos de varilla de succión (SRP). En este contexto, los datos provenientes de sensores y tarjetas dinamométricas se han convertido en recursos esenciales para identificar anomalías operativas. Estas herramientas permiten realizar un seguimiento continuo de las condiciones de funcionamiento, detectando desviaciones que podrían comprometer la eficiencia o causar fallas graves.

Entre las tecnologías más utilizadas, destacan los modelos basados en datos (Data-Driven Models), que aprovechan herramientas como Big Data y análisis avanzado para evaluar el estado de los equipos. Estas metodologías son especialmente útiles en entornos donde las operaciones se distribuyen geográficamente, como es común en la industria petrolera. Las redes neuronales convolucionales (CNN), por ejemplo, han demostrado ser altamente eficaces en el procesamiento de datos complejos, como curvas de potencia e imágenes generadas por tarjetas dinamométricas. Este enfoque se ha aplicado en múltiples estudios, consolidándose como una solución ideal para escenarios con datos no estructurados.

Por otro lado, las máquinas de soporte vectorial (SVM) se han posicionado como una tecnología confiable para clasificar estados operativos. Cuando se combinan con algoritmos de optimización, como el Chicken Swarm Optimization (CSO), las SVM logran una precisión significativamente mejorada, siendo útiles incluso en entornos con ruido en los datos. Además, las redes neuronales auto-organizadas y los modelos basados en lógica difusa se mencionan recurrentemente debido a su capacidad para manejar incertidumbre y diagnosticar fallas en condiciones operativas complejas.

El uso de Big Data en el mantenimiento predictivo ha permitido integrar datos provenientes de sensores distribuidos, proporcionando una base sólida para predicciones precisas y análisis en tiempo real. Estas herramientas facilitan la toma de decisiones basada en datos, optimizando la planificación de mantenimiento y aumentando la eficiencia operativa. Los estudios revisados destacan cómo las tecnologías basadas en Big Data han mejorado la capacidad de las empresas para anticiparse a fallas, reduciendo los tiempos de inactividad y maximizando el rendimiento de los equipos.

Las tecnologías más avanzadas, como las CNN, SVM y el aprendizaje profundo, han mostrado un rendimiento superior en términos de precisión. En varios estudios, estas herramientas alcanzaron tasas de precisión superiores al 94%, con aplicaciones específicas que lograron hasta un 99.4% al integrar algoritmos como GoogLeNet con clasificadores tradicionales, como SVM y k-NN. Este nivel de precisión es particularmente útil en el diagnóstico de fallas complejas, donde los patrones de comportamiento no son fácilmente identificables por métodos tradicionales.

En contraste, tecnologías como las redes neuronales de retropropagación (BPNN) y las máquinas de aprendizaje extremo (ELM) presentan limitaciones en escenarios con datos no lineales o condiciones operativas desafiantes. Estas herramientas, aunque útiles en contextos específicos, alcanzaron precisiones inferiores al 90%, como el caso del modelo ELM aplicado a sistemas de bombeo, que logró un 89%, y los modelos de retropropagación, con un 78% en aplicaciones similares. Métodos más simples, como las simulaciones basadas en regresión múltiple, también enfrentan restricciones, ya que carecen de la robustez necesaria para manejar datos heterogéneos o incompletos.

La adopción de tecnologías avanzadas, como las CNN y Big Data, enfrenta desafíos significativos en la industria petrolera. Uno de los principales obstáculos es la calidad y disponibilidad de datos. Estas tecnologías requieren grandes volúmenes de datos bien etiquetados y estructurados, lo cual puede ser complicado en un sector caracterizado por operaciones en condiciones extremas. Además, la infraestructura necesaria, que incluye hardware especializado como GPUs y plataformas de análisis escalables, representa un costo inicial elevado. Esto, sumado a la necesidad de capacitar a los equipos técnicos, puede desincentivar su adopción en algunas organizaciones.

La implementación de modelos basados en Big Data también exige la integración de sistemas capaces de recopilar, almacenar y analizar datos en tiempo real provenientes de múltiples

sensores distribuidos. Este proceso implica la sincronización de datos heterogéneos, un reto considerable en operaciones geográficamente dispersas. Por otro lado, las redes neuronales convolucionales, aunque efectivas para procesar datos complejos, requieren experiencia especializada en su diseño, ajuste e interpretación, lo que añade un nivel de complejidad técnica y organizacional.

