

## Predicción de fallas en un motor de combustión interna de la empresa OCP Ecuador

Fabrizio Bladimir Vega Álvarez

[fabla\\_cat@hotmail.com](mailto:fabla_cat@hotmail.com)

<https://orcid.org/0000-0002-0321-5109>

Universidad Internacional de la Rioja

Quito – Ecuador

### RESUMEN

El desarrollo de este trabajo tiene como objetivo principal predecir fallas en un motor de combustión interna de marca Wartsila, modelo 12V32 LN de la empresa privada Oleoducto de Crudos Pesados OCP Ecuador. Para realizar el estudio se considera el monitoreo de variables principales como: presión, temperatura, viscosidad, desgastes, entre otras; todos los activos que están constituidos por sensores facilitan la interpretación bajo tendencias y análisis de estadística descriptiva. La metodología que se implementa se basa en la aplicación de técnicas de máquinas de aprendizaje automático, sean supervisados o no supervisados con los algoritmos correspondientes que facilitan la predicción de fallas en los motores de combustión interna. Cuando la predicción de fallas es eficiente, los planes de mantenimiento preventivo serán sustituidos por planes de mantenimientos basados en condición. Si la ejecución del mantenimiento basado en condición (CBM) es eficiente, es decir, una estrategia de mantenimiento que se basa en los resultados, como la disponibilidad, fiabilidad, costes de mantenimiento, vida útil de los elementos de los motores, seguridad y bajo impacto ambiental.

*Palabras clave:* aprendizaje supervisado; estadística descriptiva e inferencial; visualización de datos masivos; inteligencia artificial; motor de combustión interna; OCP Ecuador.

Correspondencia: [fabla\\_cat@hotmail.com](mailto:fabla_cat@hotmail.com)

Artículo recibido 05 diciembre 2022 Aceptado para publicación: 05 enero 2023

Conflictos de Interés: Ninguna que declarar

Todo el contenido de **Ciencia Latina Revista Científica Multidisciplinar**, publicados en este sitio están disponibles bajo

Licencia [Creative Commons](https://creativecommons.org/licenses/by/4.0/) 

Cómo citar: Vega Álvarez, F. B. (2023). Predicción de fallas en un motor de combustión interna de la empresa OCP Ecuador. *Ciencia Latina Revista Científica Multidisciplinar*, 7(1), 4207-4224.

[https://doi.org/10.37811/cl\\_rcm.v7i1.4749](https://doi.org/10.37811/cl_rcm.v7i1.4749)

## Prediction of failures in an internal combustion engine of the company OCP Ecuador

### ABSTRACT

The main objective of this work is to predict failures in an internal combustion engine of the Wartsila brand, model 12V32 LN of the private company Oleoducto de Crudos Pesados OCP Ecuador. To carry out the study, the monitoring of main variables such as: pressure, temperature, viscosity, wear, among others; All assets that are made up of sensors facilitate interpretation under trends and analysis of descriptive statistics. The methodology that is implemented is based on the application of machine learning techniques, supervised or unsupervised with the corresponding algorithms that facilitate the prediction of failures in internal combustion engines. When the prediction of failures is efficient, the preventive maintenance plans will be replaced by maintenance plans affected in condition. If the execution of the condition-based maintenance (CBM) is efficient, that is, a maintenance strategy that is based on the results, such as availability, costs, maintenance, life of the engine elements, Safety and low environmental impact.

**Keywords:** *supervised learning; descriptive and inferential statistics; visualization of massive data; artificial intelligence; internal combustion engine.*

## INTRODUCCIÓN

La Industria 4.0 es una evolución tecnológica que se encuentra en pleno desarrollo y que está cambiando la lógica de funcionamiento de ciertas industrias. Así, esta nueva era de la industria se caracteriza por la utilización de tecnologías avanzadas como el Internet de las Cosas (IoT), la inteligencia artificial (IA), la Automatización Robótica, la Nube y el Big Data. Estas tecnologías permiten a las empresas adoptar un enfoque de fabricación inteligente, donde los procesos de fabricación se optimizan y se automatizan para aumentar la eficiencia y la productividad (Ynzunza et al., 2017).

Esto también ayuda a las industrias a mejorar el rendimiento de los productos, a reducir el tiempo de producción y a disminuir los costes asociados con la producción. Con eso, estas pueden alcanzar mayores niveles de innovación, además de ofrecer productos y servicios de mayor calidad. Además, la Industria 4.0 también ayuda a mejorar la seguridad y la eficiencia energética en la fabricación, lo que es esencial para la protección del medioambiente (Popkova et al., 2019).

La Industria 4.0 está llegando a las grandes empresas petroleras, especialmente en los países desarrollados, buscando ser más eficientes en sus procesos, reducir los gastos, preservar el medioambiente y minimizar los riesgos de accidentes laborales. Esto se consigue mediante el aprendizaje y el manejo de datos, la inteligencia artificial, que es una entrada para el uso de la Industria 4.0 (Lu et al., 2019).

Esta tecnología se está aplicando para la predicción de fallas, y por ende resulta relevante evaluar su pertinencia para la evaluación, por ejemplo, de los motores Wartsila12V32LN instalados en el OCP (Oleoducto de Crudos Pesados) de Ecuador.

El OCP se construyó en 2001 como un proyecto para transportar petróleo pesado desde la Amazonía hasta un terminal marítimo en la provincia costera ecuatoriana: Esmeraldas. La empresa OCP Ecuador S.A utiliza motores de combustión interna marca Wartsila 12V32LN para suministrar la energía necesaria. Estos motores son de alta confiabilidad y disponibilidad con un coste de mantenimiento alrededor de \$600.000 dólares por motor. Así también se sabe que los datos obtenidos de los sensores de presión, temperatura, caudal, viscosidad no permiten predecir las fallas que pueden alterar el funcionamiento del activo y parar las operaciones de transporte. Esto causa un mantenimiento ineficiente que ocasiona la sustitución de elementos antes de su vida útil, obteniendo costos excesivos (Cortés, 2017).

La predicción de fallas en los motores de combustión interna es un tema de gran importancia en la industria, ya que permite garantizar la seguridad y eficiencia en la operación de las empresas (Villada & Cadavid, 2007).

Para llevar a cabo este estudio, se recopilaron datos históricos de los motores de combustión interna en operación en la empresa OCP Ecuador. A continuación, se aplicaron técnicas de aprendizaje automático, como el algoritmo Naive Bayes, J48, SVM y redes neuronales, para desarrollar un modelo de predicción de fallas. Además, se aplicó una técnica de reducción de dimensionalidad para seleccionar los atributos más importantes en la predicción de fallas. Se llevó a cabo un proceso de saneado y validación de los datos para garantizar la precisión y confiabilidad del modelo desarrollado (Lim et al., 2021).

