



**UNIVERSIDAD POLITÉCNICA SALESIANA**  
**SEDE CUENCA**  
**CARRERA DE INGENIERÍA MECÁNICA AUTOMOTRIZ**

APLICACIÓN DE ALGORITMOS DE APRENDIZAJE SUPERVISADO PARA LA  
CLASIFICACIÓN DE FALLOS MECÁNICOS EN UN MOTOR DE ENCENDIDO  
PROVOCADO

Trabajo de titulación previo a la obtención del  
título de Ingeniero Mecánico Automotriz

AUTOR: EDWIN ESTEBAN ROCANO PIÑA

TUTOR: ING. RAFAEL WILMER CONTRERAS URGILÉS, MSc.

Cuenca - Ecuador

2023

**CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE  
TITULACIÓN**

Yo, Edwin Esteban Rocano Piña con documento de identificación N° 0105904247, manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Cuenca, 15 de febrero del 2023

Atentamente,



---

Edwin Esteban Rocano Piña

0105904247

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE  
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Yo, Edwin Esteban Rocano Piña con documento de identificación N° 0105904247, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del Artículo académico: “Aplicación de algoritmos de aprendizaje supervisado para la clasificación de fallos mecánicos en un motor de encendido provocado”, el cual ha sido desarrollado para optar por el título de: Ingeniero Mecánico Automotriz, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Cuenca, 15 de febrero del 2023

Atentamente,



---

Edwin Esteban Rocano Piña

0105904247

## CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Rafael Wilmer Contreras Urgilés con documento de identificación N° 0104463328, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: APLICACIÓN DE ALGORITMOS DE APRENDIZAJE SUPERVISADO PARA LA CLASIFICACIÓN DE FALLOS MECÁNICOS EN UN MOTOR DE ENCENDIDO PROVOCADO, realizado por Edwin Esteban Rocano Piña con documento de identificación N° 0105904247, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Cuenca, 15 de febrero del 2023

Atentamente,



---

Ing. Rafael Wilmer Contreras Urgilés, MSc.

0104463328

# APLICACIÓN DE ALGORITMOS DE APRENDIZAJE SUPERVISADO PARA LA CLASIFICACIÓN DE FALLOS MECÁNICOS EN UN MOTOR DE ENCENDIDO PROVOCADO

Esteban Rocano Piña<sup>1</sup>, Rafael Wilmer Contreras Urgiles <sup>2</sup>[0000-0003-2300-9457]

<sup>1</sup> Universidad Politécnica Salesiana, Cuenca

<sup>2</sup> Universidad Politécnica Salesiana, Cuenca

<sup>1</sup> erocanop@est.ups.edu.ec

<sup>2</sup> rcontreras@ups.edu.ec

**Abstracto.** En este trabajo se presenta la metodología aplicada para determinar los fallos mecánicos en un motor de combustión interna mediante la aplicación del Aprendizaje Automático (Machine Learning) en la clasificación de fallos mecánicos asociados a la anulación del trabajo de los cilindros, es decir, esta metodología se aplica sobre los datos obtenidos de la señal del sensor KS (Knock Sensor) y del sensor CMP (Camshaft Position Sensor) durante el funcionamiento del motor. Para evaluar los datos obtenidos, se realiza la adquisición de muestras aplicadas a diferentes condiciones de funcionamiento, tras lo cual se crea una matriz de atributos que permite una selección y reducción de variables con la aplicación de métodos basados en la arquitectura Random Forest. Posteriormente, se aplicó el algoritmo de Aprendizaje No Supervisado K-means con una clasificación de fallos por k- aglomerados obteniendo 11 clases. Consecutivamente se creó y entrenó una RNA (Red Neuronal Artificial), una SVM (Máquina de Soporte Vectorial) como algoritmos de Aprendizaje Supervisado, de las que se obtuvo un valor de error de clasificación de 0,1267% y 0,0067%, respectivamente.

**Palabras claves:** diagnóstico, fallos mecánicos, sensor KS, sensor CMP, redes neuronales artificiales, máquinas de soporte vectorial, kmeans.

## 1. Introducción

El motor de combustión interna durante su funcionamiento genera diferentes desgastes entre sus elementos, provocando averías. Como uno de los principales componentes del vehículo [1], es un elemento con un alto índice de fallos. Con la continua evolución de sus elementos y funciones, se incrementa la complejidad dificultando el diagnóstico de fallos. Por consecuencia, se utilizan metodologías para el diagnóstico y clasificación de fallos mediante la Inteligencia Artificial (IA) por el alto rendimiento en tiempo real, precisión y previsibilidad [2]. Enfocándose directamente en Machine Learning (Aprendizaje Automático) donde se aplican algoritmos de clasificación como Kmeans (Agrupamientos), ANN (Redes Neuronales Artificiales) y SVM (Máquinas de Soporte Vectorial), entre otros algoritmos aplicados a la clasificación de fallos mecánicos.