En contraste con las herramientas más complejas, tecnologías como las máquinas de soporte vectorial (SVM) y la lógica difusa ofrecen ventajas en términos de simplicidad y facilidad de implementación. Las SVM son efectivas con conjuntos de datos más pequeños y menos ruidosos, lo que reduce los requisitos de infraestructura y las hace adecuadas para aplicaciones donde los recursos son limitados. La lógica difusa, por su parte, es particularmente útil para manejar datos imprecisos o incompletos. Su integración con otras tecnologías, como redes neuronales, permite desarrollar soluciones híbridas adaptables a diversas condiciones operativas.


Aunque los 40 artículos revisados proporcionan un análisis técnico detallado de las tecnologías de mantenimiento predictivo, hay aspectos relevantes que no han sido explorados suficientemente. Estas áreas podrían enriquecer la comprensión y aplicación de estas tecnologías en la industria petrolera:

- **Impacto Ambiental:** Falta un análisis detallado sobre cómo estas tecnologías pueden contribuir a la reducción de desechos, emisiones y el uso innecesario de materiales, aspectos fundamentales en el contexto de sostenibilidad.
- **Evaluación Económica a Largo Plazo:** Hay una ausencia de estudios que analicen con profundidad el retorno de inversión (ROI) y los costos operativos a largo plazo, lo que limita la justificación económica para adoptar tecnologías más avanzadas.
- **Condiciones Operativas Extremas:** Aunque se reconocen las dificultades de operar en ambientes extremos, pocos estudios investigan cómo estas tecnologías pueden ser adaptadas para ser más resilientes a altas presiones, temperaturas extremas o ambientes corrosivos.
- **Aplicación en Equipos Secundarios:** Gran parte de los estudios se centra en equipos críticos, dejando de lado los equipos secundarios que, aunque no esenciales, son fundamentales para la continuidad de las operaciones y podrían beneficiarse significativamente de las innovaciones en mantenimiento predictivo.

En Figura 2, se confirma la predominancia de las redes neuronales y el deep learning como enfoques clave en el mantenimiento predictivo dentro de la industria petrolera. De los 40 estudios analizados, 13 implementaron estos métodos, destacando su capacidad para modelar relaciones no lineales y procesar grandes volúmenes de datos con alta precisión. En comparación, las máquinas de soporte vectorial (SVM) fueron utilizadas en 7 trabajos, consolidándose como una alternativa efectiva en escenarios específicos. La prevalencia de las redes neuronales resalta su versatilidad para adaptarse a diferentes tipos de datos y mejorar la detección temprana de fallas, lo que las posiciona como una herramienta fundamental en la optimización del mantenimiento industrial.

Figura 2

Distribución de Métodos de Mantenimiento Predictivo en la Industria Petrolera



9. Conclusiones

La implementación del mantenimiento predictivo en la industria petrolera ha demostrado ser una estrategia altamente efectiva para reducir tiempos de inactividad, mejorar la seguridad operativa y optimizar el uso de recursos. Las tecnologías basadas en inteligencia artificial y aprendizaje automático, como redes neuronales, máquinas de soporte vectorial y Big Data, han permitido realizar predicciones más precisas y acciones preventivas eficientes.

De manera particular, el uso de tecnologías avanzadas como el aprendizaje profundo (Deep Learning), transferencia de aprendizaje (Transfer Learning) y algoritmos evolutivos ha logrado mejorar la precisión diagnóstica a niveles superiores al 90%, incluso en condiciones operativas complejas. Además, los modelos híbridos, que combinan redes neuronales convolucionales con clasificadores tradicionales, han maximizado la efectividad en el diagnóstico de fallas, mostrando un gran potencial en el campo.

A pesar de los avances, la implementación de estas tecnologías enfrenta varios desafíos significativos. Un problema crítico sigue siendo la recolección y estandarización de datos, lo cual es esencial para entrenar modelos predictivos precisos. Los costos iniciales asociados con la infraestructura tecnológica necesaria también representan una barrera considerable para muchas organizaciones. Asimismo, persiste una resistencia al cambio dentro de algunas empresas, lo que dificulta la adopción de enfoques más avanzados en comparación con los métodos tradicionales establecidos.