Una vez desarrollado el modelo, se llevó a cabo una evaluación exhaustiva para medir su precisión y fiabilidad en la predicción de fallas. El rendimiento del modelo fue comparado con los métodos tradicionales de detección de fallas utilizados en la empresa OCP Ecuador. Si el modelo resultó ser eficaz, se consideró la posibilidad de implementarlo en la empresa con el objetivo de mejorar la eficiencia y reducir los costos asociados a los tiempos de inactividad debido a fallos no detectados.

Así, el propósito de este trabajo es aplicar esta tecnología a la predicción de fallas, principalmente del motor Wartsila12V32LN instaladas en el OCP Ecuador, mediante el análisis y la comprensión del comportamiento de los datos, empleando técnicas y algoritmos de aprendizaje supervisado y no supervisado; para ello, se aplicará software de libre acceso como WEKA porque la interacción con el usuario es más amigable y la utilización del Software R que facilitara la visualización de gráficos de calidad.

Así, el estudio también proporciona un sistema de predicción de fallas en un motor de combustión interna para la empresa OCP Ecuador mediante el uso de técnicas de aprendizaje automático. Este sistema tiene el potencial de mejorar la seguridad y eficiencia en la operación de la empresa, reduciendo los tiempos de inactividad y costos asociados a los fallos no detectados en los motores de combustión interna.

### **METODOLOGÍA**

Considerando que la meta de esta investigación fue prever posibles problemas en un motor de combustión interna de la marca Wartsila 12V32LN del Oleoducto de Crudos Pesados OCP Ecuador, su metodología se basó en la utilización de algoritmos de

aprendizaje automático, con el objetivo de lograr una transición eficiente al mantenimiento basado en el estado del motor. Para ello, se detalla el procedimiento para recolectar datos de las principales variables del motor Wartsila, seguido del proceso de limpieza de los datos recolectados y finalmente, la predicción de posibles fallas en los diferentes sistemas del motor descritos en el estudio.

## RESULTADOS Y DISCUSIÓN

La tabla 3, indica los resultados de la aplicación de diferentes técnicas con los algoritmos correspondientes, sus valores de error absoluto y la clasificación de las instancias correctamente son los indicadores para la selección correspondiente. Si la premisa es seleccionar por la clasificación correctamente de instancias, es muy eficiente el algoritmo de J48 con el 99.73%, seguido de la Redes Neuronales con el 99.11%. Si nuestro indicador es el valor del error absoluto, se verifica que las Redes Neuronales tiene un valor de 0.015 y el J48 indica un valor de 0.0018.

**Tabla 3.** Selección de la técnica con menor error absoluto y mayor porcentaje de instancias

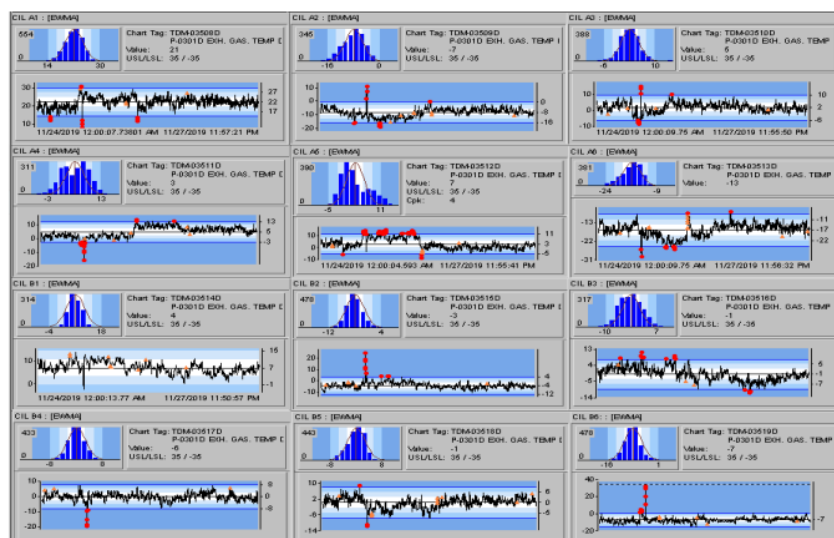
Técnicas	Algoritmos	Clasificación de Instancias correctamente [%]	Error absoluto
Supervisado	Naive Bayes	86.79	0.0615
Supervisado	Naive Bayes Modificado	95.38	0.0191
Supervisado	J48	99.73	0.0018
Supervisado	SVM	91.99	0.24
Supervisado	Redes Neuronales	98.11	0.015
No supervisado	Reducción de Dimensiones	98.37	0.0085
No supervisado	K-means	Cluster 0 = 42% Cluster 1 = 58%	X

### Visualización de las variables principales

Con la aplicación del software RStudio, se puede visualizar los datos de las variables principales del motor Wartsila 12V32LN, con el objetivo de interactuar de manera rápida con las cuatro estaciones de bombeo e identificar la anomalía en cualquier variable del motor. La gráfica 27 está dividida en tres secciones; la primera se presenta una distribución normal de los datos que se monitorean en línea directamente enlazada desde el PLC del motor, la segunda sección, se visualiza el valor de lectura real en ese

instante de tiempo con su respectivo nombre de la variable y del motor, respaldado por los límites de control inferior y superior. Finalmente, se presenta una tercera sección que muestra el comportamiento de la variable a lo largo del tiempo de funcionamiento, la gráfica indica la aplicación de un control de calidad de la ley del “SIX SIGMA” con el objetivo de indicar si una variable se encuentra en un proceso de control. Por lo tanto, el analista puede indicar si una variable está fuera de control de una manera rápida y realizar la gestión correspondiente para los mantenimientos predictivos y evitar las paradas no programadas de la operación del oleoducto.

Figura 17. Visualización de las variables principales, con R



Fuente Propia

## RESULTADOS

Este análisis ha permitido la búsqueda de técnicas de aprendizaje automático para la aplicación de diferentes algoritmos que permita evaluar de forma objetiva del estado de un síntoma de diagnóstico, que a su vez sea fuente de información para ser utilizado en el proceso de diagnóstico de los equipos y así evaluar correctamente su estado técnico y poder proponer medidas de corrección o previsión para mejorar el funcionamiento en este caso de los motores Wartsila 12V32LN instalados en el Oleoducto de Crudos Pesados OCP Ecuador.