Con la iniciativa de establecer algoritmos para el diagnóstico y clasificación de fallos en elementos mecánicos, durante el 2004 se presentan estudios que comparan el rendimiento en la detección de fallos en engranajes [3] mediante RNA y SMV, con resultados de precisión entre el 97,4 y el 100 % respectivamente. En 2007 se presenta un estudio sobre la monitorización [4] y el diagnóstico de fallos en máquinas mediante SVM, obteniendo

un excelente rendimiento en la categorización. A partir de los estudios preliminares, la aplicación de algoritmos de aprendizaje supervisado generó mayor interés, por sus altos índices de precisión en la clasificación. Durante las dos décadas se compararon las metodologías (KNN, ANN) como un método de diagnóstico propuesto para diferenciar de forma fiable las diferentes condiciones de fallo del motor de combustión interna. [5] En 2017, Sánchez R., Vásquez R., entre otros [6] adquieren una precisión de clasificación del 98,7% con SVM para el diagnóstico de fallas múltiples en una máquina rotativa. Al siguiente año 2018 se considera dos metodologías de clasificación (aprendizaje supervisado SVM y el aprendizaje no supervisado k-means) para categorizar una base de datos [7]. De igual manera [8] utiliza el algoritmo K-means de aprendizaje sin supervisión, para encontrar agrupaciones de datos obtenidos con diferentes combinaciones de variables. Para el año 2019 en la detección de fallos en rodamientos [9] se aplica RNA y SVM con resultados de clasificación del 96% y 100% respectivamente. En el mismo año, Contreras W., obtuvo una identificación precisa de los diferentes tipos de condiciones mecánicas del MEP [10] mediante la aplicación de una Red Neuronal Feed-Forward Backpropagation, con un error de clasificación de  $1.89e^{-11}$ .

A partir de 2019 se utiliza la metodología de aprendizaje supervisado para el diagnóstico de fallos en motores de combustión por encendido provocado [11] utilizando Redes Neuronales [12], aplicándose de igual manera para estrategias de mantenimiento [13]. En 2020, estudios que van desde la búsqueda de los fallos generados en un componente [14] tanto para motores a gasolina como para motores a diésel [15] en 2022, aplican los algoritmos por su precisión de diagnóstico, exactitud y otros indicadores clave. En 2023 Contreras R.W., aplica la comparativa entre los algoritmos ANN y SVM para clasificación de fallos [16], con un error de clasificación de 0,1267% y 0,0067%, respectivamente.

Continuando con las investigaciones anteriormente indicadas, este trabajo presenta una metodología que permite detectar fallos en motores de encendido provocado, mediante el uso de algoritmos de Aprendizaje Automático (Machine Learning) como una técnica mínimamente intrusiva en la categorización de fallos. Una vez desarrollado y validado el algoritmo no supervisado K-means, se ha empleado en una segunda fase los algoritmos supervisados tipo ANN y SVM. Con la aplicación de los diferentes algoritmos y desarrollada la metodología, se establece una base para el desarrollo de nuevos sistemas inteligentes de diagnóstico de fallos en motores de encendido provocado. La comparación de diferentes interacciones de fallos, aunque fuera del alcance de este estudio, constituye un reto futuro para el planteamiento mejorado de los sistemas inteligentes de diagnóstico.

## **2. Materiales y Métodos**

En esta sección se explican los instrumentos y la metodología utilizada para la aplicación de fallos mecánicos en el elemento experimental, las condiciones para la toma de muestras en los sensores KS y CMP, y la metodología para la obtención de la matriz de atributos para su posterior análisis, selección, reducción y su aplicación en los algoritmos (Kmeans, ANN y SVM). Los sensores KS y CMP se aplican en el proceso experimental ya que el primero capta la vibración producida por el motor en las diferentes condiciones de

funcionamiento y el segundo identifica las fases del motor para obtener el orden de fallo. Los otros sensores no se abordan porque no corresponden al final de esta investigación.

## 2.1. Unidad Experimental

El motor utilizado para simular las fallas es un motor Hyundai SONATA 2.0, en el que se instalan los instrumentos de adquisición de datos. La Tabla 1 describe las características del motor utilizado para la experimentación.

**Tabla 1.** Características técnicas del motor.


Descripción	Características
Número de cilindros	4
Desplazamiento [cm <sup>3</sup> ]	2000
Distribución	DOHC
Compresión	10.5:1
Potencia [HP/rpm]	175/6000
Torque [nm/rpm]	168/4000
Combustible	Gasolina
Transmisión	Automática

## 2.2. Muestreo

Para obtener las muestras de las señales eléctricas de los sensores, se utiliza una tarjeta DAQ. Las muestras se obtienen a una frecuencia de muestreo de 200 kHz establecida según el criterio de Nyquist, para el sensor KS y el sensor CMP, con un tiempo de 3 segundos. Las muestras se adquieren con el motor a temperatura normal de funcionamiento, encendiendo el ventilador al menos dos veces, evitando muestras erróneas.

