



UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS
CARRERA DE INGENIERÍA AUTOMOTRIZ

TRABAJO DE INTEGRACIÓN CURRICULAR

TEMA:

Implementación de un sistema de diagnóstico predictivo para motores de combustión interna basado en análisis de vibraciones y señales de encoders rotatorios

Trabajo de titulación previo a la obtención del título en Ingeniería Automotriz

Línea de investigación: Producción industrial y tecnología sostenible

AUTOR:

Castro Hernández Gandy Matteo

Garrido Guerrero Martín Israel

DIRECTOR:

Mafla Yépez Carlos Nolasco

Ibarra – Ecuador 2026



UNIVERSIDAD TÉCNICA DEL NORTE

DIRECCIÓN DE BIBLIOTECA

AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO	
APELLIDOS Y NOMBRES:	Castro Hernández Gandy Matteo
APELLIDOS Y NOMBRES:	Garrido Guerrero Martín Israel

DATOS DE LA OBRA	
TÍTULO:	Implementación de un sistema de diagnóstico predictivo para motores de combustión interna basado en análisis de vibraciones y señales de encoders rotatorios
AUTOR (ES):	Castro Hernández Gandy Matteo Garrido Guerrero Martín Israel
FECHA: DD/MM/AAAA	
SOLO PARA TRABAJOS DE GRADO	
PROGRAMA:	<input checked="" type="checkbox"/> PREGRADO <input type="checkbox"/> POSGRADO
TITULO POR EL QUE OPTA:	Ingeniería Automotriz
DIRECTOR /ASESOR:	Ing. Carlos Mafla PhD / Ing. Jorge Melo Msc.



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



2. CONSTANCIAS

Los autores manifiestan que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que son los titulares de los derechos patrimoniales, por lo que asumen la responsabilidad sobre el contenido de la misma y saldrán en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 22 días del mes de mayo de 2026

LOS AUTORES:

(Firma).....

(Firma).....

Nombre: Castro Hernández Gandy Matteo

Nombre: Garrido Guerrero Martín Israel



**CERTIFICACIÓN DEL DIRECTOR DEL TRABAJO DE
INTEGRACIÓN CURRICULAR**

Ibarra, 22 de mayo de 2026

PhD. Mafla Yépez Carlos Nolasco

DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR

CERTIFICA:

Haber revisado el presente informe final del trabajo de Integración Curricular, el mismo que se ajusta a las normas vigentes de la Universidad Técnica del Norte; en consecuencia, autorizo su presentación para los fines legales pertinentes.

(f)

PhD. Mafla Yépez Carlos Nolasco

C.C.: 0401447826



APROBACIÓN DEL COMITÉ CALIFICADOR

El Comité Calificador del trabajo de Integración Curricular “Implementación de un sistema de diagnóstico predictivo para motores de combustión interna basado en análisis de vibraciones y señales de encoders rotatorios.” elaborado por Castro Hernández Gandy Matteo y Garrido Guerrero Martín Israel, previo a la obtención del título del Ingeniero Automotriz, aprueba el presente informe de investigación en nombre de la Universidad Técnica del Norte:

(f):.....

PhD. Mafla Yépez Carlos Nolasco

C.C.: 0401447826

(f):.....

MsC. Melo Obando Jorge Luís

C.C.: 1718346529



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



DEDICATORIA

Dedico el esfuerzo y el tiempo invertido en este trabajo, en primer lugar, a mis padres, Tomás Castro y Amalia Hernández, pilares fundamentales que con su amor, sacrificio y ejemplo han forjado no solo mi vida personal, sino también mi trayectoria profesional. También se lo dedico a mi hermano, quien ha sido mi principal fuente de inspiración para seguir adelante incluso en los momentos más difíciles. Su fortaleza y su fe en mí me han recordado siempre que no hay obstáculo demasiado grande cuando se tiene un motivo para luchar.

Y, finalmente, dedico este trabajo a mi compañero Martín Garrido y a mí. Porque nuestro esfuerzo mutuo, nuestra complicidad y nuestra capacidad de remar juntos en la misma dirección fue lo que puso en marcha este proyecto y lo que permitió su culminación. Sin su empuje y sin mi propia determinación, este logro no habría sido posible.

Att. Gandy Castro

A mis padres, quienes han sido el pilar más importante en mi vida. A mi padre Edison Garrido, por su ejemplo constante de esfuerzo y perseverancia, por enseñarme a luchar por mis metas sin rendirme ante las dificultades. A mi madre Mary Guerrero, por su apoyo incondicional, sus consejos y por ser mi fortaleza en los momentos más complejos.

A mi hermana, por ser mi confidente y brindarme siempre palabras de aliento; a mi primo, por su apoyo y compañía como un hermano en este camino; y a mi novia, por su amor, paciencia y por no soltar mi mano en los momentos más difíciles, siendo un apoyo fundamental en este logro.

Finalmente, a mi compañero Gandy Castro, por haber compartido conmigo todo el desarrollo de este trabajo de titulación, por su compromiso, esfuerzo conjunto y compañerismo constante; por hacer de este proceso una experiencia de aprendizaje compartido que siempre llevaré conmigo.

Att. Martín Garrido



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



AGRADECIMIENTO

Expresamos nuestro sincero agradecimiento al Ingeniero Carlos Mafla, PhD, por su guía constante, su paciencia y su compromiso durante el desarrollo de este trabajo de titulación. Su experiencia y orientación fueron fundamentales para dar forma a esta investigación y culminarla con éxito.

Agradecemos a la Universidad Técnica del Norte por brindarnos la oportunidad de formarnos académicamente, así como a la Carrera de Ingeniería Automotriz, cuyos docentes aportaron con sus conocimientos, exigencia y vocación a nuestro crecimiento profesional.

Un especial reconocimiento a nuestro compañero Vismar Ramírez, por compartir este camino con nosotros, por el trabajo en equipo, el esfuerzo conjunto y por haber afrontado cada reto de la mano, convirtiendo este proceso en una experiencia de aprendizaje y crecimiento mutuo.

Finalmente, agradecemos a todas las personas que, directa o indirectamente, formaron parte de este proceso, aportando con su ayuda y motivación para alcanzar esta meta.

Gracias a todos por ser parte fundamental de este logro.



RESUMEN EJECUTIVO

El presente trabajo analiza el comportamiento dinámico de un motor de combustión interna mediante el estudio de señales de vibración y variables operativas, con el objetivo de identificar condiciones de funcionamiento normal y fallas inducidas. Se evaluó la desconexión eléctrica de un inyector de combustible como estrategia controlada para simular una falla real en el sistema. Para ello, se implementó un mecanismo basado en un interruptor (on/off) y un relé, permitiendo interrumpir selectivamente la señal eléctrica del inyector sin alterar la arquitectura original del sistema de control del motor. Se definieron dos estados operativos: BE (Buen Estado), correspondiente al funcionamiento normal, y ME (Mal Estado), asociado a la falla inducida, facilitando así un análisis comparativo. La adquisición de datos se realizó mediante acelerómetros y encoders, registrando simultáneamente señales de vibración y posición angular. Se recolectaron más de veinte millones de datos experimentales, los cuales fueron procesados en los dominios del tiempo y la frecuencia para identificar patrones asociados a eventos mecánicos relevantes como la combustión y el giro del cigüeñal. Se calcularon parámetros estadísticos como la media y la desviación estándar de variables angulares y armónicos, evidenciando que en condición ME existe una disminución del régimen de giro, mayor amplitud de vibraciones y mayor dispersión de las señales. Finalmente, se implementaron modelos de clasificación en MATLAB, destacando el algoritmo SVM, que alcanzó una precisión de más del 80%, mostrando el mejor desempeño y tiempo de procesamiento. Estos resultados confirman la efectividad del análisis de vibraciones como herramienta para la detección temprana de fallas en motores de combustión interna.

Palabras clave: Motores Diesel, Análisis de Vibraciones, Procesamiento de Señales, Transformada Rápida de Fourier, Aprendizaje Autónomo.



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



ABSTRACT

This paper analyzes the dynamic behavior of an internal combustion engine by studying vibration signals and operating variables, with the aim of identifying normal operating conditions and induced faults. The electrical disconnection of a fuel injector was evaluated as a controlled strategy to simulate a real system fault. To this end, a mechanism based on an on/off switch and a relay was implemented, allowing selective interruption of the injector's electrical signal without altering the original architecture of the engine control system. Two operating states were defined: BE (Good State), corresponding to normal operation, and ME (Bad State), associated with the induced fault, thus facilitating a comparative analysis. Data acquisition was performed using accelerometers and encoders, simultaneously recording vibration and angular position signals. More than twenty million experimental data points were collected and processed in the time and frequency domains to identify patterns associated with relevant mechanical events such as combustion and crankshaft rotation. Statistical parameters such as the mean and standard deviation of angular and harmonic variables were calculated, revealing that under ME conditions there is a decrease in rotational speed, greater vibration amplitude, and greater signal dispersion. Finally, classification models were implemented in MATLAB, with the SVM algorithm standing out, achieving an accuracy of over 80%, demonstrating the best performance and processing time. These results confirm the effectiveness of vibration analysis as a tool for the early detection of faults in internal combustion engines.

Keywords: Diesel engines, Vibration Analysis, Signal Processing, Fast Fourier Transform, Autonomous Learning.



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



LISTA DE SIGLAS

FFT. Fast Fourier Transform (Transformada Rápida de Fourier).

NTE. Norma Técnica Ecuatoriana.

INEN. Instituto Ecuatoriano de Normalización.

ODS. Objetivos de Desarrollo Sostenible.

ONU. Organización de las Naciones Unidas.

ICE. Internal Combustion Engine (Motor de Combustión Interna).

WT. Wavelet Transform (Transformada de Wavelet).

WVD. Wigner-Ville Distribution (Distribución de Wigner-Ville).

FEM. Finite Element Model (Modelo de Elementos Finitos).

MCI. Motor de Combustión Interna.

ANOVA. Analysis Of Variance (Análisis de Varianzas).

MEC. Motor de Encendido por Compresión.

MAF. Mass Air Flow sensor (Sensor de Masa de Aire).

TPS. Throttle Position Sensor (Sensor de Posición del Acelerador).

ECU. Electronic Control Unit (Unidad de Control Electrónico).

IAT. Intake Air Temperature sensor (Sensor De Temperatura Del Aire De Admisión).

MAP. Manifold Absolute Pressure (Presión Absoluta del Múltiple).

DPF. Diesel Particulate Filter (Filtro de Partículas Diésel).

SCR. Selective Catalytic Reduction (Reducción Catalítica Selectiva).

PdM. Predictive Maintenance (Mantenimiento Predictivo).



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



IoT. Internet of Things (Internet de las Cosas).

CPS. Cyber-Physical System (Sistemas Ciber-Físicos).

ML. Machine Learning (Aprendizaje Autónomo).

BCD. Binario Codificado Decimal.

PID. Proportional-Integral-Derivative (Proporcional-Integral-Derivativo).

DC. Direct Current (Corriente Continua).

PWM. Pulse Width Modulation (Ancho de Pulso Modulado).

QEI. Quadrature Encoder Interface module (Módulo de Interfaz de Codificador de Cuadratura).

MEMS. Micro-Electro-Mechanical Systems.

MUSIC. Multiple Signal Classification.

IIR. Infinite Impulse Response.

DFT. Discrete Fourier Transform (Transformada Discreta de Fourier).

LabVIEW. Laboratory Virtual Instrument Engineering Workbench.