Las investigaciones sobre casos de estudio y ejemplos de empresas petroleras que han adoptado estrategias de mantenimiento predictivo han revelado mejores prácticas y lecciones aprendidas, que proporcionan valiosas oportunidades para otras empresas del sector. La integración de tecnologías avanzadas como el aprendizaje automático, Big Data y sistemas híbridos de diagnóstico ha sido clave para lograr reducciones significativas en costos operativos, mejorar la confiabilidad de los equipos y optimizar los tiempos de inactividad. Para asegurar el éxito futuro de estas iniciativas, es crucial invertir en sistemas robustos de recolección y almacenamiento de datos, ya que la calidad y disponibilidad de los datos son fundamentales para el desarrollo de modelos predictivos confiables. Además, es indispensable implementar programas de capacitación técnica para los equipos operativos. Formar a los empleados en inteligencia artificial, aprendizaje automático y análisis de datos mejorará no solo la comprensión de las

herramientas, sino también la interpretación adecuada de los resultados generados por los modelos predictivos, lo que ayudará a cerrar la brecha entre la tecnología y los usuarios finales.

10. Referencias

- Abdou, H. A., Elamer, A. A., Abedin, M. Z., & Ibrahim, B. A. (2024). The impact of oil and global markets on Saudi stock market predictability: A machine learning approach. *Energy Economics*, 132, 107416. <https://doi.org/10.1016/j.eneco.2024.107416>
- Animah, I., & Shafiee, M. (2018). Condition assessment, remaining useful life prediction and life extension decision making for offshore oil and gas assets. *Journal of Loss Prevention in the Process Industries*, 53, 17–28. <https://doi.org/10.1016/j.jlp.2017.04.030>
- Bangert, P. (2017). Smart Condition Monitoring Using Machine Learning. *SPE Intelligent Oil and Gas Symposium*, SPE-187936-MS. <https://doi.org/10.2118/187936-MS>
- Bangert, P. (2019, marzo 15). *Predicting and Detecting Equipment Malfunctions using Machine Learning*. SPE Middle East Oil and Gas Show and Conference, Manama, Bahrain. <https://doi.org/10.2118/195149-MS>
- Bangert, P., & Sharaf, S. (2019). Predictive Maintenance for Rod Pumps. *SPE Western Regional Meeting*, D031S009R003. <https://doi.org/10.2118/195295-MS>
- Barbariol, T., Feltresi, E., & Susto, G. A. (2020). A Machine Learning-Based System for Self-Diagnosis Multiphase Flow Meters. *Day 2 Tue, January 14, 2020*, D021S042R003. <https://doi.org/10.2523/IPTC-19865-MS>
- Bezerra, M. A. D., Schnitman, L., De A. Barreto Filho, M., & A. M. Felipe De Souza, J. (2009). Pattern Recognition For Downhole Dynamometer Card In Oil Rod Pump System Using Artificial Neural Networks: *Proceedings of the 11th International Conference on Enterprise Information*, 2, 351–355. <https://doi.org/10.5220/0002000403510355>
- Cai, W., Li, W., & Xu, J. (2022). Study on the P-S-N Curve of Sucker Rod Based on Three-Parameter Weibull Distribution. *Materials*, 15(2), 560. <https://doi.org/10.3390/ma15020560>
- Calderon Blanco, J. D. (2021). Gestión de mantenimiento preventivo como herramienta para la optimización de procesos en la industria [Trabajo de Grado Pregrado, Universidad de Pamplona]. Repositorio Institucional. <http://repositoriodspace.unipamplona.edu.co/jspui/handle/20.500.12744/5679>
- Chen, M. (2024, septiembre 23). *¿Qué es el big data?* Oracle. <https://www.oracle.com/mx/big-data/what-is-big-data/>