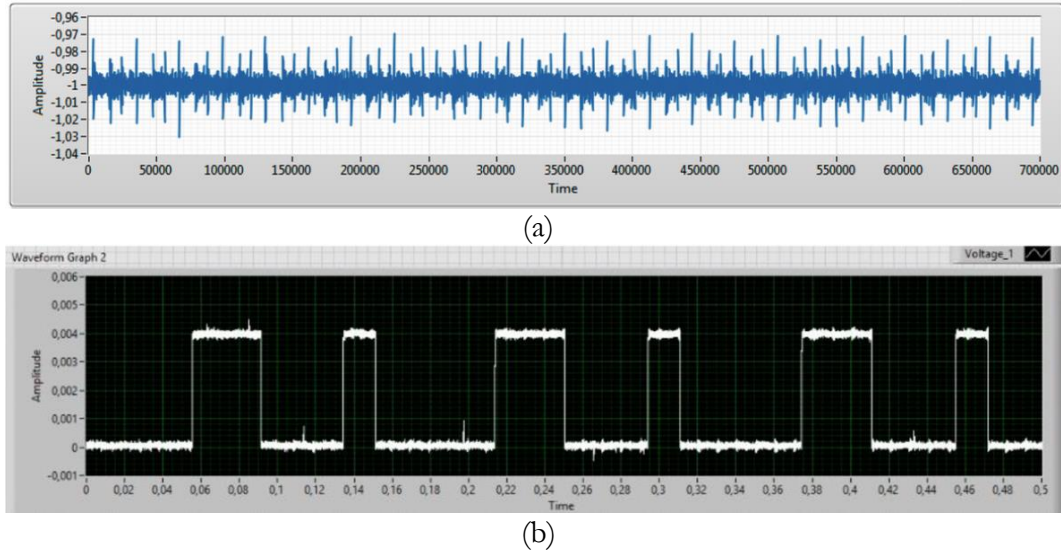
## 2.3. Condiciones para la adquisición de datos

Como el objetivo del método aplicado es reducir el tiempo de diagnóstico y una intervención mínimamente invasiva en el motor, se procede a tomar las señales proporcionadas por el sensor KS y el sensor CMP instalado en un motor Hyundai Sonata 2.0 DOHC. El proceso de obtención de datos se describe a continuación en la Figura 1.



**Figura 1.** Proceso para adquisición de muestras.

El proceso inicia con la unidad experimental, que debe tener un funcionamiento óptimo [17], así como la señal de los sensores (véase la Figura 2). Con la respectiva verificación, la señal de los sensores se adquiere, se registra y se guarda en una matriz general para la comprobación de fallos. Para determinar el segundo estado de la unidad de experimentación, se provocan fallos controlados, como se describe en la Tabla 2.



**Figura 2.** Señal de muestreo: (a) sensor KS, (b) sensor CMP.

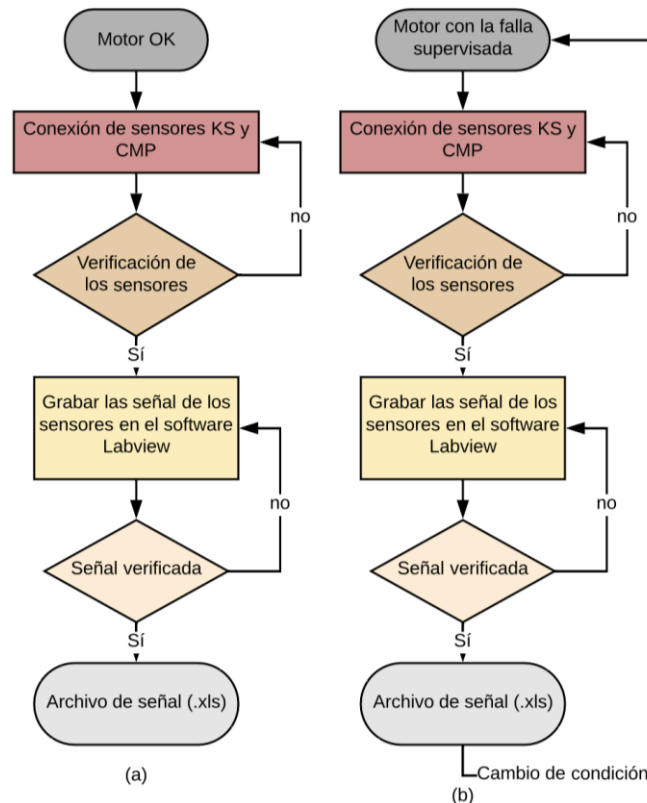
**Tabla 2.** Condiciones para la unidad experimental.