Los datos del monitoreo continuo de las variables principales del motor se ajustaron con mejor valor de exactitud los algoritmos como el J48 y Redes Neuronales; la clasificación de las instancias correctamente para cada algoritmo fue de 99.73% y 98.11% y cuando el indicador es el error absoluto, se tiene 0.0018 y 0.015 correspondientemente. La

aplicación del algoritmo de Naive Bayes tiene una clasificación de instancias correctas del 86.79% con un error absoluto de 0.0615, al momento de realizar ciertos ajustes en el algoritmo, el resultado de clasificación de instancias correctas incrementa hasta el 95.38% y su error disminuye a 0.0191.

El algoritmo de reducción de dimensiones es de gran ayuda para optimizar el análisis de las instancias de entrada, pero no es muy eficiente al aplicar a los datos del motor Wartsila porque se pueden hacer discretas ciertas variables que pueden alterar nuestra predicción, sin embargo, se reduce de 18 atributos a 6 atributos incluidos los de la clase. Sus resultados fueron muy ajustados con un error absoluto de 0.0085 y 98.37% de instancias clasificadas correctamente.

Al ejecutar el algoritmo k-means, se puede ver que los datos son agrupados en dos clústeres con 42% y 58%, este tipo de algoritmo no facilita la identificación del tipo de falla puntualmente, por lo tanto, la predicción no es confiable.

El fichero de visualización es de gran ayuda práctica y de inspección visual para encontrar patrones de fallas, similitudes o correlaciones entre las variables de diagnóstico del motor Wartsila, ver figura 26. La aplicación del software RStudio facilita la obtención de gráficas con la estadística descriptiva, ver figura 27, el valor del resultado de la estadística descriptiva es importante para la predicción o para el control de calidad de cada variable en función del tiempo. Como el motor consta de gran cantidad de variables, la visualización de todas las variables en una sola interfaz complica el entendimiento para el analista y aún más si se necesita observar el comportamiento en los 22 motores Wartsila en un mismo instante.

Una vez realizado el siguiente estudio e identificado las técnicas y algoritmos que facilitan la predicción de fallas en los motores Wartsila 12V32LN, se ejecuta en las estaciones de bombeo, principalmente en la estación Amazonas, que contiene 5 motores Wartsila. Donde los resultados de big-data indica tener problemas en el sistema de postcombustión. Al notificar el resultado al personal de campo, se revisa el sistema de bombas de inyección y valida la predicción, dando como resultado el daño interno en la bomba de inyección del cilindro B6, por lo tanto, posteriormente se gestiona una orden correctiva y se registra en el sistema de mantenimiento del Oleoducto de Crudos Pesados. Con la aplicación del algoritmo J48 y Redes Neuronales, las predicciones en función de las variables son confiables.

ILUSTRACIONES, TABLAS, FIGURAS.

Adquisición de datos

Siguiendo las instrucciones del manual de mantenimiento del motor Wartsila 12V32LN y aplicando las técnicas de mantenimiento basado en el estado del motor, se identifican los sistemas principales y las variables relevantes a monitorear. Con esto en mente, se recolectan los datos directamente del sistema LHMI en cada estación de bombeo.

**Tabla 1.**

*Sistemas de monitoreo del motor Wartsila 12V32LN.*

Sistemas Principales	Variables	Descripción
Sistema de arranque	T AC	Temperatura del aire de carga
	P AC	Presión del aire de carga
	RPM	Velocidad del motor
Sistema de combustible	P Fuel	Temperatura del combustible
	T Fuel	Temperatura del combustible
Sistema de refrigeración	T HT	Temperatura de HT
	T LT	Temperatura de LT
	P OIL	Presión de aceite
Sistema de desgaste	P Cárter	Presión de cárter
Sistema de post-combustión	T A/B	Temperatura de gases de escape banco A y banco B

Los sistemas son monitoreados mediante variables específicas y los datos son recolectados en tiempo real y almacenados en bases de datos. Se verifica qué motores están en uso y luego se seleccionan las variables correspondientes en el archivo "Historic Trend" para cada estación de bombeo. La tabla 3.0 muestra la nomenclatura de las variables para el motor "DELTA" en la estación de bombeo Sardinias.

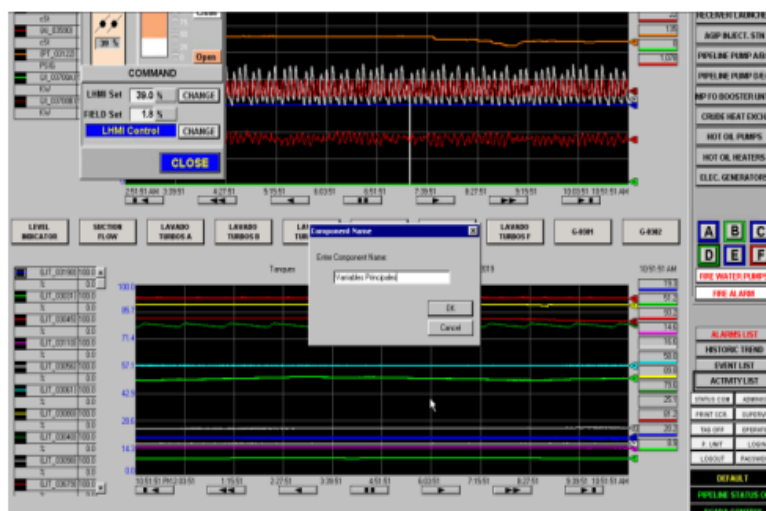


Tabla 2. Identificación de las variables principales en el sistema SCADA

Variables	Tags del motor "DELTA"	Descripción
T AC	TI-03536D	Temperatura del aire de carga
P AC	PI-03536D	Presión del aire de carga
RPM	SI-03500D	Velocidad del motor
Sistema de combustible	PI-03540D	Presión del combustible
	TI-03540D	Temperatura del combustible
Sistema de refrigeración	TI-03545D	Temperatura de HT
	TI-03547D	Temperatura de LT
	PI-03537D	Presión del aceite
Sistema de desgaste	PI-03580D	Presión del cárter
Sistema de post-combustión	TI-03532D	Temperatura de gases de escape banco A y banco B
	TI-03533D	

Cuando se selecciona las variables, los archivos se guarda en formato "csv" con el nombre de "Variables Principales "en disco local. Por seguridad se tiene mapeado los discos por estación para no ocasionar problemas al sistema SCADA.