- Chen, S., Zhao, R., Deng, F., Zhang, D., Chen, G., Hao, H., Shi, J., & Zhang, X. (2023). Research of Big Data Production Measurement Method for SRP Wells Based on Electrical Parameters. *Processes*, 11(7), 2158. <https://doi.org/10.3390/pr11072158>
- Chen, Z., White, L. W., & Zhang, H. (2018). Predicting Sucker-Rod Pumping Systems With Fourier Series. *SPE Production & Operations*, 33(04), 928–940. <https://doi.org/10.2118/189991-PA>
- Eyoh, J., & Kalawsky, R. S. (2018, julio). Evolution of Maintenance Strategies in oil and Gas Industries: The Present Achievements and Future Trends. FEAST International Conference on Engineering Management, Industrial Technology, Applied Sciences, Communications and Media 1-9. repository.lboro.ac.uk/account/articles/9550085
- Fauzi, M. F. A. M., Aziz, I. A., & Amiruddin, A. (2019). The Prediction of Remaining Useful Life (RUL) in Oil and Gas Industry using Artificial Neural Network (ANN) Algorithm. *2019 IEEE Conference on Big Data and Analytics (ICBDA)*, 7–11. <https://doi.org/10.1109/ICBDA47563.2019.8987015>
- Figueroa, J., Guarda, L., Benites Perez, R., Bittencourt, C. H., Ramos, M., & Lopez, E. (2022). Deep learning health state prognostics of physical assets in the Oil and Gas industry. *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, 236(4), 598–616. <https://doi.org/10.1177/1748006X20976817>
- Gao, Q., Sun, S., & Liu, J. (2015). Fault diagnosis of suck rod pumping system via extreme learning machines. *2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*, 503–507. <https://doi.org/10.1109/CYBER.2015.7287990>
- Garduño, R. J. (2018, octubre 12). *Algoritmos genéticos*. Conogasi. <https://conogasi.org/articulos/algoritmos-geneticos/>
- Gatta, F., Giampaolo, F., Chiaro, D., & Piccialli, F. (2024). Predictive maintenance for offshore oil wells by means of deep learning features extraction. *Expert Systems*, 41(2), e13128. <https://doi.org/10.1111/exsy.13128>
- Giuliani, M., Camarda, G., Montini, M., Cadei, L., & Bianco, A. (2019, marzo 27). Flaring Events Prediction And Prevention Through Advanced Big Data Analytics And Machine Learning Algorithms. Offshore Mediterranean Conference and Exhibition, <https://onepetro.org/OMCONF/proceedings-abstract/OMC19/All-OMC19/1968>

- Guo, J., Wan, J.-L., Yang, Y., Dai, L., Tang, A., Huang, B., Zhang, F., & Li, H. (2023). A deep feature learning method for remaining useful life prediction of drilling pumps. *Energy*, 282, 128442. <https://doi.org/10.1016/j.energy.2023.128442>
- Guo-hua, L., Shun-li, H., Zhi, Y., Hai-yang, Z., Jing-hong, H., Quan, X., & Ying-hao, S. (2011). A prediction model for a new deep-rod pumping system. *Journal of Petroleum Science and Engineering*, 80(1), 75–80. <https://doi.org/10.1016/j.petrol.2011.10.011>
- Gupta, S., Kumar, A., & Maiti, J. (2024). A critical review on system architecture, techniques, trends and challenges in intelligent predictive maintenance. *Safety Science*, 177, 106590. <https://doi.org/10.1016/j.ssci.2024.106590>
- Hao, D., & Gao, X. (2022). Unsupervised Fault Diagnosis of Sucker Rod Pump Using Domain Adaptation with Generated Motor Power Curves. *Mathematics*, 10(8), 1224. <https://doi.org/10.3390/math10081224>
- Huang, Z., Li, K., Xu, Z., Yin, R., Yang, Z., Mei, W., & Bing, S. (2024). STP-Model: A semi-supervised framework with self-supervised learning capabilities for downhole fault diagnosis in sucker rod pumping systems. *Engineering Applications of Artificial Intelligence*, 135, 108802. <https://doi.org/10.1016/j.engappai.2024.108802>
- Kejela, G., Esteves, R. M., & Rong, C. (2014). Predictive Analytics of Sensor Data Using Distributed Machine Learning Techniques. *2014 IEEE 6th International Conference on Cloud Computing Technology and Science*, 626–631. <https://doi.org/10.1109/CloudCom.2014.44>
- Liu, J., Feng, J., & Gao, X. (2019). Fault Diagnosis of Rod Pumping Wells Based on Support Vector Machine Optimized by Improved Chicken Swarm Optimization. *IEEE Access*, 7, 171598–171608. <https://doi.org/10.1109/ACCESS.2019.2956221>
- Liu, J., Feng, J., Xiao, Q., Liu, S., Yang, F., & Lu, S. (2021). Fault Diagnosis of Rod Pump Oil Well Based on Support Vector Machine Using Preprocessed Indicator Diagram. *2021 IEEE 10th Data Driven Control and Learning Systems Conference (DDCLS)*, 120–126. <https://doi.org/10.1109/DDCLS52934.2021.9455702>
- Liu, J., Zang, D., Liu, C., Ma, Y., & Fu, M. (2019). A leak detection method for oil pipeline based on markov feature and two-stage decision scheme. *Measurement*, 138, 433–445. <https://doi.org/10.1016/j.measurement.2019.01.029>