GUI. Graphic User Interface (Interfaz Gráfica de Usuario).

DAQ. Data Acquisition (Adquisición de Datos).

NI. National Instrument.

FPGA. Field-Programmable Gate Array (Matriz de Puertas Programables en Campo).

BE: Buen Estado

ME: Mal Estado



ÍNDICE DE CONTENIDOS

CAPÍTULO I	19
1.1 Problema de Investigación.....	19
1.2 Objetivos.....	20
1.2.1 Objetivo General.....	20
1.2.2 Objetivos Específicos	20
1.3 Formulación del Problema de Investigación.	20
1.4 Justificación	20
1.5 Hipótesis o Preguntas de Investigación.....	21
CAPÍTULO II.....	22
2.1 Antecedentes.....	22
2.2 Motores de Encendido por Compresión	24
2.2.1 Ciclo Diésel.	25
2.2.2 Sistema de Admisión.....	25
2.2.3 Sistema de Escape.	27
2.2.4 Fallas Electrónicas en el Sistema de Admisión y Escape.....	28
2.3 Mantenimiento Predictivo	29
2.3.1 Problemas con el Mantenimiento Predictivo.....	29
2.3.2 Aprendizaje Autónomo en el Mantenimiento Predictivo.....	29
2.3.3 Ventajas y desventajas.....	30
2.4 Análisis de Vibraciones	31
2.5 Sensores de Encoders Rotatorios.....	33
2.5.1 Principio de Funcionamiento.....	33
2.5.2 Tipos de Encoders.	33



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



2.5.3 Aplicaciones. 34

2.6 Acelerómetro 34

2.6.1 Principio de Funcionamiento..... 34

2.6.2 Tipos de Acelerómetros..... 35

2.6.3 Desafíos y Tendencias Futuras..... 36

2.7 Técnicas de Procesamiento de Datos 36

2.7.1 Filtrado. 36

2.7.2 Transformada Rápida de Fourier..... 37

2.7.2.1 Ecuación de la FFT 37

2.8 LabVIEW..... 38

2.9 Sistemas FPGA..... 39

2.9.1 Arquitectura de los FPGA. 40

2.9.2 Integración de LabVIEW con FPGA..... 40

2.9.3 La Tarjeta NI Single-Board RIO (SB RIO)..... 41

2.10 MATLAB 41

CAPÍTULO III..... 43

3.1 Materiales 43

3.1.1 Motor Mazda BT-50 WL-C 2.5 CRDi 44

3.1.2 Soportes y acoples 45

3.1.3 Encoder PAT-14 G15E..... 45

3.1.4 Equipo Vibratorio 46

3.1.5 Softwares 48

3.2 Método..... 48

3.2.1 Implementación del Sistema..... 49



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



3.2.2	Realización de Pruebas Experimentales en Banco de Prueba	52
3.2.2.2	Simulación de Fallas en el Motor.	53
3.2.3	Procesamiento de Señales.....	54
3.2.4	Análisis en el Dominio Temporal y de Frecuencias.....	55
3.2.4.1	Análisis Estadístico.....	56
3.2.5	Toma de Variables Mediante Árbol de Decisiones	58
3.2.6	Desarrollo de Aprendizaje Autónomo	59
3.3	Proceso de Validación	61
CAPÍTULO IV		62
4.1	Programación de LabVIEW	62
4.2	Análisis del Patrón Vibracional del Motor	65
4.3	Aplicación de FFT a los Datos Obtenidos.....	67
4.4	Caracterización Vibracional	68
4.5	Análisis de Amplitud	69
4.6	Análisis de Órdenes	71
4.7	Análisis Estadístico de Datos de Amplitud y Ángulo	72
4.7.1	Comparación de Resultados Estadísticos de Datos de Vibración ..	73
4.7.2	Comparación de Resultados Estadísticos de Datos de Ángulo	75
4.8	Análisis de Árbol de Decisión	77
4.8.1	Árbol de Decisión de Amplitud.....	79
4.8.2	Árbol de Decisión de Ordenes.....	82
4.8.3	Árbol de Decisión de Variables Estadísticas de Amplitud.....	84
4.8.4	Árbol de Decisión de Variables Estadísticas de Ángulo	87
4.9	Evaluación y Selección del modelo de Aprendizaje Autónomo	90



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



4.10	Evaluación del Modelo de Clasificación Seleccionado.....	93
4.10.1	Diagrama de Dispersión	93
4.10.2	Matriz de Confusión	94
4.10.3	Curva PRC	96
4.10.4	Curva ROC	97
4.11	Validación de modelo de aprendizaje.....	99
CAPÍTULO V.....		102
5.1	Conclusiones.....	102
5.2	Recomendaciones	103
REFERENCIAS BIBLIOGRÁFICAS.		105
ANEXOS		112



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



ÍNDICE DE TABLAS

Tabla 1. Materiales de Campo	43
Tabla 2. Equipos	43
Tabla 3. Software	44
Tabla 4 Especificaciones técnicas del motor Mazda MT-50 WL-C 2.4 CRDi .	44
Tabla 5. Especificaciones de Encoder	46
Tabla 6. Especificaciones de Tarjeta de Adquisición de Datos	47
Tabla 7. Especificaciones de Acelerómetro.....	48
Tabla 8. Caracterización Vibracional BE	68
Tabla 9. Caracterización Vibracional ME	68
Tabla 10. Comparación estadística de amplitud en condiciones BE y ME	71
Tabla 11. Comparación de Órdenes entre Buen Estado (BE) y Mal Estado (ME)	72
Tabla 12. Comparación de resultados estadísticos de amplitud en BE y ME ...	74
Tabla 13. Comparación de resultados estadísticos de ángulo en BE y ME.....	76
Tabla 14. Comparación de Eficiencia de Arboles de Decisión	90
Tabla 15. Tabla comparativa eficiencia de modelos.....	91
Tabla 16. Tabla de selección modelo más eficiente	92



ÍNDICE DE FIGURAS

Figura 1. Inyección de combustible.....	25
Figura 2. Sensor de temperatura del aire A) Vista completa, B) Vista de corte	26
Figura 3. Esquemático de un sistema de inyección indirecta	27
Figura 4. Diagrama de eficiencia del diagnóstico predictivo	31
Figura 5. Consideraciones sobre la transmisibilidad	32
Figura 6. Partes de Encoder	33
Figura 7. Ejemplo de acelerómetro.....	35
Figura 8. Transformada Rápida de Fourier	37
Figura 9. Paletas de tipos de datos numéricos, booleanos y texto	39
Figura 10. Panel Frontal LabVIEW	39
Figura 11. Placa de desarrollo SB RIO 9632.....	41
Figura 12. Encoder PAT-14 G15E	46
Figura 13. Acelerómetro MMA 7361	47
Figura 14. Flujograma de metodología.....	49
Figura 15. Volante de inercia de motor Mazda BT-50.....	51
Figura 16. Implementación de sensores en el banco de pruebas	52
Figura 17. Motor en estado normal	53
Figura 18. Flujograma de programación para MATLAB.....	54
Figura 19. Flujograma de análisis estadístico.....	57
Figura 20. Flujograma de programación para Aprendizaje Autónomo	59
Figura 21. Programación en LabVIEW	63
Figura 22. Datos obtenidos de LabVIEW	64
Figura 23. Dominio de la frecuencia	66
Figura 24. Gráfica de Análisis FFT con ciclos (órdenes).....	68
Figura 25. Resultados de análisis estadístico.....	73
Figura 26. Código para Árbol de Decisiones	79
Figura 27. Árbol de decisión de Amplitud	81
Figura 28. Árbol de Decisión de Ordenes	83



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



Figura 29. Árbol de Decisión Variables de Amplitud	86
Figura 30. Árbol De Decisión De Variables Estadísticas de Ángulo	89
Figura 31. Diagrama de Dispersión	93
Figura 32. Diagrama de confusión	95
Figura 33. Curva Precision-Recall.....	96
Figura 34. Curva ROC.....	99
Figura 35. Código de uso para predicción	99
Figura 36. Validación de modelo	101



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



CAPÍTULO I
INTRODUCCIÓN

1.1 Problema de Investigación.

En la actualidad, los métodos tradicionales de diagnóstico de fallas en motores presentan importantes desafíos y limitaciones. Estos procedimientos suelen enfocarse en la detección de problemas una vez que se han manifestado de manera significativa, lo cual puede generar costosas intervenciones correctivas y afectar gravemente la productividad. La mayoría de estas técnicas dependen de inspecciones visuales periódicas, mantenimiento programado y pruebas manuales, procesos que, aunque necesarios, no son lo suficientemente precisos ni eficientes para identificar fallas incipientes o microdefectos que podrían derivar en problemas mayores. Esta situación tiene un impacto directo en la vida útil de los motores, ya que problemas internos no detectados a tiempo pueden evolucionar rápidamente, generando daños acumulativos. Estos defectos ocultos pueden causar desgastes prematuros en componentes críticos, disminuyendo su rendimiento y, en muchos casos, ocasionando averías catastróficas que detienen por completo el funcionamiento del motor. Estas paradas inesperadas no sólo implican altos costos de reparación, sino también representan un riesgo significativo si ocurren en lugares poco seguros o zonas poco pobladas. En estas áreas, la falta de acceso rápido a servicios de reparación y asistencia puede exacerbar el problema, aumentando el tiempo de inactividad y los costos asociados. Además, la seguridad del personal y del equipo puede verse comprometida.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO****1.2 Objetivos****1.2.1 Objetivo General**

Desarrollar un sistema de diagnóstico capaz de detectar tempranamente fallas en sistemas del motor, como sistema de inyección y admisión, a través del análisis de las vibraciones y las señales provenientes del encoder rotatorio del cigüeñal.

1.2.2 Objetivos Específicos

- Adquirir datos con el uso combinado de acelerómetros y encoders para obtener datos de vibración y posición.
- Procesar señales con la aplicación de técnicas de análisis de vibraciones (FFT) y análisis de series temporales para identificar patrones anómalos.
- Desarrollar algoritmos de detección de fallas con la implementación de modelos predictivos basados en aprendizaje autónomo.

1.3 Formulación del Problema de Investigación.

En el presente proyecto se define el alcance en la utilización del equipo de adquisición de vibraciones y el acelerómetro pertenecientes a la Universidad Técnica del Norte, llevándose a cabo en un motor diésel electrónico de 4 cilindros con una cilindrada entre 2 000 y 2 500 cm³, de la categoría N1 según la norma NTE INEN 2656; se simularán tres fallas en el motor, recopilándose 200 datos por cada una de las fallas simuladas para asegurar una base de datos robusta para el análisis; y para el procesamiento y análisis de datos se implementará un sistema que permita la adquisición continua de datos de vibración y posición del encoder, utilizando técnicas de procesamiento (FFT) y análisis de series temporales para identificar patrones anómalos.

1.4 Justificación

El presente proyecto está enfocado en la innovación y la ingeniería de precisión lo que lo relaciona directamente con el objetivo 9 de los ODS creados por la ONU que menciona “Promover la industria sostenible y fomentar la innovación”. Al emplear

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

tecnologías de vanguardia como el análisis de vibraciones y los encoders rotatorios, se promueve la modernización y adopción de procesos industriales más sostenibles [1].

Además, se alinea perfectamente con la Política 7.2 del Plan de Desarrollo para el nuevo Ecuador 2024-2025 que pretende garantizar el manejo eficiente de los recursos naturales no renovables. Mediante el uso de tecnologías avanzadas de diagnóstico, como el análisis de vibraciones y señales de encoders, el proyecto busca optimizar la eficiencia operativa y reducir las fallas en motores de combustión interna [2].