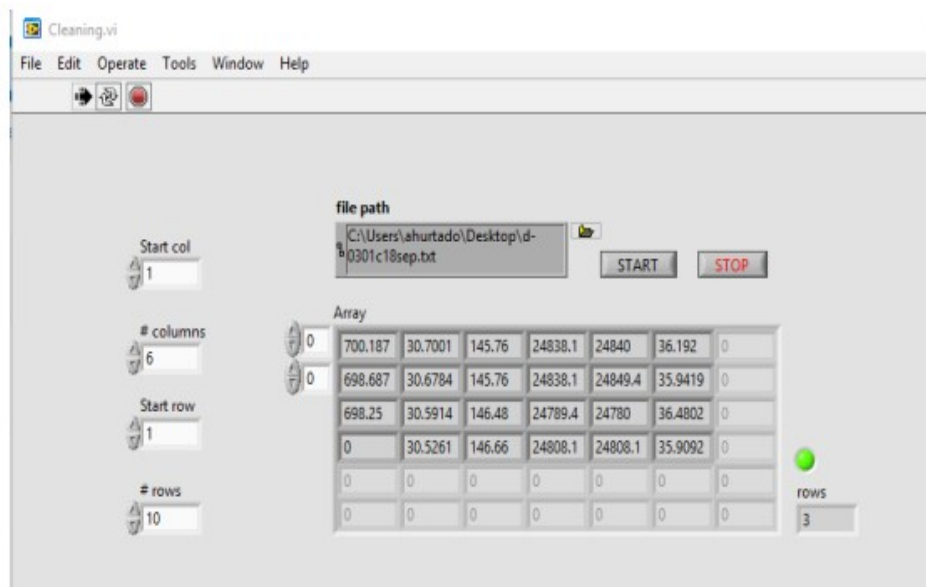
Figura 1. Selección y sustracción de variables principales del motor D-0301D



(Fuente Propia)

Finalmente, el archivo llega al analista para el proceso de sanear la información, validar los valores y sincronizarlos con la fecha y el tiempo. El especialista en vibraciones ayuda a desarrollar una interfaz (denominada "Cleaning") en programación LABVIEW para eliminar valores incorrectos y sincronizar las variables. La data se extrae desde campo, se convierte en formato "txt", se limpia y se guarda en disco local.

Figura 2. Saneado de la data del motor D-0301D con la aplicación del programa Cleaning



(Fuente Propia)

Figura 3. Saneado de la data del motor D-0301D

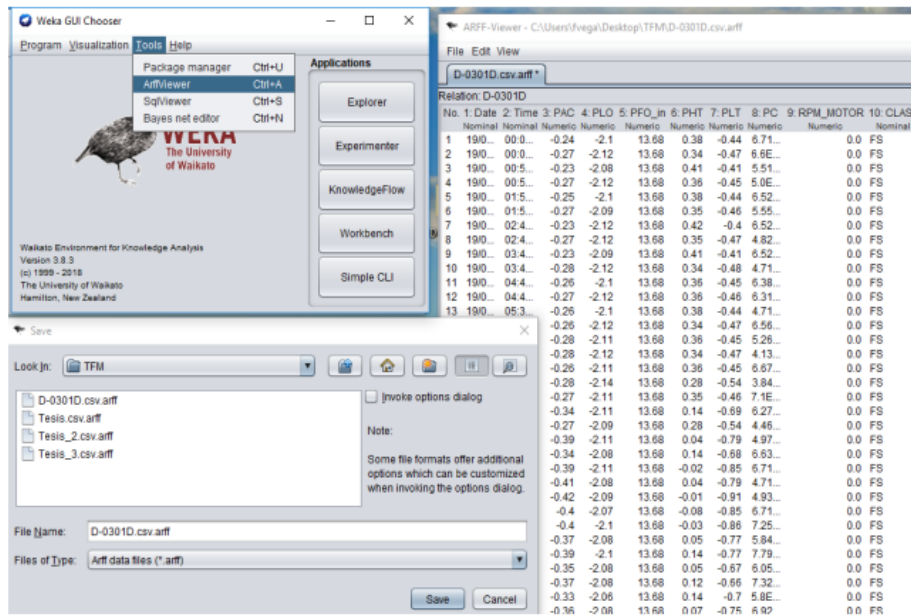
Date	Time	PRESION AIRE CARGA	PRESION LUBRICACION	PRESION COMBUSTIBLE	PRESION HT	PRESION LT	PRESION CENTR	RPM	RPM TURBO BANDA 1	RPM TURBO BANDA 2	POSICION CENILLERA	TEMPERATURA AIRE CARGA	TEMPERATURA ENTRADA COMBUSTIBLE	TEMPERATURA HT	TEMPERATURA LT	TEMPERATURA LUBRICACION	TEMPERATURA GASES ESCAPE BANDA 1	TEMPERATURA GASES ESCAPE BANDA 2	Posibles fallas
23/07/2019	11:40:26	0.53	4.37	6.71	1.697	2.630	0.851	627	16067	13434	24	50	124	91	41	63	625	602	FS
23/07/2019	12:36:26	0.14	5.05	6.52	2.117	1.711	0.888	522	11569	13971	21	55	124	92	47	65	615	632	FS
23/07/2019	12:36:36	0.83	3.96	6.56	1.606	2.176	0.886	627	16134	16980	24	53	124	91	44	64	630	636	FS
23/07/2019	13:32:36	0.53	4.99	6.83	2.095	1.640	0.945	499	10485	16044	21	57	124	92	49	65	610	614	FS
23/07/2019	13:32:46	0.34	5.14	6.73	1.834	1.861	0.963	560	12073	13013	21	59	123	88	41	64	586	597	FS
23/07/2019	14:28:46	0.85	4.71	6.42	2.224	2.511	0.946	609	21039	20904	31	53	125	92	51	66	632	636	S_Refrigeración Func NM
23/07/2019	14:28:56	0.30	3.84	7.03	2.201	2.502	0.965	609	8963	10300	18	53	123	90	43	64	572	583	FS
23/07/2019	15:24:56	0.92	5.09	6.43	1.579	1.620	0.941	493	20558	20747	31	58	125	92	49	65	632	632	FS
23/07/2019	15:25:06	0.35	5.11	6.07	2.068	2.693	0.944	712	15480	24180	38	53	123	85	37	64	561	558	S_Combustible
23/07/2019	16:21:06	1.78	4.89	6.75	2.407	2.014	0.971	615	24261	15390	24	57	123	91	45	65	626	630	FS
23/07/2019	16:21:16	1.78	5.10	7.15	1.578	1.631	0.942	494	8944	10434	18	54	122	88	44	64	625	627	FS
23/07/2019	17:17:16	0.83	3.86	6.09	2.379	2.694	0.967	710	24266	24152	38	58	124	92	37	65	556	555	S_Combustible
23/07/2019	17:17:26	1.75	4.96	6.24	2.325	2.681	0.941	707	23961	23801	36	56	124	91	41	64	565	564	S_Combustible
23/07/2019	18:13:26	1.71	4.99	6.18	2.370	2.389	0.959	703	24058	23963	37	58	127	85	36	65	560	558	S_Combustible
23/07/2019	18:13:36	1.74	4.96	6.17	2.358	2.639	0.970	706	23963	23852	36	58	127	91	41	65	564	564	S_Combustible
23/07/2019	19:09:36	1.72	4.99	6.21	2.328	2.536	0.940	704	24060	23949	37	57	126	88	39	65	560	558	S_Combustible
23/07/2019	19:09:46	1.71	4.99	6.19	2.329	2.675	0.955	704	24058	23985	36	59	126	91	41	65	560	560	S_Combustible
23/07/2019	20:05:36	1.72	4.95	6.15	2.358	2.531	0.938	707	23929	23831	37	58	129	88	39	65	568	565	S_Combustible
23/07/2019	20:06:06	1.72	5.01	6.24	2.351	2.535	0.954	698	23868	23513	37	57	129	88	39	65	561	561	S_Combustible
23/07/2019	21:02:06	1.73	4.96	6.17	2.297	2.665	0.939	706	24090	23976	36	58	126	91	41	65	565	566	S_Combustible
23/07/2019	21:02:16	1.73	5.01	6.31	2.350	2.529	0.966	698	24015	23899	35	57	126	88	41	65	566	567	S_Combustible
23/07/2019	21:58:16	1.72	4.96	6.20	2.291	2.678	0.943	706	23578	23483	37	58	129	91	39	65	559	558	S_Combustible
23/07/2019	21:58:26	1.72	4.96	6.16	2.335	2.721	0.959	703	23927	23481	36	58	129	88	39	65	557	557	S_Combustible
23/07/2019	22:54:26	1.75	4.99	6.24	2.403	2.540	0.993	707	24090	23976	37	59	125	91	41	65	561	560	S_Combustible
23/07/2019	22:54:36	1.79	5.00	6.18	2.371	2.572	0.960	707	23959	23994	37	58	129	91	42	65	554	559	S_Combustible
23/07/2019	23:50:36	1.74	4.93	6.14	2.412	2.724	0.993	704	24109	23839	36	59	129	88	39	65	559	555	S_Combustible
23/07/2019	23:50:46	1.78	4.96	6.14	2.391	2.714	0.941	708	24197	24084	36	58	128	88	41	65	558	561	S_Combustible
24/07/2019	00:48:46	1.74	4.91	6.17	2.326	2.536	0.980	708	24058	23942	36	59	129	91	39	65	564	557	S_Combustible
24/07/2019	00:48:56	1.75	4.95	6.17	2.330	2.674	0.938	706	24211	24017	37	58	129	91	39	65	559	562	S_Combustible
24/07/2019	01:42:56	1.77	4.88	6.13	2.364	2.520	0.954	709	24129	24118	36	58	129	88	41	65	564	557	S_Combustible
24/07/2019	01:43:06	1.76	4.88	6.16	2.384	2.538	0.950	706	24086	23976	36	58	129	88	39	65	557	555	S_Combustible
24/07/2019	02:39:06	1.79	4.94	6.12	2.327	2.708	0.984	709	24263	24174	37	59	130	91	41	65	562	560	S_Combustible
24/07/2019	02:39:16	1.75	4.89	6.26	2.323	2.663	0.940	710	24113	24009	37	57	120	88	39	65	559	560	S_Combustible