Nº	Fallo mecánico	Código
0	Motor en correcto funcionamiento [OK]	0
1	Fallo del inyector 1 [finy1]	100
2	Fallo del inyector 2 [finy2]	200
3	Fallo del inyector 3 [finy3]	300
4	Fallo del inyector 4 [finy4]	400
5	Fallo de bujía 1 [bujcer1]	500
6	Fallo de bujía 2 [bujcer2]	600
7	Fallo de bujía 3 [bujcer3]	700
8	Fallo de bujía 4 [bujcer4]	800
9	Fallo de la bobina 1-4 [bob1-4]	900
10	Fallo de la bobina 2-3 [bob2-3]	1000



## 2.4. Metodología para la adquisición de datos

Para obtener los datos se sigue el proceso de la Figura 3. La prueba experimental comienza con el motor en correcto funcionamiento y posteriormente con los fallos supervisados. Con la conexión correcta de los sensores, se registra la señal eléctrica con el software LabVIEW y se almacena en una hoja de cálculo [10]. Para el registro de las señales se aplica el procedimiento descrito anteriormente tanto para el caso del motor en buen funcionamiento Figura 3(a) como para el motor con fallo supervisado Figura 3(b). Para obtener una base de datos suficientemente grande, el proceso de adquisición de datos se realiza 30 veces para cada una de las condiciones del motor.



**Figura 3.** Diagrama de flujo del proceso de adquisición de datos (a) Motor OK, (b) Motor con fallo supervisado.

## 2.5. Obtención de la matriz de atributos

Los atributos obtenidos corresponden a 72 en total, y son los resultados de la estadística descriptiva de la señal tal y como se observa en [17]. Parte de los atributos son: energía, potencia, asimetría, factor de curtosis, máximo, mínimo, mediana, media, modo, mediana recortada, raíz cuadrada media, factor de cresta, desviación estándar, varianza, rango, coeficiente de varianza, energía de Fourier (energía de la transformada de Fourier de la señal), potencia de Fourier (potencia de la transformada de Fourier de la señal), índice max (posición máxima de la transformada de Fourier; para el sensor KS y CMP).

## 2.6. Reducción de atributos con Random Forest

Para la selección y reducción de atributos, la matriz general se analiza mediante 3 métodos: Curvature Test (Figura 4), Standard CART (Figura 5) y Interaction-curvature (Figura 6), que se basan en la arquitectura Random Forest.

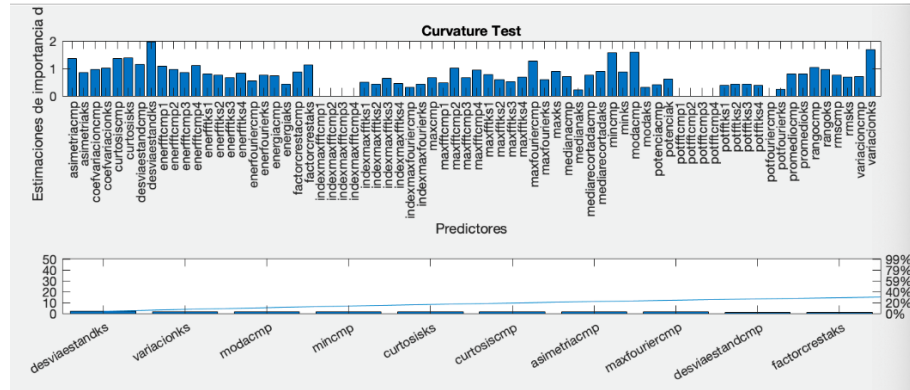


Figura 4. Predictores con metodología Curvature Test.