En el artículo “Relación entre los fallos y las variables de diagnóstico en motores diésel” se resalta la complejidad de diagnosticar de manera efectiva las fallas en motores de combustión interna, lo que impacta negativamente en la vida útil del motor. Este proyecto abordaría dicho desafío mediante el uso de encoders rotatorios y el análisis de vibraciones, logrando así un diagnóstico más eficiente [3].

1.5 Hipótesis o Preguntas de Investigación

Se plantean como hipótesis de investigación que el análisis de las señales de vibración permite identificar el estado de funcionamiento del sistema mecánico, estableciendo diferencias claras entre condiciones de buen estado y posibles condiciones de falla. De igual manera, se considera que variables derivadas de la señal como amplitud, armónicos y órdenes de frecuencia presentan comportamientos diferenciados según el estado operativo del sistema. Asimismo, se plantea que la aplicación de herramientas computacionales para el procesamiento de señales, junto con sistemas de adquisición sincronizados, mejora la caracterización y el análisis del comportamiento vibracional.

Como preguntas de investigación se propone determinar cómo las señales de vibración pueden ser utilizadas para identificar el estado del sistema, qué diferencias existen en los armónicos y órdenes de frecuencia bajo distintas condiciones de operación, y cómo el procesamiento de datos influye en la calidad del análisis vibracional. También se plantea analizar la efectividad de la sincronización entre la señal de vibración y la posición angular en la interpretación del comportamiento dinámico del sistema.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO****CAPÍTULO II
MARCO TEÓRICO****2.1 Antecedentes**

El artículo "A Review on Engine Fault Diagnosis through Vibration Analysis" examina el diagnóstico de fallos en motores de combustión interna (ICE) mediante el análisis de vibraciones, un problema crítico para los conductores debido a la complejidad de los motores y las condiciones operativas variables. Se presentan diversas técnicas de análisis, como la Transformada Rápida de Fourier (FFT), la Transformada de Onda (WT) y la Distribución de Wigner-Ville (WVD), que permiten extraer información dinámica de las señales de vibración, crucial para la detección temprana de fallos como fallos de encendido y desgaste de componentes. Los resultados indican que el uso de estas técnicas puede lograr una alta precisión en la identificación de fallos, alcanzando hasta un 93.55% de precisión en condiciones controladas. El estudio subraya la importancia del monitoreo continuo y el análisis de vibraciones para mejorar la fiabilidad y el rendimiento de los motores, contribuyendo así a la prevención de daños graves y a la reducción de emisiones contaminantes [4].

Un experimento combinó análisis modal y mediciones experimentales para investigar las frecuencias naturales del bloque del motor y su relación con las vibraciones durante su funcionamiento. Utilizando un modelo de elementos finitos (FEM) y un analizador de vibraciones, se identificaron frecuencias naturales que coincidieron con los picos en espectros vibratorios medidos. Estas frecuencias, más pronunciadas en motores desgastados, resultaron ser indicadores clave del estado técnico del motor, validando el FEM como una herramienta eficaz para diagnóstico en motores de combustión interna (MCI) [5].

Se realizó un experimento para diagnosticar fallos en motores diésel mediante análisis de vibraciones, utilizando acelerómetros y procesamiento de señales con FFT para identificar frecuencias características en imágenes espectrales. Se simularon fallos como desconexión de inyectores y variaciones en el volumen de inyección, observándose

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

patrones específicos en las vibraciones asociadas a cada fallo. Además, se aplicaron pruebas ANOVA para validar la consistencia y repetibilidad de los datos, confirmando la utilidad del análisis espectral para identificar y diferenciar fallos en la combustión [6].

Se realizó un experimento para diagnosticar fallos en motores diésel mediante el análisis de vibraciones, correlacionando las señales generadas con eventos específicos del ciclo del motor. Utilizando acelerómetros y FFT, se identificaron impulsos relacionados con la apertura y cierre de válvulas, inyección de combustible y otros procesos críticos. Se simularon fallos como holgura excesiva en válvulas, golpes de pistón y problemas en la inyección de combustible, observando cómo estos alteraban las características de las vibraciones, como amplitud y tiempos. Los resultados permitieron establecer patrones distintivos para diagnosticar el estado del motor de forma precisa y eficiente, validando el análisis vibracional como herramienta técnica esencial [7].

Se desarrolló un método para diagnosticar fallos en cilindros individuales de motores diésel mediante el análisis de la vibración angular del cigüeñal, sin requerir un modelo dinámico. Utilizando un software especializado (TVCA) y acelerómetros, se midieron las vibraciones en motores de 4, 6 y 8 cilindros. El método emplea la teoría vectorial, donde la vibración angular total se descompone en contribuciones individuales de cada cilindro. Se analizaron las amplitudes y fases de la vibración angular, destacando la sensibilidad del orden 0.5 para identificar fallos. En simulaciones, los ángulos de fase de diagnóstico mostraron distribuciones uniformes y simétricas, con diferencias de fase consistentes entre cilindros (60° en motores de 6 cilindros y 45° en los de 8). Las validaciones experimentales confirmaron su alta precisión, con errores mínimos en las diferencias de fase, y demostraron su efectividad para identificar cilindros defectuosos en motores en operación real [8].

Se desarrolló un método para diagnosticar fallos en cilindros individuales de motores diésel mediante el análisis de vibraciones angulares del cigüeñal, evitando la necesidad de modelos dinámicos complejos. Utilizando acelerómetros, se midieron las vibraciones en motores de 4, 6 y 8 cilindros, y se calcularon amplitudes y diferencias de

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

fase en condiciones normales y con fallos simulados. El método, basado en la teoría vectorial, demostró que los ángulos de fase diagnóstica se distribuyen uniformemente en un círculo vectorial, con diferencias consistentes entre cilindros (60° para motores de 6 cilindros y 45° para los de 8). Las simulaciones y validaciones experimentales confirmaron una alta precisión, con errores mínimos (hasta 0.1765° en motores de 6 cilindros), y se probó su efectividad en identificar cilindros defectuosos durante pruebas reales, validando su aplicabilidad práctica en motores diésel [9].

Se desarrolló y validó un método para medir la posición de un eje de salida utilizando dos codificadores absolutos de diferentes resoluciones (12 y 15 bits/rev) conectados mediante mecanismos de multiplicación. La posición del eje se determinó combinando las lecturas de los codificadores y utilizando ecuaciones diofánticas, permitiendo mediciones precisas incluso ante interrupciones eléctricas. Simulaciones y experimentos demostraron que los mecanismos de multiplicación mejoran significativamente la resolución y reducen errores de medición. Por ejemplo, un codificador de 12 bits/rev con multiplicación mostró un desempeño comparable al de un codificador de 15 bits/rev sin multiplicación. Aunque los experimentos presentaron mayores errores que las simulaciones, se confirmó que este enfoque incrementa la precisión y es viable para sistemas avanzados de medición de posición [10].

2.2 Motores de Encendido por Compresión

Los Motores de Encendido por Compresión (MEC), también son conocidos como motores diésel debido a su creador Rudolf Diesel. Los MEC operan mediante la entrada de un fluido, generalmente aire, el cual es comprimido hasta alcanzar condiciones de presión y temperatura que, al inyectar el combustible, provocan su autoinflamación [11].


En el ciclo de los MEC como se menciona anteriormente solo se comprime aire, que es el fluido de admisión, por lo que el combustible es inyectado a presiones muy altas al inicio del tiempo de expansión para generar la combustión.

Como menciona BOSCH, el aire es comprimido a una presión de entre 30 y 55 bar y la temperatura oscila entre los 700°C y 900°C en su punto máximo [12], lo que es suficiente para completar la combustión del diésel inyectado en la cámara como se



observa en la **Figura 1**. Estos parámetros se cumplen cuando el pistón está próximo a llegar al punto muerto superior, terminando la compresión.

Figura 1. Inyección de combustible



Tomado de: Secundino, Motores, 2011 [11].

2.2.1 *Ciclo Diésel.*

Según Payri, el ciclo de cuatro tiempos de un MEC comprende las siguientes etapas: admisión de aire, compresión del fluido, expansión de los gases combustionados y escape de estos. Sin embargo, es importante incluir la inyección del combustible después de la compresión y la descarga de los gases antes de su expulsión. Este ciclo se distingue del ciclo Otto principalmente en la etapa de admisión, donde el fluido es una mezcla de aire y combustible. Además, como se mencionó anteriormente, la inyección de combustible en el ciclo diésel, se realiza en un momento diferente a la admisión [13].

2.2.2 *Sistema de Admisión.*

Para un motor de combustión interna existen sistemas críticos de funcionamiento dentro de los cuales está el sistema de admisión, por el cual ingresa el fluido, en el caso de los MEC aire, que permite realizar la combustión.

Según el manual de Ceac, el sistema de admisión consta de los siguientes elementos [14]:

- Filtro de Aire: Elimina las impurezas del aire antes de que entre en el motor.
- Turbocompresor: Aumenta la cantidad de aire que entra en el motor, mejorando así la potencia.



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS


SUBDECANATO



- Múltiple de Admisión: Distribuye el aire enfriado a los cilindros del motor.
- Culata de Cilindro: Contiene las válvulas de admisión y escape.

Estas serían las partes fundamentales de este sistema, pero con el pasar de los años y la incorporación de la electrónica en la automoción se han implementado sensores, como el que se muestra en la **Figura 2**, que ayudan a mejorar el funcionamiento y precisión de trabajo de los motores.

Figura 2. Sensor de temperatura del aire A) Vista completa, B) Vista de corte



Tomado de: Molina, Electricidad, electromagnetismo y electrónica aplicados al automóvil: Mantenimiento de los sistemas eléctricos y electrónicos de vehículos, 2 011 [15].

Para definir un sensor Medina menciona que es un dispositivo capaz de medir magnitudes físicas o químicas, llamadas variables de instrumentación, y transformarlas en variables eléctricas [16]. Así también deben incluirse estas piezas, y Alonso nos destaca los siguientes [17]:


- Sensor de Masa de Aire (MAF): Mide la cantidad de aire que entra en el motor y envía esta información a la ECU (Unidad de Control Electrónico) para ajustar la cantidad de combustible inyectado.
- Sensor de Posición de la Válvula (TPS): Detecta la posición de la válvula de admisión y proporciona datos a la ECU para sincronizar la inyección de combustible.
- Sensor de Temperatura del Aire de Admisión (IAT): Mide la temperatura del aire que entra en el motor y ayuda a la ECU a ajustar la mezcla aire-combustible.
- Sensor de Presión Absoluta del Colector (MAP): Mide la presión en el colector de admisión y proporciona información a la ECU para ajustar la cantidad de combustible y la sincronización de la inyección.



2.2.3 Sistema de Escape.

El sistema de escape de un motor diésel 4 tiempos es crucial para gestionar y expulsar de manera segura y eficiente los gases de combustión generados durante el funcionamiento del motor. La **Figura 3** muestra los sistemas de admisión y escape de un sistema de inyección indirecta. Este sistema no solo se encarga de dirigir los gases fuera del vehículo, sino también de minimizar el impacto ambiental y el ruido producido, cumpliendo con las regulaciones de emisiones. Durante la combustión, se generan gases como dióxido de carbono (CO_2), óxidos de nitrógeno (NO_x), hidrocarburos no quemados y partículas de hollín, que deben ser procesados antes de ser liberados a la atmósfera [18].