(Fuente Propia)

### Transformación de la data en formato arff

Para convertir archivos "csv" a "arff", se utiliza el software de WEKA. WEKA facilita la interacción con el analista y la validación del proceso de limpieza de datos. Para convertir el archivo, se selecciona "Tools" y "Arffviewer" en la interfaz principal de WEKA, se busca el archivo "D-0301D.csv" para abrir, analizar y finalmente guardar en formato de WEKA.

Figura 4. Transformación de formato CSV a ARFF, en Weka



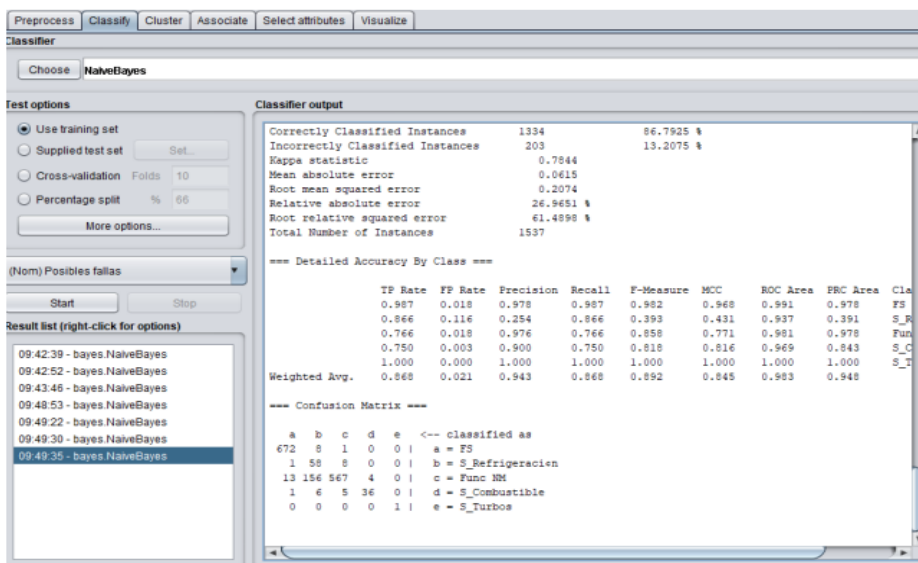
Fuente Propia

## Aplicación de técnicas de aprendizaje supervisado

### Algoritmo Naive Bayes

Una vez que se han aplicado los filtros necesarios al archivo, se emplea el algoritmo Naive Bayes y se entrena con el conjunto de datos "Use training set" para predecir fallos en un motor de combustión interna. Al ejecutar el algoritmo, se obtiene un porcentaje de registros clasificados correctamente del 86.79% y un porcentaje de registros clasificados incorrectamente del 13.20% con un error absoluto de 0.06.