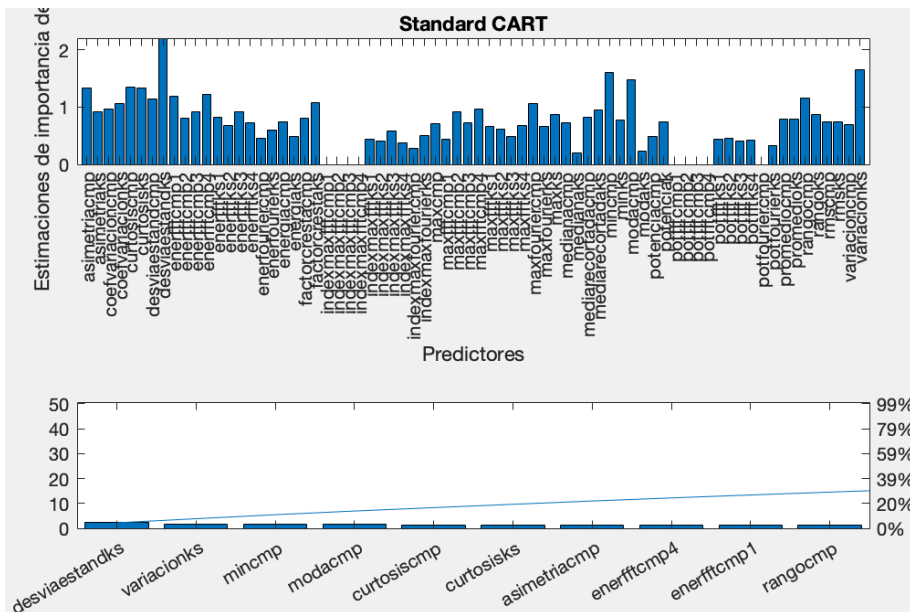


Figura 5. Predictores con metodología Standard CART.




Figura 6. Predictores con metodología Interaction-curvature.

## 2.7. Selección de atributos para el entrenamiento de los algoritmos

Los atributos se seleccionan en función de la mayor importancia de los predictores, que se observa en las Figuras 4, 5 y 6. La herramienta de Pareto se aplica a los atributos para ordenar y se obtienen aquellos con mayor efectividad de predicción. Los atributos utilizados para la entrada de los algoritmos se describen en la Tabla 3, para el caso de esta prueba experimental existen 11 atributos, cabe destacar que estos atributos representan aproximadamente el 31% y que en base al principio de Pareto este porcentaje es conveniente para analizar fallos mecánicos.

Tabla 3. Matriz de atributos.

Atributo	Nº Importancia	Valor	Frecuencia acumulada	Valor de Pareto
desviaestandsks	1	2.10	4.20	-----
variacionks	2	1.83	3.65	7.85
modacmp	3	1.59	3.17	11.02
mincmp	4	1.48	2.95	13.98
curtosisks	5	1.46	2.92	16.60
asimetricamp	6	1.43	2.85	19.75
curtosiscmp	7	1.26	2.51	22.26
enerfftcmp4	8	1.24	2.49	24.75
rangocmp	9	1.17	2.33	27.08
enerfftcmp1	10	1.10	2.19	29.28
desviaestandcmp	11	1.09	2.17	31.45

## 2.8. Algoritmo de Aprendizaje No Supervisado para Clasificación de fallos

### 2.8.1 Algoritmo K-means

Una vez realizada la selección de atributos, se procede a la aplicación de un método no supervisado de clasificación [18] para evaluar el conjunto de datos de los 11 atributos, sin la etiqueta de respuesta resultantes de la Tabla 3. En la Figura 7 (a) se representa la matriz de datos con valores asignados de manera aleatoria para el respectivo número de k-agrupaciones a clasificar, definiéndose 11 grupos por cada condición de funcionamiento de la Tabla 2.




Figura 7. (a) Matriz de agrupamiento, (b) Matriz de coincidencias.

La Figura 7(b) representa los 11 k-grupos con respecto a las posibles condiciones de fallo. Como se observa existen puntos de coincidencia, sin embargo, otros de discrepancia.

En base a la matriz Figura 7(b), cuando se consideran los atributos de mayor discrepancia en puntos, (atributos 6 y 9), se ilustra una clasificación confusa de interpretar Figura 8 (a). Limitando la inspección de los colores designados para el fallo correspondiente. El mismo caso Figura 8 (b) se obtiene de atributos 7 y 9.





Figura 8. Clasificación de fallos mediante K-means: (a) Grupo 6-9, (b) Grupo 7-9.

Un caso opuesto se adquiere de los atributos con un mayor número de puntos coincidentes, siendo el caso Figura 9(a) de los atributos 2 y 4 donde se distingue una clasificación con agrupaciones definidas. Algo similar ocurre Figura 9(b) con los atributos 1 y 3.



**Figura 9.** Clasificación de fallos mediante K-means: (a) Grupo 2-4, (b) Grupo 1-3.

Como lo visto en la Figura 9, el método K-means permite clasificaciones en k-grupos, pero no la identificación de la clase [19]. Como consecuencia se recurre a una siguiente fase, empleando los algoritmos de aprendizaje supervisado.

## 2.9. Algoritmos de Aprendizaje Supervisado para Clasificación de fallos

### 2.9.1. Algoritmo de la Red Neuronal Artificial (ANN)

Para la creación y entrenamiento de la red neuronal se desarrolla un script que permite combinar y evaluar diferentes tipos de: ANN, capas, número de neuronas, funciones de transferencia entre capas y funciones de entrenamiento. Las siguientes características como: Red de tipo red de retro propagación de Elman, con tres capas ocultas de 20, 40 y 60 neuronas entre cada capa, las funciones de transferencia entre cada capa fueron del tipo tansig y purelin para la capa de salida, el valor de % para el: entrenamiento, validación y prueba fueron 70, 15 y 15 respectivamente, el número de épocas para el entrenamiento fue de  $2e4$ ; las características fueron seleccionadas para obtener el menor error de clasificación de los fallos. En la Figura 10 se indica el proceso de entrenamiento y sus características.