Figura 3. Esquemático de un sistema de inyección indirecta



Tomado de: Hemógenes, Sistemas de inyección de gasolina, 2 002 [19].

El sistema de escape como dice Santander consta de varias partes de las cuales se destacan [20]:

- **Colector de escape:** Es el punto inicial del sistema, conectado directamente a la culata del motor. Su función es recolectar los gases de combustión provenientes de cada cilindro y dirigirlos hacia el resto del sistema de escape. Generalmente está fabricado en acero resistente a altas temperaturas.
- **Turbocompresor:** En motores diésel turbocargados, utiliza la energía de los gases de escape para comprimir el aire que ingresa al motor, mejorando la eficiencia y aumentando la potencia.
- **Convertidor catalítico:** Reduce la emisión de gases contaminantes al convertir sustancias tóxicas como hidrocarburos (HC), monóxido de carbono (CO) y óxidos de



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



nitrógeno (NO_x) en compuestos menos nocivos, como agua (H₂O), dióxido de carbono (CO₂) y nitrógeno (N₂).

- Filtro de partículas diésel (DPF): Es un componente clave en los motores modernos, diseñado para atrapar partículas de hollín (material particulado) y prevenir su liberación al medio ambiente. El DPF requiere regeneración periódica para quemar el hollín acumulado.
- Silenciador: Reduce el ruido producido por los gases de escape al salir del motor mediante cámaras y materiales de absorción acústica.
- Tubería de escape: Conduce los gases procesados por el sistema hacia la parte trasera del vehículo para ser liberados al aire.

Así como en el sistema de admisión, el sistema de escape consta de varios sensores que son de vital importancia para el funcionamiento del motor. Los principales según Agueda son [21]:

- Sensor de oxígeno (Lambda): Mide la cantidad de oxígeno en los gases de escape, permitiendo ajustar la mezcla aire-combustible y optimizar la eficiencia del motor.
- Sensor de presión diferencial: Colocado antes y después del DPF, detecta diferencias de presión para monitorear el nivel de obstrucción en el filtro, indicando si es necesaria una regeneración.
- Sensor de óxidos de nitrógeno (NO_x): Mide las emisiones de NO_x para verificar que se cumplan las normativas ambientales y, en algunos sistemas, ajustar el funcionamiento del sistema de reducción catalítica selectiva (SCR).

2.2.4 Fallas Electrónicas en el Sistema de Admisión y Escape.

Así como la electrónica proporciona precisión de trabajo también trae consigo fallas que pueden afectar fatalmente el funcionamiento del motor. Los sensores, al proporcionar la sobre la admisión del aire, está directamente relacionada con la combustión en las cámaras; si estos sensores no envían la información correcta, no habrá una combustión completa.

Las principales fallas en estos sensores, según Rodríguez, se pueden dar debido al desgaste por el tiempo, una falla en la instalación o el cableado, o incluso puede fallar

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

debido a la acumulación de impurezas. Estas fallas así mismo pueden provocar una subida en el ralenti del motor, un consumo excesivo de combustible y perdida de potencia [22]; en cualquiera de los casos presentados el motor tendrá una anomalía en las vibraciones.

2.3 Mantenimiento Predictivo

Zonta afirma que el Mantenimiento Predictivo (PdM con sus siglas en inglés) se basa en el uso de datos históricos, modelos estadísticos, y métodos de aprendizaje autónomo para predecir fallas potenciales en activos industriales antes de que ocurran, mejorando así la eficiencia operativa. La integración de tecnologías de la Industria 4.0, como el Internet de las Cosas (IoT con sus siglas en inglés) y los Sistemas Ciber-Físicos (CPS con sus siglas en inglés), permite la recolección y análisis de grandes volúmenes de datos en tiempo real, lo cual refuerza la capacidad predictiva [23]. Este enfoque contribuye a reducir el tiempo de inactividad, los costos de mantenimiento y mejora la calidad de producción, alineándose con las demandas de personalización y conectividad actuales en los sistemas industriales modernos.

2.3.1 Problemas con el Mantenimiento Predictivo.

El mantenimiento predictivo enfrenta problemas significativos que limitan su eficacia en entornos industriales. Entre los principales retos se encuentran la gestión de datos ruidosos y erróneos generados en condiciones ambientales adversas, la necesidad de procesar grandes volúmenes de información en tiempo real, y la falta de datos etiquetados que dificultan la precisión de los modelos [24]. Además, las soluciones actuales suelen ser específicas para equipos individuales, careciendo de adaptabilidad a sistemas industriales diversos. Otro desafío clave es la integración tecnológica, ya que los sistemas requieren arquitecturas robustas que combinen procesamiento en la nube, niebla y borde para manejar la complejidad de los datos sin comprometer la velocidad ni la calidad de los análisis.

2.3.2 Aprendizaje Autónomo en el Mantenimiento Predictivo.

Wang menciona que el PdM utiliza Aprendizaje Autónomo (ML con sus siglas en inglés) para anticipar fallas en equipos industriales, mejorando la confiabilidad y



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



reduciendo costos asociados con el tiempo de inactividad. Este enfoque ha evolucionado desde métodos tradicionales a técnicas avanzadas que integran sensores y algoritmos para monitorear condiciones en tiempo real. Las estrategias de ML se dividen en supervisadas, donde se utilizan datos etiquetados de fallas históricas, y no supervisadas, que analizan patrones anómalos en datos operativos [25].

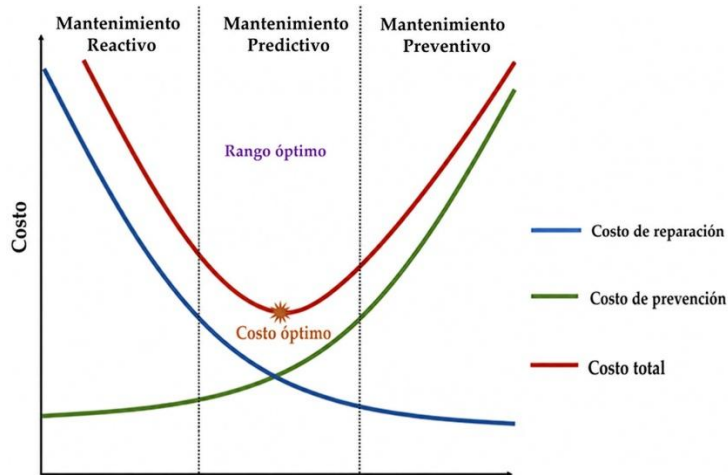
Las tareas de ML en PdM incluyen clasificación binaria para predecir fallos, regresión para estimar la Vida Útil Restante (RUL con sus siglas en inglés) y clasificación multiclase para identificar causas raíz de fallas. El uso de ML en PdM permite adoptar reglas dinámicas para la gestión del mantenimiento, optimizando recursos y reduciendo tiempos de inactividad. Sin embargo, se identifican áreas para futuros trabajos, como ampliar los conjuntos de datos, explorar escenarios de fallas adicionales y mejorar el análisis en el dominio de la frecuencia. Estos avances buscan fortalecer la capacidad del PdM para abordar desafíos en entornos industriales diversos y complejos[26].

2.3.3 *Ventajas y desventajas.*

El mantenimiento predictivo, afirma Castro, presenta varias ventajas clave, como la optimización del tiempo de actividad de los equipos, la mejora en la confiabilidad, y la reducción de costos por fallas imprevistas como se observa en la **Figura 4**. Además, permite prever problemas incipientes y minimizar el uso innecesario de repuestos y mano de obra, creando un historial detallado del equipo. Sin embargo, este enfoque tiene desventajas, como los altos costos iniciales en equipos y formación, la necesidad de técnicos especializados y el tiempo requerido para desarrollar tendencias y establecer umbrales de alarma precisos [27].



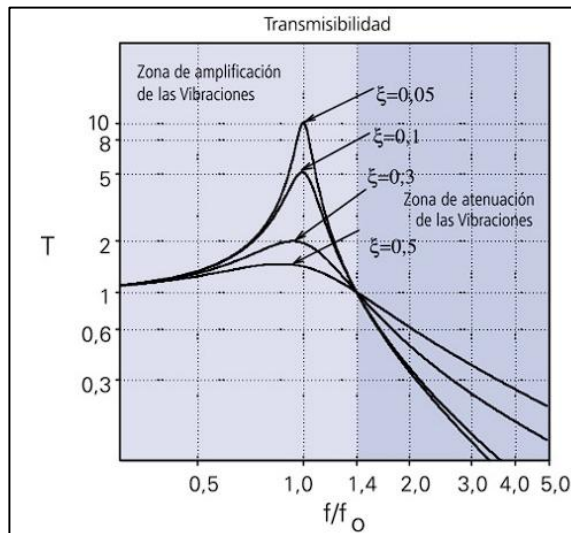
Figura 4. Diagrama de eficiencia del diagnóstico predictivo



Tomado de: Arena, Predictive Maintenance in the Automotive Sector: A Literature Review”, Mathematical and Computational Applications, 2 021 [28].

2.4 Análisis de Vibraciones

El análisis de vibraciones en motores diésel es una técnica esencial para diagnosticar y mantener la salud de estos motores. Este análisis se basa en la medición de vibraciones utilizando acelerómetros, que son dispositivos sensibles que capturan las oscilaciones del motor. Los datos recogidos se analizan mediante transformadas rápidas de Fourier, un método matemático que descompone las señales en sus componentes de frecuencia [6]. Esto permite identificar problemas específicos del motor, como desequilibrios en el cigüeñal o fallos en la combustión, que pueden afectar el rendimiento del motor y causar daños a largo plazo. El diagnóstico técnico basado en análisis de vibraciones es una herramienta poderosa para identificar y prevenir fallos mecánicos en motores de combustión interna. Utilizando técnicas como el análisis modal que se puede ver en la **Figura 5** y modelos de elementos finitos, los ingenieros pueden prever y corregir problemas antes de que se conviertan en fallos costosos[29]. Este enfoque preventivo es especialmente valioso en la industria automotriz y en aplicaciones industriales donde los motores diésel son ampliamente utilizados.

**Figura 5.** Consideraciones sobre la transmisibilidad

Tomado de: Criollo, Diagnóstico de fallos en la combustión para motores de combustión interna alternativos diésel por análisis de vibraciones, 2 014[6].

Los motores diésel funcionan mediante la combustión generada al comprimir el combustible mezclado con aire dentro de la cámara, esta combustión genera un trabajo que da movimiento al pistón y consecuentemente al cigüeñal [7]. Este proceso conjunto con las piezas móviles del motor genera vibraciones que se consideran normales. Debido al desgaste de estas piezas, y errores en la calibración de sistemas vitales del motor, las vibraciones cambian. El análisis de vibraciones se basa en este principio, encontrar anomalías en las señales de vibración que emite el motor.


El uso frecuencias naturales del bloque del motor como herramienta diagnóstica para identificar el estado técnico de componentes críticos, como válvulas, pistones y cilindros mediante la aplicación de técnicas estadísticas especializadas como la Transformada Rápida de Fourier (FFT con sus siglas en inglés) para su determinación [5]. A través de simulaciones y mediciones experimentales, se encontró una correlación entre los picos de frecuencia y el desgaste, siendo más pronunciados en motores con mayor uso. Las principales fuentes de vibraciones incluyen fuerzas de gas impulsivas, impacto en mecanismos y desigualdad en el momento torsional. Se concluye que el análisis de vibraciones en estas frecuencias puede mejorar la precisión del diagnóstico y que el FEM es esencial para evaluar estructuras complejas como los bloques de motor [30].