- Liu, Y., Yao, K., Lenz, T. L., Olabinjo, L., Seren, B., Seddighrad, S., & Babu, C. G. D. (2010). Failure Prediction for Rod Pump Artificial Lift Systems. *SPE Western Regional Meeting*, 70. <https://doi.org/10.2118/133545-MS>
- Liu, Y., Yao, K.-T., Raghavenda, C. S., Wu, A., Guo, D., Zheng, J., Olabinjo, L., Balogun, O., & Ershaghi, I. (2013). Global Model for Failure Prediction for Rod Pump Artificial Lift Systems. *SPE Western Regional & AAPG Pacific Section Meeting 2013 Joint Technical Conference*, SPE-165374-MS. <https://doi.org/10.2118/165374-MS>
- Lv, X., Wang, H., Zhang, X., Liu, Y., Jiang, D., & Wei, B. (2021). An evolutionary SVM method based on incremental algorithm and simulated indicator diagrams for fault diagnosis in sucker rod pumping systems. *Journal of Petroleum Science and Engineering*, 203, 108806. <https://doi.org/10.1016/j.petrol.2021.108806>
- Manrique, E. M. (2020). Machine Learning: análisis de lenguajes de programación y herramientas para desarrollo. *Revista Ibérica de Sistemas e Tecnologias de Informação*, (E28), 586-599. <https://www.risti.xyz/issues/ristie28.pdf>
- Martinović, B., Bijanić, M., Danilović, D., Petrović, A., & Delibasić, B. (2023). Unveiling Deep Learning Insights: A Specialized Analysis of Sucker Rod Pump Dynamographs, Emphasizing Visualizations and Human Insight. *Mathematics*, 11(23), 4782. <https://doi.org/10.3390/math11234782>
- Maya, J. A. V. (2018). Aplicación de RCM como estrategia de implementación del mantenimiento predictivo para la metodología TPM [MasterThesis, [Trabajo de grado, Universidad Nacional De Colombia].Repositorio Institucional. <https://repositorio.unal.edu.co/handle/unal/64727>
- Mohammed, A. (2023). Data driven-based model for predicting pump failures in the oil and gas industry. *Engineering Failure Analysis*, 145, 107019. <https://doi.org/10.1016/j.engfailanal.2022.107019>
- Nascimento, J., Maitelli, A., Maitelli, C., & Cavalcanti, A. (2021). Diagnostic of Operation Conditions and Sensor Faults Using Machine Learning in Sucker-Rod Pumping Wells. *Sensors*, 21(13), 4546. <https://doi.org/10.3390/s21134546>
- Navarro, M. X. S. (2023). Sostenibilidad del sector de hidrocarburos en colombia: perspectivas y alternativas al petróleo de cara al 2050 [MasterThesis, [Trabajo de grado, Universidad