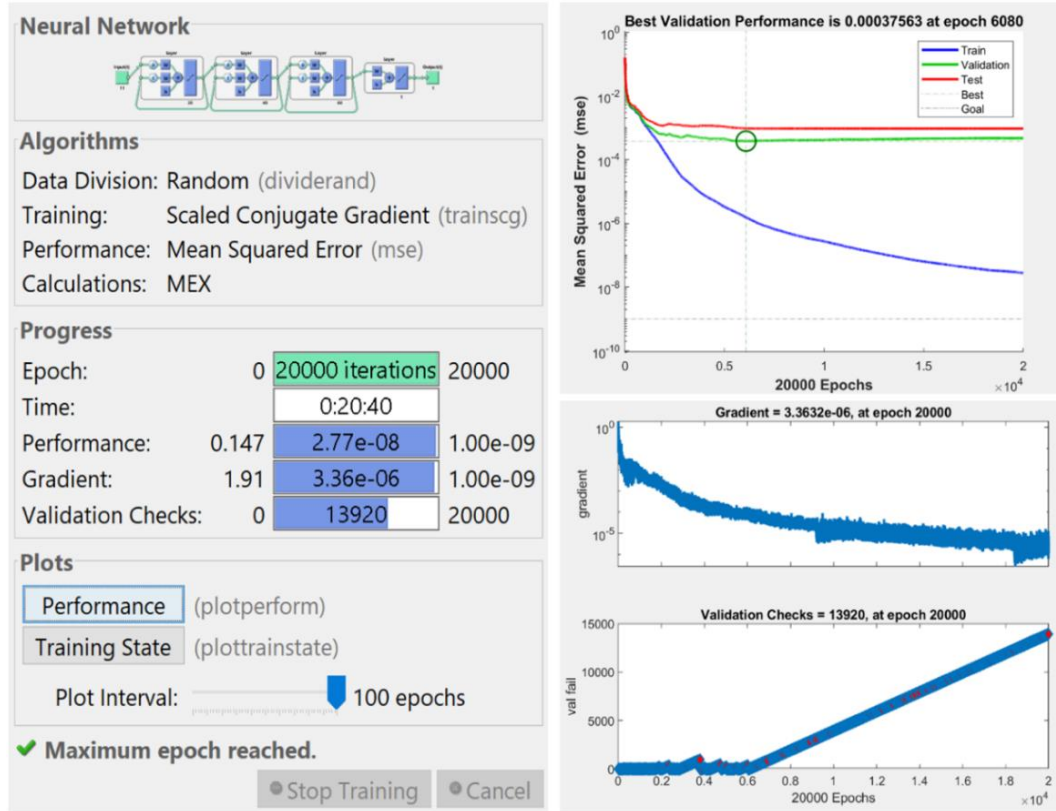


Figura 10. Características de la creación de la ANN.

### 2.9.2. Algoritmo de la Máquina de Soporte Vectorial (SVM)

Para la creación del SVM, se aplican los mismos atributos que para el ANN, visto en la sección anterior. Las siguientes características identifican los parámetros y el tipo de SVM: KFold = 5, Kernel = 0.55, Function = Polynomial, Order = 3, BoxConstrain = 3. Estas características se seleccionaron después de diferentes combinaciones, manteniendo el objetivo de reducir el error de clasificación. de las fallas. En la Figura 11 se indica el proceso de entrenamiento y las características de la matriz de confusión y la curva ROC.





Figura 11. Características de SVM: (a) matriz de confusión y (b) la curva ROC.


### 3. Resultados y Discusión

Mediante la aplicación del algoritmo K-means, se han representado distintas clasificaciones de fallo. En la Figura 12(a) se observan los datos masivos a ser clasificados. En la figura 12(b), se identifican 11 k-agrupaciones aplicadas a la selección y reducción de atributos. Con el fin de clasificar las agrupaciones se han previsto diferentes centroides, en base a la intersección de las medianas de la triangulación de los puntos más cercanos.



**Figura 12.** (a) Datos masivos a clasificar, (b) Clasificación kmeans en k-grupos.


En la Figura 13(a), se nota la interacción de los centroides sobre un conjunto de datos (Atributos 1 y 6). Los centroides agrupan datos cercanos para la clasificación, conformando una partición óptima de los k-aglomerados Figura 13(b).