2.5 Sensores de Encoders Rotatorios

Se define como un dispositivo electromecánico que convierte información posicional rotacional en señales digitales como se muestra en la **Figura 6**. Este dispositivo consta de un disco codificado circular, que rota sincronizadamente con el eje del encoder, junto con una fuente de luz fija y un conjunto de fotodetectores [31].

Figura 6. Partes de Encoder



Tomado de: Ellin, "The design and application of rotary encoders", Sensor Review, 2008 [32].

2.5.1 Principio de Funcionamiento.

El principio de funcionamiento es que convierte el movimiento angular de un eje en señales eléctricas, proporcionando información sobre la posición, velocidad o dirección de giro del eje [32]. Funciona mediante la detección de cambios físicos, ópticos o magnéticos asociados al movimiento del eje y es ampliamente utilizado en aplicaciones como control de motores, robótica y sistemas de automatización industrial.

2.5.2 Tipos de Encoders.

Según Buhai, los encoders se dividen en dos tipos incrementales y absolutos, encoders incrementales generan pulsos eléctricos mediante un disco con marcas opacas y transparentes al girar, proporcionando información relativa del movimiento. Estos pueden ser unidireccionales, que no determinan el sentido de giro y son útiles para medir velocidades, o bidireccionales, que utilizan dos señales desfasadas para identificar tanto la dirección como la posición [33]. Algunos incluyen una marca de referencia (Z) para establecer un punto de origen. Este tipo de encoder requiere seguimiento continuo para



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



interpretar correctamente la posición. Por otro lado, los encoders absolutos proporcionan la posición angular del eje en cualquier momento mediante un sistema de codificación binaria, como Binario Codificado Decimal (BCD) o código Gray, que minimiza errores al variar solo un bit por transición. Estos encoders son ideales para aplicaciones que necesitan medidas absolutas, ya que no dependen del historial de movimiento. Además, los modelos multivuelta emplean un segundo encoder para rastrear varias revoluciones. Ambos tipos tienen aplicaciones en automatización, control de precisión y robótica, destacando por su importancia en sistemas que demandan alta exactitud.

2.5.3 Aplicaciones.

Los encoders en motores se emplean para medir y controlar con precisión la posición, velocidad y dirección del eje del rotor. Estos dispositivos generan señales digitales que son procesadas por sistemas de control como el PID para ajustar el movimiento del motor según parámetros deseados. En motores de Corriente Continua (DC), los encoders proveen retroalimentación esencial para ajustar la potencia mediante controladores PWM y puentes H [34]. Además, al integrarse con microcontroladores, como el dsPIC30F2010 con módulo QEI, facilitan el procesamiento de datos en aplicaciones de control de posición angular, siendo fundamentales en sistemas que requieren alta exactitud y fiabilidad.


2.6 Acelerómetro

2.6.1 Principio de Funcionamiento.

Los acelerómetros operan bajo principios como la detección de masa sísmica, el efecto piezoeléctrico y tecnologías Micro-Electro-Mechanical Systems (MEMS). Los acelerómetros MEMS, los más comunes debido a su bajo costo y tamaño reducido, utilizan una masa suspendida como se muestra en la **Figura 7** que se mueve en respuesta a la aceleración, generando una señal eléctrica proporcional al movimiento [35].



Figura 7. Ejemplo de acelerómetro



Tomado de: Lotters, "The mechanical properties of the rubber elastic polymer polydimethylsiloxane for sensor applications", Journal of Micromechanics and Microengineering, 1 997 [35]

2.6.2 Tipos de Acelerómetros.

- **Acelerómetros Piezoeléctricos:** Utilizan materiales piezoeléctricos que generan una carga eléctrica en respuesta a la deformación mecánica causada por la aceleración. Son ideales para mediciones de alta frecuencia y vibraciones [36].
- **Acelerómetros de Capacitancia:** Basados en cambios en la capacitancia debido al movimiento de una masa sísmica. Son comunes en aplicaciones de bajo consumo y alta precisión, como en dispositivos móviles [37].
- **Acelerómetros Ópticos:** Miden la aceleración mediante interferometría óptica, ofreciendo alta precisión y resistencia a interferencias electromagnéticas [38].

Los acelerómetros tienen una amplia variedad de aplicaciones en diferentes campos, ya que permiten medir y analizar el movimiento y las vibraciones con gran precisión. A continuación, se presentan algunos de los principales usos:

- **Ingeniería Civil:** Monitoreo de vibraciones en estructuras como puentes y edificios [39].
- **Automoción:** Sistemas de control de estabilidad y airbags [40].
- **Electrónica de Consumo:** Orientación de pantallas en smartphones y tablets [41].
- **Robótica:** Navegación y estabilización de robots móviles [42].

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO****2.6.3 Desafíos y Tendencias Futuras.**

Los principales desafíos incluyen la mejora de la precisión, la reducción del consumo de energía y la integración en sistemas IoT. Las tendencias actuales se centran en el desarrollo de acelerómetros de alta resolución, bajo consumo y mayor robustez ante condiciones ambientales adversas [41].

2.7 Técnicas de Procesamiento de Datos

Las técnicas de procesamiento de datos en sensores automotrices son fundamentales para la detección precisa de objetos y la mejora de la seguridad vehicular. Entre los métodos clave se encuentran la Transformada Rápida de Fourier FFT para la estimación de rango y velocidad, el algoritmo Multiple Signal Classification (MUSIC con sus siglas en inglés) para la localización de objetos con alta resolución angular, y el procesamiento adaptativo de señales para mitigar interferencias y mejorar la detección en entornos complejos [43].

2.7.1 Filtrado.

En la industria automotriz, el filtrado de información es un proceso esencial para mejorar la precisión y confiabilidad de los sensores mecánicos, especialmente en entornos ruidosos. Los sensores en vehículos, como los acelerómetros y sensores de velocidad de rueda, están expuestos a vibraciones, interferencias electromagnéticas y variaciones ambientales que pueden afectar la calidad de la señal. Para mitigar estos efectos, se emplean técnicas de filtrado óptimo, como los filtros de Kalman y los filtros adaptativos, que permiten extraer información relevante mientras minimizan el impacto del ruido [44].

Los filtros Infinite Impulse Response (IIR con sus siglas en inglés) son una de las técnicas clásicas aplicadas en el procesamiento de señales caóticas, utilizados principalmente para la reducción de ruido en sistemas de comunicación. Estos filtros presentan la ventaja de ofrecer una alta selectividad y eficiencia en la eliminación de componentes indeseados, debido a su estructura basada en realimentación. Sin embargo, en el contexto de señales caóticas, los filtros IIR presentan limitaciones debido a la sensibilidad a perturbaciones no lineales y a la posible distorsión de la señal útil. A pesar

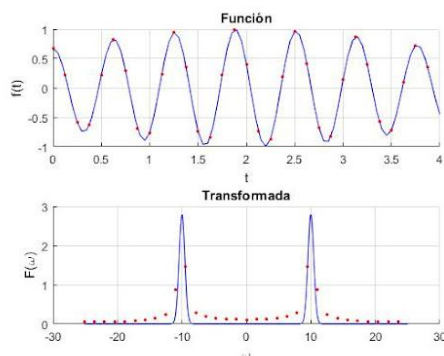


de esto, los filtros IIR siguen siendo una opción viable en escenarios donde se requiere una implementación computacional eficiente con bajos requisitos de procesamiento [45].

2.7.2 Transformada Rápida de Fourier.

La FFT es un algoritmo optimizado para el cálculo eficiente de la Transformada Discreta de Fourier (DFT con sus siglas en inglés), logrando una reducción en la complejidad computacional de $O(N^2)$ a $O(N \log N)$ lo que la hace especialmente útil en aplicaciones automotrices donde el procesamiento en tiempo real es crucial. La FFT descompone señales en componentes frecuenciales utilizando una estructura jerárquica de mariposas (butterflies), como se ve en la **Figura 8**, lo que permite una implementación eficiente en hardware y software. En el ámbito automotriz, la FFT se aplica en el análisis de vibraciones en motores y transmisiones, detección de fallas mediante el monitoreo de espectros de frecuencia y en sistemas de radar para asistencia en la conducción [46].

Figura 8. Transformada Rápida de Fourier



Tomado de: Spilsbury, Transformada Rápida de Fourier, 2 019 [47].

2.7.2.1 Ecuación de la FFT

La transformada rápida de Fourier (FFT) se basa en el cálculo de la transformada discreta de Fourier (DFT), que permite expresar una señal discreta como una suma de componentes sinusoidales de diferentes frecuencias. En el artículo se presenta la DFT como una operación que toma una secuencia de valores y la transforma en otra secuencia que describe su contenido en complejos que dependen de la frecuencia considerada [48]. La fórmula de la DFT consiste en una combinación lineal de los datos de entrada con exponenciales complejas, lo que permite descomponer la señal en sus distintas



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



contribuciones armónicas. Cada término de la suma representa la influencia de un punto de la señal en una frecuencia específica, y el resultado final indica la intensidad de cada una de estas frecuencias. De este modo, la fórmula proporciona una herramienta fundamental para analizar cómo se distribuye la información de la señal en el dominio frecuencial [48].

A partir de esta expresión, el artículo explica que la FFT no modifica la definición matemática de la transformada, sino que reorganiza el cálculo para hacerlo más eficiente. En lugar de evaluar directamente todas las sumas de la DFT, el procedimiento divide el problema en partes más pequeñas, reutilizando resultados intermedios y reduciendo significativamente el número de operaciones necesarias [48]. Esto permite pasar de un cálculo costoso a uno mucho más rápido, manteniendo exactamente el mismo resultado.

Una vez comprendido su funcionamiento, la FFT se convierte en una herramienta clave para el análisis y procesamiento de datos en distintos campos. A continuación, se presentan algunas de sus aplicaciones más relevantes


- **Procesamiento de Señales:** Análisis espectral de señales de audio, vibraciones y telecomunicaciones [49].
- **Procesamiento de Imágenes:** Filtrado y compresión de imágenes mediante transformadas bidimensionales [50].
- **Ingeniería Civil:** Monitoreo de vibraciones en estructuras como puentes y edificios [39].

2.8 LabVIEW

LabVIEW (Laboratory Virtual Instrument Engineering Workbench) es una plataforma de desarrollo gráfico ampliamente utilizada en ingeniería, investigación y educación. Según Travis y Kring, LabVIEW permite crear aplicaciones mediante un enfoque visual con el uso de paletas de trabajo como se presenta en la **Figura 9**, lo que facilita la implementación de sistemas de adquisición de datos, control de instrumentos y automatización [51]. Este enfoque, conocido como programación "G", hace que LabVIEW sea especialmente accesible para ingenieros, científicos y técnicos que no tienen experiencia en programación tradicional.




Figura 9. Paletas de tipos de datos numéricos, booleanos y texto



Tomado de: Lajara, LabVIEW TM Core 1 Manual de Curso, 2 010 [52].

El entorno de desarrollo de LabVIEW consta de dos componentes principales: el Front Panel (**Figura 10**) y el Block Diagram. El Front Panel es la interfaz gráfica de usuario (GUI), donde se colocan controles (entradas) e indicadores (salidas). El Block Diagram es donde se programa la lógica del sistema mediante la conexión de funciones y estructuras. Según National Instruments, esta combinación de interfaz gráfica y programación visual facilita la creación de aplicaciones interactivas y robustas [53].