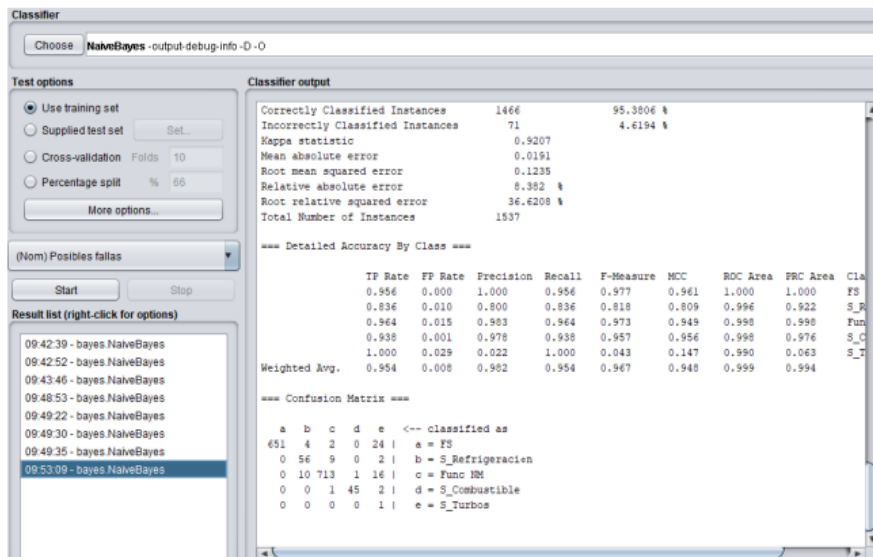
Figura 5. Algoritmo Naive Bayes, en Weka



Fuente Propia

Para mejorar la clasificación de las instancias del motor de combustión interna (MCI), se modifica el algoritmo Naive Bayes. La figura 6 muestra una clasificación correcta del 95.38%, clasificación incorrecta del 4.61% y un error de 0.019%. Por lo tanto, se realizan algunos cambios en la configuración del clasificador Naive Bayes, lo que da como resultado un mejor porcentaje de éxito del 95.38%.

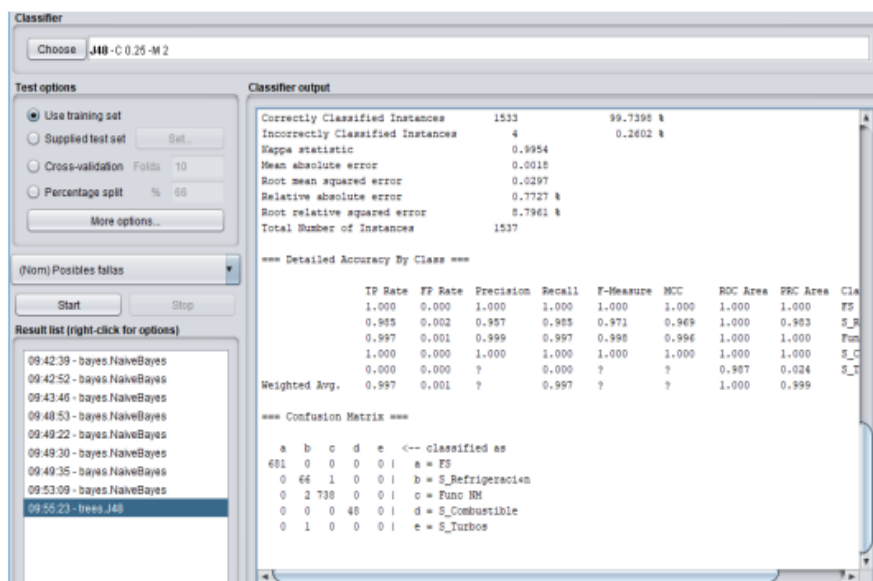
Figura 6. Clasificación mediante algoritmo Naive Bayes mejorado, en Weka



Fuente Propia

Se llevaron a cabo pruebas con otros algoritmos, como J48, SVM y redes neuronales. La figura 7 muestra que las instancias se clasifican correctamente en el 99.7% de los casos con un error absoluto del 0.0018%.

Figura 7. Clasificación mediante algoritmo J48, en Weka (Fuente Propia).



En la figura 8, se indica el árbol de clasificación del algoritmo J48, donde se analiza los datos de las variables principales con las respectivas alarmas del motor Wartsila.

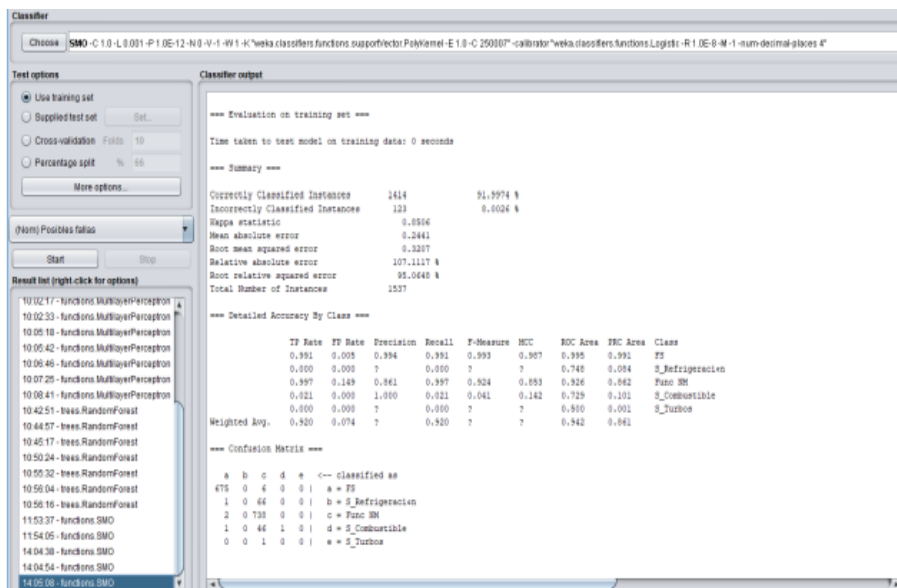
Figura 8. Árbol de clasificación con algoritmo J48, en Weka



Fuente Propia

El algoritmo de SVM mostrado en la figura 9, indica que el 91.99% de las instancias se clasificaron correctamente, el 8.02% las instancias fueron clasificados incorrectamente, dando un error absoluto es de 0.24.

Figura 9. Algoritmo de SVM, en Weka



Fuente Propia

La figura 10 muestra una visualización de la predicción de fallas en el motor, indicando que la mayoría de las clases están correctamente clasificadas. Los datos muestran que el

motor y el turbo cargador están trabajando en condiciones ideales, mientras que el sistema de combustible tiene problemas pequeños, pero aún puede seguir funcionando.