**Figura 13.** (a) Centroides aleatorios, (b) Clasificación k-aglomerados.

Aplicando los algoritmos de aprendizaje supervisado como métodos de clasificación para la detección de fallas mecánicas, se obtienen varios porcentajes en la precisión de la clasificación. La Figura 14 presenta una comparación de los resultados de las

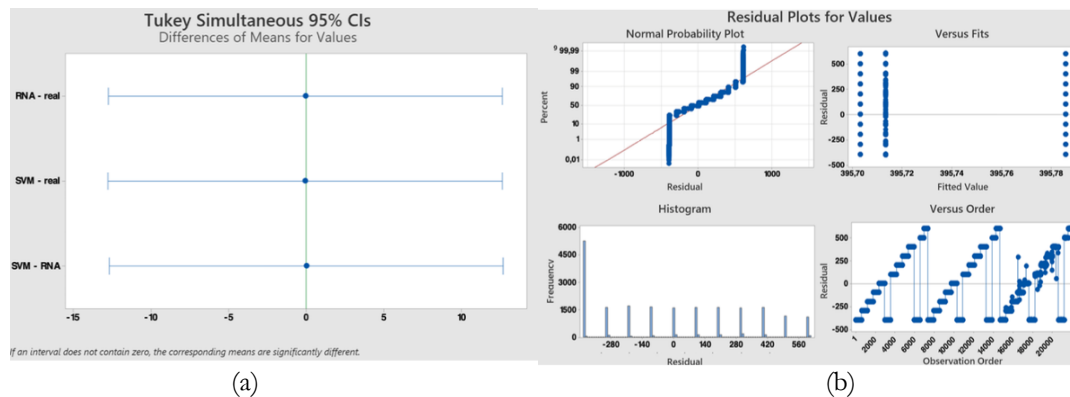
metodologías. Para el caso del ANN, el error global es del 0,1267% y para el SVM es del 0,0068%, lo que muestra una baja dispersión de puntos para ANN y casi nula para el SVM.



**Figura 14.** Clasificación de fallos, (a) con ANN y (b) SVM.

De acuerdo con la Figura 11 (a), se puede observar que las SVM son más adecuadas para la clasificación de fallos mecánicos utilizando los atributos de la señal del sensor KS, ya que el valor máximo de falsos positivos es 16 en la clase 700 (Fallo de bujía 3), como se evidencia en la matriz de confusión de la Figura 11 (b), de la que se deduce que este método de clasificación obtiene una eficiencia superior al 95%.

Obtenidos los resultados de las diferentes condiciones de funcionamiento del motor de encendido provocado, se puede destacar que la diferencia entre las respuestas tanto de la condición real como de la RNA y la SVM, tienen una similitud muy marcada, lo que se evidencia a través de la comparación de Tukey y el estudio ANOVA realizado sobre los resultados de los dos métodos de clasificación utilizados en este trabajo y que se observa en la Figura 15.



**Figura 15.** Comparación de resultados: (a) Método de Tukey del (b) Estudio ANOVA.



## 4. Conclusiones

Este artículo afirma la aplicación de dos métodos de Aprendizaje Automático (Machine Learning): Algoritmo de Aprendizaje No Supervisado Kmeans y Algoritmos de Aprendizaje Supervisado ANN y SVM, para la clasificación de fallos mecánicos en motores de encendido por chispa, con la ventaja de aplicar una técnica mínimamente invasiva.

La selección de los atributos de entrada para las dos metodologías de predicción se determinó en función de la mayor importancia de los predictores, mediante un estudio de Random Forest, obteniéndose resultados satisfactorios con un error de clasificación inferior al 1%.

El aprendizaje no supervisado K-means aplicado a este estudio, presenta una clasificación de 11 k-aglomerados. Mediante la exploración del conjunto de datos, se obtuvo que la combinación de los conglomerados (6 y 9) presentan las particiones más significativas, corroborado por la discrepancia de puntos de la Figura 7(b).

Según los resultados obtenidos del entrenamiento y validación de los sistemas de predicción, se establece que las Máquinas de Soporte Vectorial (SVM) tienen una mejor respuesta hacia la detección de fallos mecánicos con la señal del sensor KS, destacando frente a las Redes Neuronales Artificiales (ANN). Con el modelo SVM se obtuvo una tasa de error del 0,0068%, lo que demuestra que las máquinas de vectores soporte podrían ser aplicadas para el desarrollo de técnicas de diagnóstico automotriz que permitan obtener un diagnóstico eficiente en poco tiempo.

## 5. Referencias

- [1] F. P. González y J. M. Desantes Fernández, *Motores de combustión interna alternativos...*, Barcelona: Editorial Reverté, S.A, 2011.
- [2] V. Venkatasubramanian, R. Raghunathan, K. Yin y S. N. Kavuri, «A review of process fault detection and diagnosis: Part I: Quantitative model-based methods,» *Computers & Chemical Engineering*, vol. Volume 27, n° Issue 3, pp. Pages 293-311, 2003.
- [3] B. Samanta, «Gear fault detection using artificial neural networks and support vector machines with genetic algorithms,» *Mechanical Systems and Signal Processing*, vol. volumen 18, n° 3, pp. 625-644, 2004.
- [4] A. Widodo y S. Yang, «Support vector machine in machine condition monitoring and fault diagnosis,» *Mechanical Systems and Signal Processing*, vol. Volumen 21, n° 6, pp. 2560-2574, 2006.
- [5] A. Moosavian, H. Ahmadi y A. Tabatabaeefar, «Comparison of Two Classifiers; K-Nearest Neighbor and Artificial Neural Network, for Fault Diagnosis on a Main Engine Journal-Bearing,» *Shock and Vibration*, vol. 20, p. 263–272, 2013.