Figura 10. Panel Frontal LabVIEW



Tomado de: Lajara, LabVIEW TM Core 1 Manual de Curso, 2 010 [52].

2.9 Sistemas FPGA

Los Field-Programmable Gate Array (FPGA con sus siglas en inglés) son dispositivos de hardware reconfigurables que permiten implementar circuitos digitales personalizados. A diferencia de los procesadores tradicionales, que ejecutan instrucciones



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



de manera secuencial, los FPGA pueden realizar múltiples operaciones en paralelo, lo que los hace ideales para aplicaciones que requieren alto rendimiento y flexibilidad. Según Brown y Vranesic, los FPGA consisten en una matriz de bloques lógicos programables interconectados, memoria integrada y unidades de entrada/salida (E/S), lo que permite a los diseñadores crear circuitos digitales personalizados para tareas específicas [54].

2.9.1 *Arquitectura de los FPGA.*

La arquitectura de un FPGA según Boutros se compone de los siguientes elementos clave [55]:

- **Bloques lógicos:** Son los componentes básicos que realizan operaciones lógicas y aritméticas. Estos bloques pueden configurarse para implementar funciones como sumas, multiplicaciones y comparaciones.
- **Memoria integrada:** Los FPGA incluyen bloques de memoria (BRAM) que pueden utilizarse para almacenar datos temporalmente o implementar buffers.
- **Unidades de E/S:** Permiten la comunicación entre el FPGA y otros dispositivos, como sensores, actuadores y sistemas embebidos.
- **Interconexiones programables:** Estas conexiones permiten enlazar los bloques lógicos y otros componentes del FPGA, lo que facilita la implementación de circuitos complejos.

2.9.2 *Integración de LabVIEW con FPGA.*

La integración de LabVIEW con FPGA permite desarrollar sistemas embebidos de alto rendimiento. Según National Instruments, el módulo LabVIEW FPGA permite programar directamente el hardware de FPGA, lo que es especialmente útil para aplicaciones de control en tiempo real y procesamiento de señales [53]. Eriksson describe su uso en sistemas de control de motores y drones, donde la precisión y el tiempo de respuesta son críticos. Además, destaca su aplicación en sistemas de adquisición de datos y control industrial [56].



2.9.3 La Tarjeta NI Single-Board RIO (SB RIO).

La tarjeta NI Single-Board RIO (SB RIO) como la que se observa en la **Figura 11**, es un ejemplo destacado de la integración de FPGA en sistemas embebidos. Combina un FPGA reconfigurable, un procesador en tiempo real y periféricos de E/S, lo que la hace ideal para aplicaciones avanzadas. Según Chen, la SB RIO es ampliamente utilizada en sistemas de control industrial, como el control de motores y la automatización de procesos [57]. McDonald también destacan su uso en sistemas de adquisición de datos para el monitoreo de variables ambientales e industriales[58].

Figura 11. Placa de desarrollo SB RIO 9632



Tomado de: McDonald, Introducción rápida a Matlab y Simulink para ciencia e ingeniería, 2 003 [58].

2.10 MATLAB

MATLAB es definido como “un entorno de cálculo técnico de alto nivel y un lenguaje de programación interactivo para el desarrollo de algoritmos, visualización de datos y análisis numérico” Asimismo, se destaca que su estructura basada en matrices permite trabajar de manera eficiente con datos numéricos y resolver problemas complejos en distintas áreas de la ingeniería (MATLAB Programming for Engineers)[59].

En términos más prácticos, MATLAB puede entenderse como una herramienta muy versátil que facilita el trabajo del ingeniero o investigador, ya que integra en un solo

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

entorno la programación, el análisis matemático y la representación gráfica. Esto permite no solo procesar grandes volúmenes de datos, sino también interpretar resultados de forma visual y clara [60]. Gracias a estas características, se ha convertido en un software ampliamente utilizado en áreas como el procesamiento de señales, el análisis de vibraciones y el desarrollo de modelos computacionales, siendo especialmente útil en proyectos donde se requiere precisión y rapidez en los cálculos.

El aprendizaje autónomo (Machine Learning) es una rama de la inteligencia artificial que permite a los sistemas identificar patrones a partir de datos y realizar predicciones o clasificaciones sin ser programados explícitamente para cada tarea. Su aplicación en el análisis de señales y detección de fallas ha cobrado gran relevancia, debido a su capacidad para procesar grandes volúmenes de información y extraer características significativas que facilitan la toma de decisiones[61].

En este contexto, MATLAB se presenta como una herramienta ampliamente utilizada para el desarrollo e implementación de modelos de aprendizaje autónomo, gracias a su entorno de programación orientado al análisis numérico, procesamiento de señales y visualización de datos. Esta plataforma proporciona funciones y librerías especializadas que permiten entrenar, validar y evaluar modelos de clasificación de manera eficiente, facilitando su aplicación en problemas de ingeniería [62]

El uso de MATLAB en Machine Learning permite implementar diversos algoritmos de clasificación, tales como árboles de decisión, máquinas de soporte vectorial, clasificadores bayesianos y modelos basados en regresión, entre otros. Además, ofrece herramientas para el preprocesamiento de datos, selección de características y análisis de resultados, lo cual resulta fundamental para mejorar el desempeño de los modelos y garantizar su aplicabilidad en escenarios reales.

Asimismo, la integración de técnicas de aprendizaje autónomo con herramientas de análisis de señales en MATLAB permite abordar problemas complejos, como la detección de fallas en sistemas mecánicos, mediante la identificación de patrones en señales de vibración y su relación con condiciones de operación específicas, facilitando la clasificación de estados de funcionamiento como el buen estado y el mal estado [62].


**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**
SUBDECANATO

**CAPÍTULO III
MATERIALES Y MÉTODOS**

En este apartado se describen los materiales y métodos empleados para el análisis de vibraciones en el motor, incluyendo los sensores utilizados, el sistema de adquisición de datos y las herramientas de procesamiento como la FFT y técnicas de aprendizaje autónomo. Además, se detalla el procedimiento seguido para la recolección, tratamiento y evaluación de las señales, con el objetivo de identificar condiciones de funcionamiento y posibles fallas del motor. **Materiales**

En la **Tabla 1** se presentan los materiales de campo que serán utilizados en el desarrollo experimental del proyecto, los cuales permitirán la implementación del sistema de medición y la correcta instalación de los sensores para la adquisición de datos.

Tabla 1. Materiales de Campo

Materiales de campo
Motor Mazda BT-50 WL-C 2.4 CRDi
Soportes, cables y acoples para sensores

A continuación, en la **Tabla 2**, se detallan los equipos que serán empleados en la investigación, los cuales permitirán la medición, registro y procesamiento de las señales durante las pruebas experimentales, asegurando la calidad y confiabilidad de los datos obtenidos.

Tabla 2. Equipos

Equipos
Encoder (PAT-14 G15E)
SBRIO (9636)
Acelerómetro MMA7361


**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**
SUBDECANATO


En la **Tabla 3** se describen las herramientas de software que serán utilizadas en el desarrollo del proyecto, las cuales permitirán el procesamiento de señales, análisis de datos y la implementación del modelo de diagnóstico basado en técnicas de aprendizaje automático.

Tabla 3. Software

Software
National Instruments LABVIEW
Módulo FPGA
MATLAB

3.1.1 Motor Mazda BT-50 WL-C 2.5 CRDi

El estudio tuvo como base de análisis un motor diésel de denominación Mazda BT-50 WL-C 2.4 CRDi. Este motor se destaca por su potencia y eficiencia, lo que lo hizo muy competitivo en condiciones exigentes como carga pesada. Las especificaciones técnicas se detallan en la **Tabla 4**.

Tabla 4 Especificaciones técnicas del motor Mazda MT-50 WL-C 2.4 CRDi

Detalle	Especificación
Tipo de motor	WL-C 2.4 CRDi
Disposición y número de cilindros	En línea, 4 cilindros
Capacidad (cm ³)	2 499
Relación de compresión	18:1
Diámetro interior y carrera (mm)	93.0 x 92.0

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO****3.1.2 Soportes y acoples**

Se utilizarán soportes, cables y acoples destinados a la correcta instalación y funcionamiento de los sensores empleados en la adquisición de datos. Estos elementos permitirán asegurar la fijación adecuada de los dispositivos, así como la integridad y confiabilidad de las señales obtenidas durante el proceso experimental. Los diseños de los soportes y la disposición de los componentes serán tomados de los planos establecidos en la tesis titulada “Diseño de un sistema de adquisición de datos basado en encoders rotatorios para la optimización de la combustión en motores de combustión interna”, elaborada por el estudiante Vismar Ramírez, los cuales servirán como base para su implementación.

3.1.3 Encoder PAT-14 G15E

Para la captura de posición y desplazamiento angular se empleó un encoder modelo PAT-14 G15E (**Figura 12**), cuyas especificaciones principales se resumen en la **Tabla 5**. Este dispositivo opera con una resolución de 12 bits, lo que permite una discretización fina de las mediciones angulares. El rango de temperatura de operación se extiende desde 0 °C hasta +50 °C, asegurando su funcionamiento estable en condiciones ambientales controladas. Además, el encoder funciona con un voltaje de alimentación de 1.5 V, lo cual lo hace compatible con sistemas de bajo consumo energético. La inclusión de este componente resulta fundamental para sincronizar las mediciones temporales y espaciales durante la adquisición de señales.



Figura 12. Encoder PAT-14 G15E



Tabla 5. Especificaciones de Encoder

Detalle	Especificación
Modelo	Encoder (PAT-14 G15E)
Resolución	12 bit de resolución
Temperatura de operación	0 °C ~ +50 °C
Voltaje	1.5 V

3.1.4 Equipo Vibratorio

La adquisición y el procesamiento de las señales analógicas y digitales se realizaron mediante una tarjeta sbrIO-9636, cuyas características se detallan en la **Tabla 6**. Este dispositivo integra una memoria de 512 MB y una memoria RAM de 256 MB, recursos suficientes para manejar volúmenes de datos moderados y ejecutar algoritmos de procesamiento en tiempo real. La tarjeta incorpora un FPGA modelo LX45, lo cual le confiere capacidad de procesamiento paralelo y flexibilidad para implementar lógica personalizada. En cuanto a la interfaz con sensores, dispone de 16 canales de entrada analógica con resolución de 16 bits, permitiendo una conversión analógico-digital de alta precisión. Gracias a estas características, la sbrIO-9636 actúa como el núcleo del sistema


**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**
SUBDECANATO


de adquisición, gestionando tanto la lectura de los sensores como la comunicación con el modelo entrenado.

Tabla 6. Especificaciones de Tarjeta de Adquisición de Datos

Detalle	Especificación
Modelo	Tarjeta sbRIO-9636
Memoria (MB)	512
Ram (MB)	256
FPGA	LX45
AI	16ch-16bit

Para la medición de aceleraciones lineales se utilizó un acelerómetro modelo MMA7361 (**Figura 13**), cuyas especificaciones se presentan en la **Tabla 7**. Este sensor opera con un voltaje de alimentación comprendido entre 2 V y 3.6 V, lo que facilita su integración en sistemas de bajo voltaje. Su sensibilidad es de 800 mV/g cuando se configura en un rango de medición de ± 1.5 G, aunque también admite un rango de ± 6 G para aplicaciones que requieran medir aceleraciones más elevadas. El MMA7361 proporciona dos tipos de salida: una salida analógica que varía linealmente entre 0 V y 5 V en función de la aceleración detectada, y una salida digital con niveles de 0 V o 5 V, útil para aplicaciones de umbral o disparo. Esta dualidad lo convierte en un sensor versátil, capaz de adaptarse tanto a sistemas de adquisición analógica convencionales como a esquemas de lectura digital más simples.