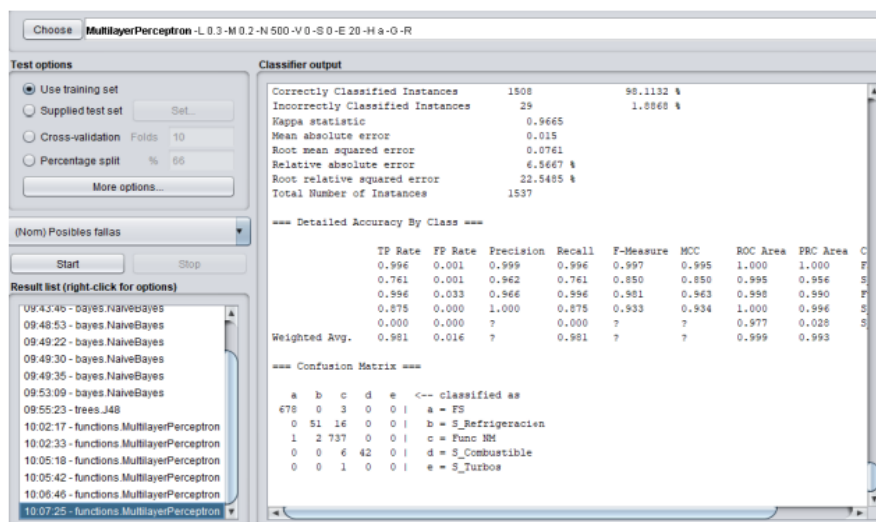
Figura 10. Predicción de fallas, en Weka



Fuente Propia

La aplicación del algoritmo como las Redes Neuronales mostradas en la figura 11, se evidencia que el 98.11% de las instancias clasifica correctamente, el error absoluto es del 0.015.


Figura 11. Algoritmo de Redes Neuronales, en Weka



Fuente Propia

La figura 12, se indica la estructura de un algoritmo de redes neuronales, donde se evidencia los datos de entrada, en este estudio se ejecuta con una capa oculta y la predicción de las fallas conocidas como las clases.

Figura 12. Aplicación de Redes Neuronales, en Weka

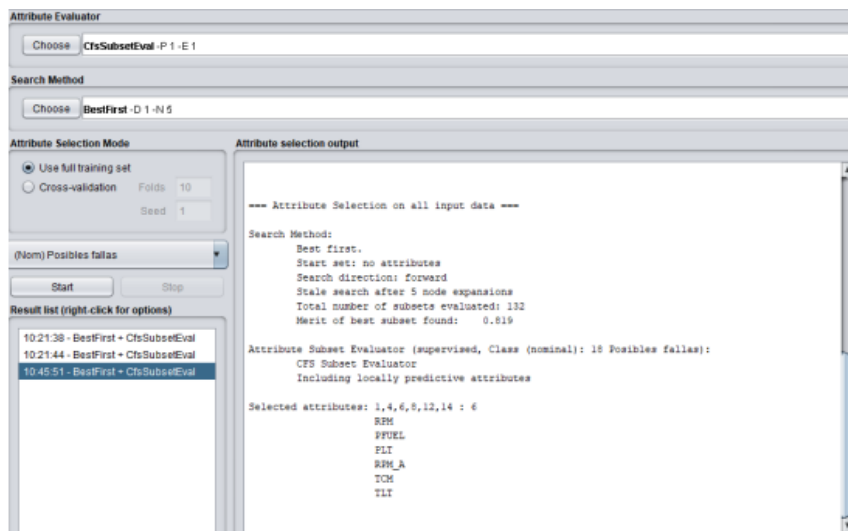


Fuente Propia

### Aplicación de técnicas de aprendizaje no supervisado

La figura 13 muestra el uso de un algoritmo de reducción de dimensiones, utilizando todos los datos de entrenamiento e incluyendo los atributos de predicción o clases, sumando 18 atributos. Al ejecutar el algoritmo se reduce a 6 atributos: las RPM del motor, la presión del combustible, la presión de LT, las RPM del turbo cargador banco A, la temperatura del combustible y la temperatura de LT.

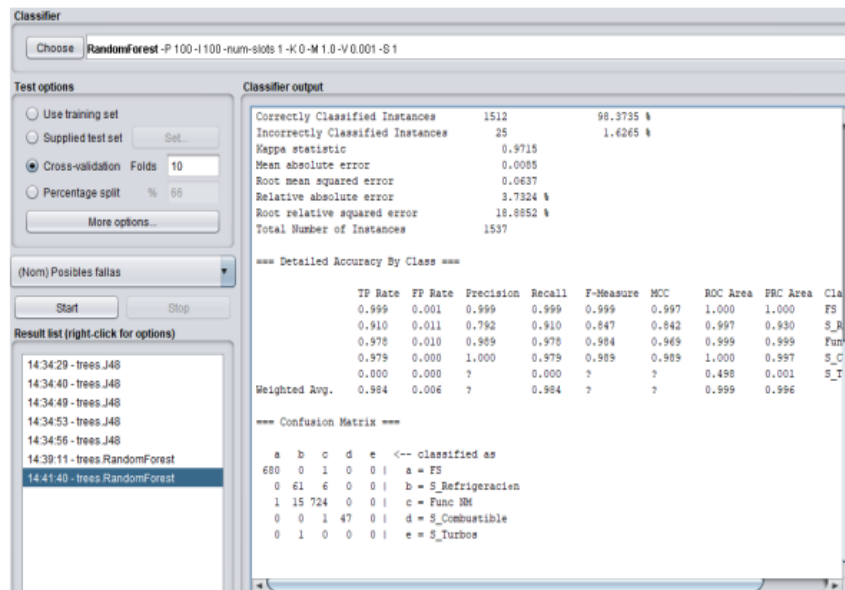
Figura 13. Reducción de dimensiones, en Weka



Fuente Propia

Posteriormente de realizar la reducción de dimensiones, se ejecuta un clasificador en Weka como “RandomForest”, con los datos de prueba en la validación cruzada y 10 “Folds”, como se indica en la figura 14. Los resultados son del 98.73% en instancias clasificadas correctamente y un error absoluto de 0.085.

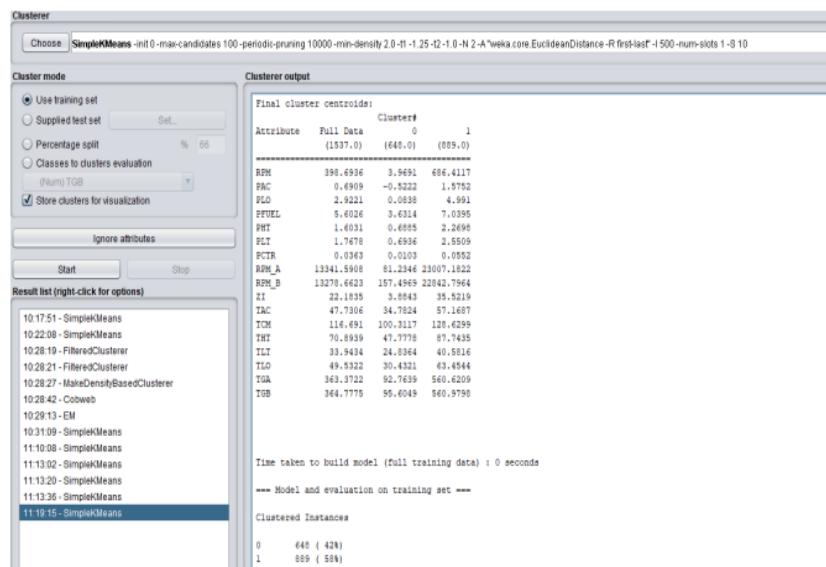
Figura 14. Aplicación del algoritmo "RandomForest" después de la aplicación de reducción de dimensiones, en Weka



Fuente Propia

La figura 15, indica la aplicación del algoritmo de K-means y la selección del fichero de clúster en Weka, para el modelo se usa los datos de entrenamiento, por lo tanto, se obtiene 2clústeres con el 42% y 58% de clasificación correspondientemente.