- [6] R. V. Sánchez, P. Lucero, J.-C. Macancela, M. Cerrada, R. E. Vásquez y F. Pacheco, «Diagnóstico de múltiples fallas de maquinaria rotativa mediante el uso de métodos de clasificación de características y clasificadores basados en SVM,» de *International Conference on Sensing, Diagnostics, Prognostics, and Control*, 2017.
- [7] R. C. N. Diego., P. A. Molina Campoverde., G. P. Quirola Novillo y A. K. Naula Bermeo, «Development of an Algorithm Capable of Classifying the Starting, Gear Change and Engine Brake Variables of a Vehicle by Analyzing OBD II Signals,» *Systems and Information Sciences. ICCIS 2020*, vol. 1273 AISC, pp. 121-133, 2020.
- [8] R. C. N.D., J. L. Muñoz Sanz y B. Arenas-Ramirez, «Estimation of Pollutant Emissions in Real Driving Conditions Based on Data from OBD and Machine Learning,» *Sensors*, vol. 19, 2021.
- [9] A. Pavan y P. Jayaswal, «Diagnosis and Classifications of Bearing Faults Using Artificial Neural Network and Support Vector Machine,» *Journal of The Institution of Engineers (India)*, vol. 101, n° Issue 1, pp. p.61-72, 2019.
- [10] R. W. Contreras Urgiles, J. Maldonado Ortega y R. León Japa, «Aplicación de una red neuronal feed-forward backpropagation para el diagnóstico de fallas mecánicas en motores de encendido provocado,» *Ingenius.* , n° 21, pp. págs. 32-40, 2019.
- [11] M. A. Hashim, M. H. Nasef, A. E. Kabeel y N. M. Ghazaly, «Combustion fault detection technique of spark ignition engine based on wavelet packet transform and artificial neural network,» *Alexandria Engineering Journal*, 2020.
- [12] E. M. da Silva, D. R. De Sousa, R. P. Marinho, R. B. Formiga y E. P. Matamoros, «Fault Diagnosis in Combustion Engines Using Artificial Neural Networks,» *SAE International, Warrendale, PA, SAE Technical Paper 2020-36-0076* , 2021.
- [13] I. Tessaro, V. Cocco Mariani y L. dos Santos Coelho, «Machine Learning Models Applied to Predictive Maintenance in Automotive Engine Components,» *The 1st International Electronic Conference on Actuator Technology: Materials, Devices and Applications*, n° no. 1: 26. .
- [14] Y. Ling y C. Niu, «Fault Diagnosis of Automobile Engine Based on Improved BP Neutral Network,» *Application of Neural Network in Mobile Edge Computing*, vol. 22, p. 11 pages, 2022.
- [15] S. M. Ramteke, H. Chelladurai y M. Amarnath, «Diagnosis and Classification of Diesel Engine Components Faults Using Time–Frequency and Machine Learning Approach,» *J. Vib. Eng. Technol.*, vol. 10, p. 175–192 , 2022.
- [16] R. W. Contreras Urgiles, J. M. Ortega, E. E. Rocano Piña y J. Chiluisa, «Classification of Mechanical Failures in Provoked Ignition Engine by Means of ANN and SVM,» *Intelligent Technologies: Design and Applications for Society. CITIS 2022. Lecture Notes in Networks and Systems Springer, Cham.*, vol. 607, p. pp 161–172, 2023.
- [17] E. H. Delgado Calle, «Desarrollo de un algoritmo de diagnóstico para la detección de fallas mecánicas en motores de encendido provocado basados en la transformada Wavelet,» 2018.
- [18] M. K. A. d. k-medias, «MathWorks,» [En línea]. Available: [https://la.mathworks.com/help/stats/kmeans.html?searchHighlight=kmeans&cs\\_tid=srchtitle\\_kmeans\\_1](https://la.mathworks.com/help/stats/kmeans.html?searchHighlight=kmeans&cs_tid=srchtitle_kmeans_1).
- [19] A. K. Jain, «Data Clustering: 50 Years Beyond K-means,» *Daelemans, W., Goethals, B., Morik, K. (eds) Machine Learning and Knowledge Discovery in Databases. ECML PKDD 2008. Lecture Notes in Computer Science()*, vol. 5211, 2008.