Figura 13. Acelerómetro MMA 7361





**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



Tabla 7. Especificaciones de Acelerómetro

Detalle	Especificación
Modelo	Acelerómetro MMA7361
Voltaje (V)	2 V ~ 3.6 V.
Sensibilidad	800 mV/g a 1.5 G.
Rango	± 1.5 G, ± 6 G.
Salida Analógica	0 V ~ 5 V.
Salida Digital	0 V o 5 V.

3.1.5 Softwares

Se emplearán herramientas de software especializadas como LabVIEW, en su versión 2020 SP1, junto con el módulo LabVIEW FPGA Module, y MATLAB, en su versión 2025b, para el desarrollo del sistema de adquisición y análisis de datos. LabVIEW 2020 SP1, en conjunto con el módulo FPGA, será utilizado para la adquisición y sincronización de las señales provenientes de los sensores, permitiendo un control preciso y en tiempo real del proceso experimental.

Por su parte, MATLAB 2025b será empleado para el procesamiento de los datos obtenidos, incorporando técnicas como la Transformada Rápida de Fourier (FFT) para el análisis en el dominio de la frecuencia, así como métodos de aprendizaje autónomo orientados a la interpretación y clasificación de la información recopilada[63].

3.2 Método

El proceso metodológico inicia con la implementación de sensores en un banco de pruebas, donde se configuran los dispositivos necesarios para la adquisición de datos. Posteriormente, se realizan pruebas experimentales bajo distintas condiciones de operación, con el objetivo de obtener información representativa del comportamiento del sistema.



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



Una vez recolectados los datos, estos se analizan tanto en el dominio temporal como en el dominio de frecuencias, lo que permite identificar patrones, tendencias y posibles anomalías. A partir de este análisis, se lleva a cabo la selección de variables mediante un árbol de decisiones, enfocándose en aquellas que presentan bajo desempeño y que ofrecen mayor potencial de mejora.

Finalmente, con la variable seleccionada se desarrolla un modelo de aprendizaje autónomo, el cual es posteriormente validado para asegurar su confiabilidad. El proceso concluye con la obtención de resultados finales que permiten evaluar el desempeño del sistema como se observa en la **Figura 14**.

Figura 14. Flujograma de metodología



3.2.1 Implementación del Sistema

Se implementa un sistema de adquisición de datos orientado al monitoreo del comportamiento dinámico del motor, integrando sensores y hardware de procesamiento especializados. Para la captación de vibraciones se emplea un acelerómetro MMA7361, el cual permite medir aceleraciones en distintos ejes y detectar variaciones asociadas al estado del sistema. De manera complementaria, se incorpora un encoder rotatorio PAT-14 G15E, acoplado directamente al cigüeñal del motor, con el fin de registrar la velocidad angular y la posición, proporcionando información precisa sobre el movimiento rotacional.



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



La adquisición y el procesamiento de las señales se realizan mediante una tarjeta NI sbRIO-9636, que permite trabajar en tiempo real gracias a su arquitectura basada en FPGA y procesador embebido. Esta plataforma facilita la sincronización de las señales provenientes de los sensores y asegura una captura de datos confiable y de alta resolución, lo cual es fundamental para el análisis posterior.

Todo el sistema se integra en un entorno de programación desarrollado en LabVIEW, donde se diseña la interfaz de usuario para la visualización, almacenamiento y gestión de los datos adquiridos. Esta interfaz permite supervisar el funcionamiento del sistema en tiempo real, así como configurar parámetros de adquisición y procesamiento, logrando una solución completa para el análisis y monitoreo del motor.

Con el fin de garantizar la correcta lectura, compatibilidad y procesamiento de la información, se ha priorizado el uso de texto sin acentuación, sin que esto afecte la comprensión del contenido. La programación de la tarjeta sbRIO para el uso del encoder es tomada de la tesis “Diseño de un sistema de adquisición de datos basado en encoders rotatorios para la optimización de la combustión en motores de combustión interna” con autoría del estudiante Vismar Ramírez.

Para la implementación del encoder al cigüeñal del motor de prueba se realizó un eje rígido de acero. Este eje fue realizado con método de torneado, para lo cual se tomó en cuenta la entrada disponible en el volante de inercia del motor (**Figura 15**) y el acople mecánico que se usó en el Encoder.



Figura 15. Volante de inercia de motor Mazda BT-50



Además de esto, se aseguró el Encoder a una base de acero empernada a la bahía del banco de pruebas. Esta base se realizó con proceso de soldadura SMAW. Con esto se garantiza una unión segura y estable entre el sensor y el motor de pruebas.


Una vez realizadas las adaptaciones para acoplar el encoder al banco de pruebas, se realizó la sincronización de estos. Para este proceso se procedió de la siguiente manera:

1. Se extrajo el inyector del primer cilindro.
2. El pistón se puso en punto muerto superior.
3. Se aseguró el encoder a la base de acero.
4. Con ayuda del programa LabVIEW, el encoder se ubicó en el punto cero
5. Usando el acople flexible se fijó la unión del sensor y el volante de inercia asegurando la sincronización de estos.

El acelerómetro se acopló al cabezote con ayuda de un imán de neodimio, como se ve en la **Figura 16**. Se optó por realizarlo así debido a que el sensor no puede soportar la temperatura de trabajo del motor y el imán funciona como un aislante térmico.



Figura 16. Implementación de sensores en el banco de pruebas



3.2.2 Realización de Pruebas Experimentales en Banco de Prueba

Los equipos mencionados fueron utilizados en un motor Mazda BT-50 de 2.4 l perteneciente a la Universidad Técnica del Norte. Las pruebas realizadas abarcan los siguientes parámetros:

El motor diésel de 4 cilindros, 2.4 L turbo (Mazda BT-50) del banco de pruebas fue operado inicialmente en condiciones normales sin presencia de fallas inducidas en el sistema de inyección. Se estableció un régimen base de 1 000 rpm, correspondiente a un estado estable sin carga significativa.

Durante esta fase se verificó el funcionamiento adecuado del sistema de inyección, asegurando una combustión homogénea, estabilidad en el régimen de giro y ausencia de vibraciones anómalas. Estos valores constituyen la línea base experimental para la posterior simulación de fallas (**Figura 17**).

**Figura 17.** Motor en estado normal

3.2.2.2 Simulación de Fallas en el Motor.

La simulación de falla consistió en la desconexión eléctrica mediante el uso de un selector (on/off) y un relé, de uno de los inyectores del motor, generando un corte en el suministro de combustible hacia ese inyector y afectando de forma directa a su cilindro correspondiente. Esta condición produjo una disminución del régimen de giro debido a la pérdida parcial de potencia y un incremento significativo en las vibraciones del motor.

En condiciones normales (on), el relé mantiene el circuito cerrado, permitiendo la activación del inyector por parte de la unidad de control electrónico. Al accionar el selector hacia la posición (off), el relé abre el circuito, interrumpiendo la señal eléctrica e impidiendo la inyección de combustible en el cilindro correspondiente. En este contexto, se denominará BE (Buen Estado) a la condición de funcionamiento normal del sistema, mientras que la condición de falla inducida será identificada como ME (Mal Estado), con el fin de diferenciar claramente ambos estados operativos del motor.

Este método permitió inducir la falla de forma controlada, segura y reversible, garantizando condiciones experimentales reproducibles sin modificar la configuración original del sistema de gestión electrónica del motor.

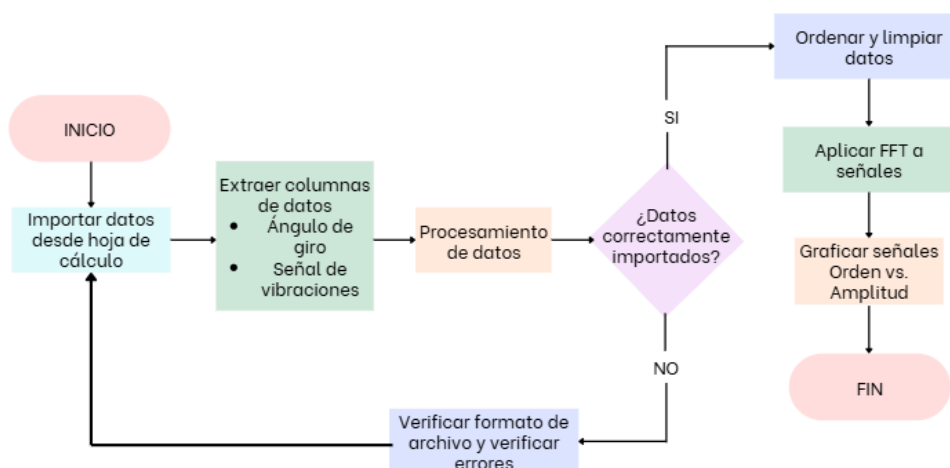


3.2.3 *Procesamiento de Señales*

Los datos por procesar fueron obtenidos del programa LabVIEW, en donde se sincronizó la señal del acelerómetro con la del encoder. Esta información es ingresada a una hoja de cálculo que se importa al programa de MATLAB.

Para el uso de MATLAB se realizó el flujograma mostrado en la **Figura 18**. En donde se detalla el proceso de importación, procesamiento y muestra en gráficas de los datos obtenidos.

Figura 18. Flujograma de procesamiento de señales



El proceso comienza con la importación de los datos desde una hoja de cálculo, donde se almacenan los registros obtenidos experimentalmente. De este archivo se extraen específicamente dos columnas fundamentales: la primera corresponde al ángulo de giro del eje o componente rotatorio, y la segunda contiene la señal de vibración medida en distintos puntos de la máquina. Una vez cargados los datos, se procede a verificar tanto el formato del archivo como la integridad de la información, detectando posibles errores como valores atípicos, celdas vacías o inconsistencias en los rangos de medición.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

En caso de que los datos no sean correctamente importados o presenten errores, se ejecuta una etapa de ordenamiento y limpieza. Esta fase implica reorganizar las filas según el ángulo de giro, eliminar registros duplicados o erróneos, y completar o descartar valores nulos según el criterio estadístico definido. Una vez limpios, los datos vuelven a ser evaluados para confirmar que cumplen con los requisitos necesarios antes de continuar.

Cuando los datos ya están validados, se aplica la Transformada Rápida de Fourier (FFT) a las señales de vibración. Este paso matemático es esencial porque convierte la señal original, que está expresada en el dominio del tiempo, a una representación en el dominio de la frecuencia. Gracias a la FFT es posible identificar las frecuencias predominantes en la vibración y relacionarlas con posibles fallos mecánicos, como desbalance, desalineación o daños en rodamientos.

Finalmente, se genera una tabla que relaciona el orden de giro (es decir, la frecuencia multiplicada por un factor relacionado con la velocidad de rotación) con la magnitud de las vibraciones. Esta representación visual permite interpretar de manera clara e intuitiva los resultados del análisis, facilitando la identificación de armónicos o frecuencias críticas. El proceso concluye una vez que se ha obtenido y documentado esta gráfica, la cual sirve como base para el diagnóstico del estado de la maquinaria.