- Pontificia Bolivariana]. Repositorio Institucional.
<http://hdl.handle.net/20.500.11912/10603>
- Nunes, P., Santos, J., & Rocha, E. (2023). Challenges in predictive maintenance – A review. *CIRP Journal of Manufacturing Science and Technology*, 40, 53–67.
<https://doi.org/10.1016/j.cirpj.2022.11.004>
- Orrù, P. F., Zoccheddu, A., Sassu, L., Mattia, C., Cozza, R., & Arena, S. (2020). Machine Learning Approach Using MLP and SVM Algorithms for the Fault Prediction of a Centrifugal Pump in the Oil and Gas Industry. *Sustainability*, 12(11), 4776.
<https://doi.org/10.3390/su12114776>
- Paredes, R. (2020). Tipos de mantenimiento aplicados en la industria petrolera venezolana de la Región Occidente. *Revista Ingeniería*, 4(9), 129–142.
<https://doi.org/10.33996/revistaingenieria.v4i9.61>
- Pennel, M., Hsiung, J., & Putcha, V. B. (2018). Detecting Failures and Optimizing Performance in Artificial Lift Using Machine Learning Models. *SPE Western Regional Meeting*, D041S011R008. <https://doi.org/10.2118/190090-MS>
- Pérez, F. A. (2021). Conceptos generales en la gestión del mantenimiento industrial. Editorial USTA. <http://hdl.handle.net/11634/33276>
- Pérez, J. P. (2024a, febrero 26). *Red Neuronal*. Definición de. <https://definicion.de/red-neuronal/>
- Pérez, J. P. (2024b, febrero 27). *Machine Learning*. Definición de. <https://definicion.de/machine-learning/>
- Raza, D. J. (2018). *From Prevent to “Predict & Prevent (PnP)”*: Optimizing oil and gas Asset integrity decisions. <https://doi.org/10.29007/257x>
- Silveira, N. N. A., Meghoe, A. A., & Tinga, T. (2024). Quantifying the suitability and feasibility of predictive maintenance approaches. *Computers & Industrial Engineering*, 194, 110342.
<https://doi.org/10.1016/j.cie.2024.110342>
- Sreenivasan, H., & Krishna, S. (2024). Automatic sucker rod pump fault diagnostics by transfer learning using googlenet integrated machine learning classifiers. *Process Safety and Environmental Protection*, 191, 14–26. <https://doi.org/10.1016/j.psep.2024.08.059>
- Tran, N. L. (2022). A Data-Driven Approach For Monitoring And Predictive Diagnosis Of Sucker Rod Pump System [MasterThesis, The University of Oklahoma]. Repositorio Institucional.
<https://hdl.handle.net/11244/334962>

- Villegas, L., & Pérez, R. (2023). *Inteligencia Artificial para Toma de Decisiones en el Mantenimiento Predictivo a equipos Turbocompresores en la Industria Petrolera. 1.* https://www.researchgate.net/publication/371008558_Artificial_Intelligence_for_Decisions_Making_in_Predictive_Maintenance_to_Turbocompressors_Equipment_in_the_Oil_Industry
- Wang, D., & Liu, H. (2018). Prediction and Analysis of Polished Rod Dynamometer Card in Sucker Rod Pumping System with Wear. *Shock and Vibration*, 2018(1), 4979405. <https://doi.org/10.1155/2018/4979405>
- Xing, H. Y., Han, Y. T., Qin, P., & Liu, C. H. (2013). MMM Identifying Damage for Recycled Pumping Rod Base on SVM. *Applied Mechanics and Materials*, 401–403, 1251–1254. <https://doi.org/10.4028/www.scientific.net/AMM.401-403.1251>
- Xu, P., Xu, S., & Yin, H. (2007). Application of self-organizing competitive neural network in fault diagnosis of suck rod pumping system. *Journal of Petroleum Science and Engineering*, 58(1–2), 43–48. <https://doi.org/10.1016/j.petrol.2006.11.008>
- Yuandeng, W., Shaohu, L., Weiguo, M., Xiaofeng, R., & Baolong, Q. (2023). Machine learning method for predicting the fatigue life of sucker rods. *Engineering Fracture Mechanics*, 282, 109161. <https://doi.org/10.1016/j.engfracmech.2023.109161>
- Zhang, K., Wang, Q., Wang, L., Zhang, H., Zhang, L., Yao, J., & Yang, Y. (2022). Fault diagnosis method for sucker rod well with few shots based on meta-transfer learning. *Journal of Petroleum Science and Engineering*, 212, 110295. <https://doi.org/10.1016/j.petrol.2022.110295>
- Zhong, Z., Sun, A. Y., Wang, Y., & Ren, B. (2020). Predicting field production rates for waterflooding using a machine learning-based proxy model. *Journal of Petroleum Science and Engineering*, 194, 107574. <https://doi.org/10.1016/j.petrol.2020.107574>