Figura 15. Resultados del algoritmo K-means, en Weka

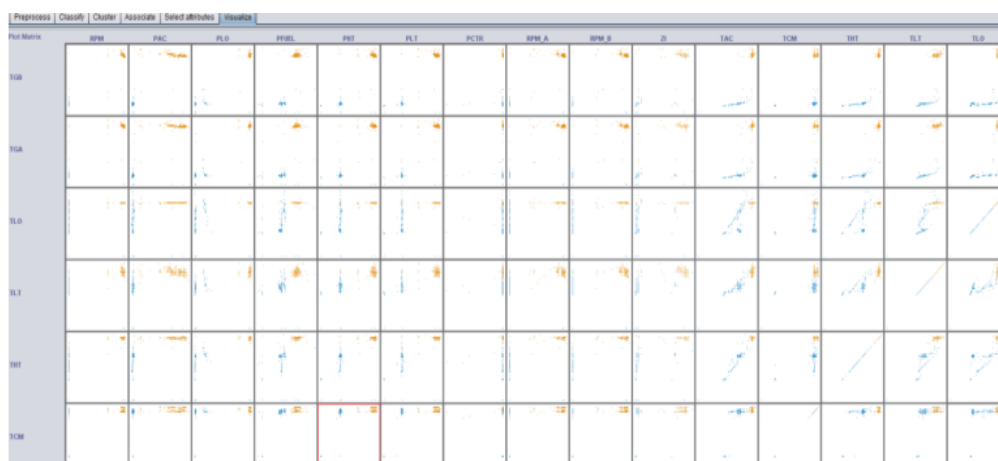


Fuente Propia

La figura 16, se muestra las relaciones de las variables principales del motor Wartsila, en la cual se puede distinguir ciertos patrones de similitud y en algunos casos las correlaciones. Es un método muy práctico y de inspección visual.



Figura 16. Visualización de las variables del motor Wartsila, en Weka



Fuente Propia

## CONCLUSIONES

La empresa OCP Ecuador S.A. ha implementado un sistema de monitoreo de variables para reducir paradas de motores de bombas, así como también ha preparado Estudios Ambientales y un Plan de Manejo. El grupo de mantenimiento del OCP Ecuador ha definido planes de mantenimiento a los activos, especialmente los motores Wartsila, para mantener su confiabilidad y disponibilidad. Se han implementado sensores para detectar fallos, y se ha empleado la inteligencia artificial para la predicción de fallas en los motores. El proceso de saneado de datos también es un factor importante, ya que permite eliminar valores erróneos y presentar una data confiable. La aplicación de la inteligencia artificial para la predicción de fallas en el motor Wartsila es muy útil, puesto que garantiza la transición de los mantenimientos preventivos y correctivos a mantenimientos basados en condición.

La inteligencia artificial (IA) es una de las tecnologías más prometedoras en la industria. La aplicación de la IA en el mantenimiento predictivo ayuda a las empresas a predecir las fallas de forma anticipada. Esto permite a las empresas prevenir los daños y el tiempo de inactividad no deseado, así como también ahorrar costos. El uso de IA en el mantenimiento predictivo también permite a las empresas aprovechar al máximo el tiempo de vida útil de los activos.

La IA también se puede utilizar para mejorar la productividad a través del análisis de los modelos de comportamiento de los activos y la detección de patrones en los datos. Esto permite a las empresas identificar áreas de mejora y adaptar los sistemas para lograr un mejor rendimiento. Además, la IA también ayuda a las empresas a mejorar la calidad de

los productos finales, ya que sus sistemas pueden identificar patrones anormales en los productos y alertar a los operadores para que se tomen las medidas adecuadas para corregirlos.

Además, se puede emplear RStudio para visualizar gráficas y presentar el resultado con la estadística descriptiva, cuando se maneja variables entre 6 a 12, el analista puede determinar una anomalía diseñada en una sola interfaz, pero si las variables son más de 12, la visualización se complica y no se puede mostrar para los 22 motores en la misma interfaz. Si se realiza 22 interfaces, el uso no sería explícito, por lo tanto, se debe realizar otro diseño de visualización del estado real, diagnóstico y predicción.

#### LISTA DE REFERENCIAS

- Cortés, C. F. (2017). *Técnicas para mejorar el transporte de crudos pesados por oleoductos*. <https://bibdigital.epn.edu.ec/bitstream/15000/18837/1/CD-8227.pdf>
- Lim, C. H., Lim, S., How, B. S., Ng, W. P. Q., Ngan, S. L., Leong, W. D., & Lam, H. L. (2021). A review of industry 4.0 revolution potential in a sustainable and renewable palm oil industry: HAZOP approach. *Renewable and Sustainable Energy Reviews*, 135, 110223. <https://doi.org/10.1016/j.rser.2020.110223>
- Lu, H., Guo, L., Azimi, M., & Huang, K. (2019). Oil and Gas 4.0 era: A systematic review and outlook. *Computers in Industry*, 111, 68–90. <https://doi.org/10.1016/j.compind.2019.06.007>
- Popkova, E., Ragulina, Y., & Bogoviz, A. (Eds.). (2019). *Industry 4.0: Industrial Revolution of the 21st Century* (Vol. 169). <https://link.springer.com/book/10.1007/978-3-319-94310-7>
- Villada, F., & Cadavid, D. R. (2007). Diagnostico de Fallas en Motores de Inducción Mediante la Aplicación de Redes Neuronales Artificiales. *Información tecnológica*, 18(2), 105–112. <https://doi.org/10.4067/S0718-07642007000200016>
- Ynzunza, C. B., Izar, J. M., & Chacón, J. G. B. (2017). *El Entorno de la Industria 4.0: Implicaciones y Perspectivas Futuras*. 54. <https://www.redalyc.org/journal/944/94454631006/94454631006.pdf>