3.2.4 Análisis en el Dominio Temporal y de Frecuencias

El análisis en el dominio temporal se realizará a partir de las series de tiempo obtenidas de los datos de vibraciones registrados experimentalmente, los cuales serán almacenados en un archivo en formato Excel [64]. En este caso, es importante destacar que las series temporales no estarán definidas en función del tiempo convencional (segundos), sino en función del ángulo de giro del motor, es decir, en el dominio angular (grados o ciclos por revolución). Esto implica que la señal de vibración será analizada en relación con la posición angular del cigüeñal, lo cual permite una representación más precisa de los fenómenos periódicos asociados al funcionamiento del motor.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

Este enfoque facilita la identificación de eventos característicos que dependen directamente de la cinemática del motor, como la combustión, la apertura y cierre de válvulas y el giro del cigüeñal, ya que dichos fenómenos ocurren en posiciones angulares específicas y no necesariamente en intervalos de tiempo uniformes. Para la obtención de dichas series, los datos serán importados al entorno de MATLAB, donde serán procesados y organizados adecuadamente para su análisis. A partir de esta información, se generarán representaciones gráficas que permitirán visualizar la evolución de la señal vibratoria en función del ángulo del motor, constituyendo una base fundamental para el análisis posterior en el dominio de la frecuencia.

Posteriormente, se realizará el análisis en el dominio de órdenes (frecuencia), con el objetivo de identificar las componentes más representativas de la señal. En este contexto, se analizará el espectro de vibraciones, en el cual se identificarán los picos más significativos de amplitud. Estos picos corresponderán a los armónicos principales del sistema, los cuales serán definidos como armónico 1, armónico 2 y armónico 3, en función de su magnitud y relevancia dentro del espectro.

En particular, los armónicos serán determinados a partir de los valores máximos observados en la gráfica de amplitud de vibración en función del orden (ciclos por revolución). Estos puntos representarán las frecuencias dominantes del sistema y estarán asociados a fenómenos mecánicos característicos, tales como la combustión, el giro del cigüeñal y la apertura y cierre de válvulas.

Finalmente, este análisis permitirá establecer una relación entre el comportamiento temporal de la señal y sus componentes en frecuencia, contribuyendo a una mejor comprensión del comportamiento dinámico del sistema y facilitando la identificación de posibles fuentes de vibración.

3.2.4.1 Análisis Estadístico

El análisis estadístico se realizará a partir de los datos de vibraciones que serán obtenidos experimentalmente, los cuales se almacenarán en un archivo en formato Excel para su posterior procesamiento. Para el tratamiento de la información se utilizará el



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

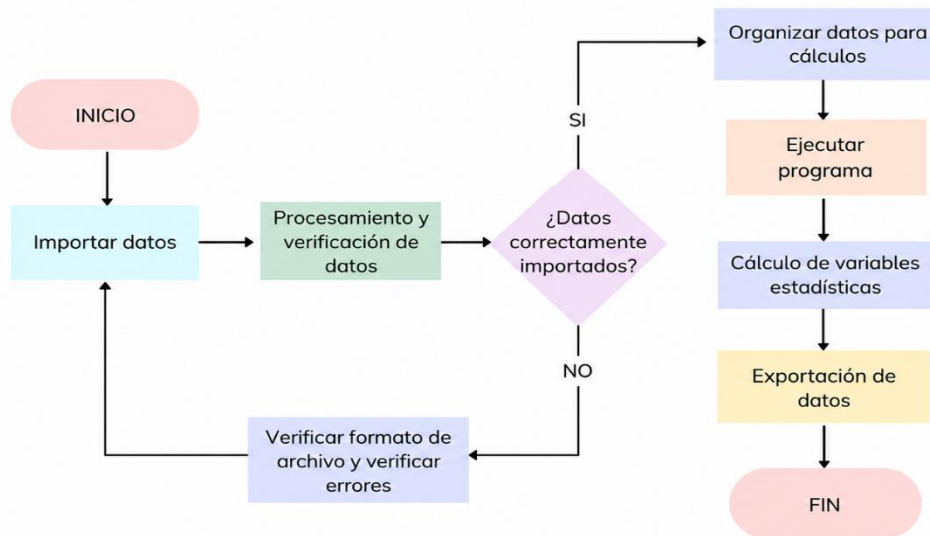
SUBDECANATO



software MATLAB, mediante la implementación de un script que permitirá calcular diversos parámetros estadísticos descriptivos, con el fin de caracterizar el comportamiento vibratorio del sistema en estudio.

En una primera etapa se utilizará un flujo grama **Figura 19** como guía, los datos serán importados desde el archivo de Excel se organizarán en una matriz, lo que permitirá su manipulación dentro del entorno de programación. A partir de esta matriz de datos, se procederá al cálculo de diferentes indicadores estadísticos. Entre ellos, se determinará el valor cuadrático medio (RMS), el cual permitirá evaluar la magnitud efectiva de las vibraciones. Asimismo, se calcularán medidas de tendencia central como la media aritmética, la mediana y la moda, con el propósito de identificar el comportamiento promedio y la distribución de los valores registrados.

Figura 19. Flujograma de análisis estadístico



De igual manera, se obtendrán medidas de dispersión como la varianza y la desviación estándar, las cuales permitirán analizar el grado de variabilidad de los datos respecto a su valor medio. Adicionalmente, se calcularán la curtosis y la asimetría, parámetros que permitirán describir la forma de la distribución de los datos, identificando la presencia de concentraciones o sesgos en los valores analizados.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

Para complementar el análisis, se determinará la media cuadrática a partir del promedio de los cuadrados de los datos originales, seguida de la obtención de su raíz cuadrada, lo que permitirá contar con otra medida representativa de la magnitud de las vibraciones. Finalmente, todos los resultados obtenidos serán organizados en una tabla generada automáticamente por el programa, facilitando su visualización y posterior interpretación.

Este conjunto de parámetros estadísticos permitirá caracterizar de manera integral el comportamiento vibratorio del sistema, contribuyendo a la identificación de patrones asociados a fenómenos mecánicos como la combustión, el giro del cigüeñal y la apertura y cierre de válvulas.

3.2.5 Toma de Variables Mediante Árbol de Decisiones

De manera complementaria al análisis estadístico previamente descrito, se realizará un proceso de evaluación de las variables obtenidas, con el objetivo de determinar cuál de ellas presenta un mejor desempeño en la caracterización del comportamiento vibratorio del sistema. Para ello, se empleará un modelo de árbol de decisiones, el cual permitirá analizar de forma comparativa las nueve variables estadísticas calculadas: RMS, media, mediana, moda, varianza, desviación estándar, curtosis, asimetría y media cuadrática.

Este procedimiento se desarrollará en el entorno de MATLAB, donde se implementará un algoritmo de clasificación basado en árboles de decisión. A partir de los datos previamente procesados, el modelo evaluará la capacidad de cada variable para discriminar y representar adecuadamente las características del sistema, considerando su relevancia dentro del conjunto de datos.

El árbol de decisiones funcionará mediante la generación de nodos de decisión, en los cuales se establecerán criterios de selección basados en la variabilidad y comportamiento de cada variable. A través de este proceso, se identificarán aquellas variables que aporten más información y que presenten una mejor capacidad de ajuste al fenómeno analizado.



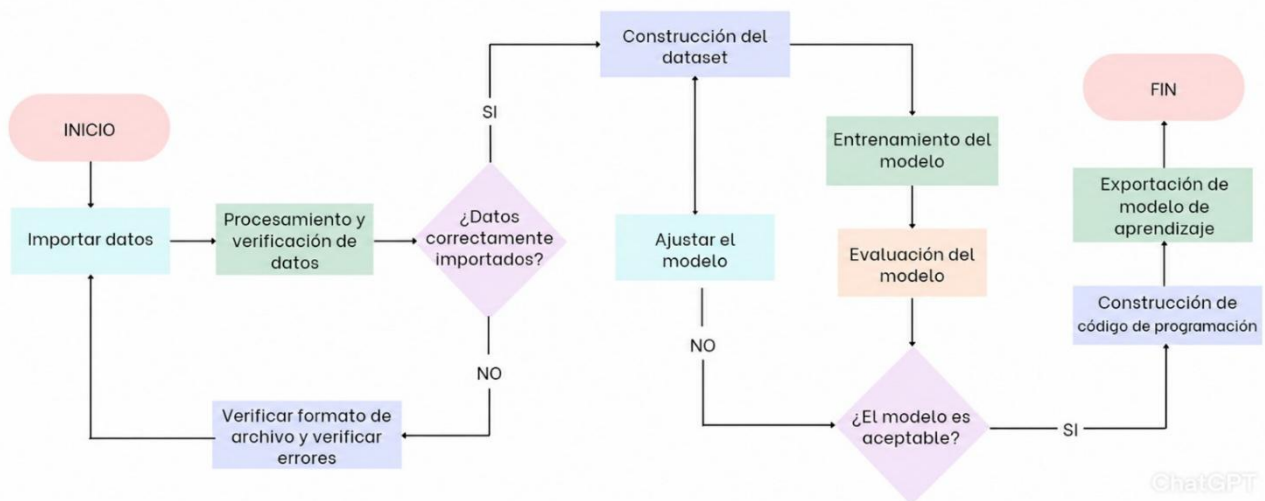
Como resultado, se obtendrá una jerarquización de las variables estadísticas, permitiendo determinar cuál de ellas es la más eficiente y representativa para el estudio del comportamiento vibratorio. Esta selección facilitará la optimización del análisis, enfocándose en los parámetros más relevantes y reduciendo la redundancia de información.

Finalmente, los resultados obtenidos mediante el árbol de decisiones permitirán respaldar de manera objetiva la elección de la variable más adecuada, contribuyendo a mejorar la precisión del análisis y la interpretación de los datos en el contexto del sistema evaluado.

3.2.6 Desarrollo de Aprendizaje Autónomo

Para organizar de mejor manera cada etapa del proceso, se utilizó un flujograma, mostrado en la **Figura 20**, como base para la planificación de la metodología. Este permitió visualizar de forma clara el orden de cada paso, desde la importación de los datos hasta la evaluación final del modelo. Gracias al flujograma, fue más fácil identificar la secuencia de actividades, evitar errores y mantener un proceso ordenado durante el desarrollo del aprendizaje autónomo en MATLAB.

Figura 20. Flujograma de programación para Aprendizaje Autónomo





FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



Se importarán los datos desde un archivo de Excel hacia MATLAB. Esto permitirá trabajar con la información de manera organizada y tener acceso a todas las variables necesarias para el análisis. Una vez cargados los datos, es importante revisar que se hayan importado correctamente, verificando que no existan valores vacíos, errores en las filas y columnas o datos incompletos que puedan afectar el resultado del modelo.

Después de comprobar que la información está validada, se procederá a separar las entradas y salidas. Las entradas corresponden a las variables que se utilizarán para hacer la predicción, mientras que la salida es el resultado que se desea obtener. Esta separación es fundamental para que el modelo pueda aprender a partir de los datos disponibles.

Luego, los datos se dividirán en dos grupos: entrenamiento y prueba. Los datos de entrenamiento sirven para que el modelo aprenda patrones y relaciones entre las variables, mientras que los datos de prueba permiten comprobar qué tan bien funciona con información nueva. Esta etapa ayuda a evitar que el modelo solo memorice los datos y asegura resultados más confiables.

Una vez organizados los datos, se elige el modelo de aprendizaje autónomo que presente el mayor nivel de eficacia. En MATLAB se pueden probar distintos modelos los cuales se clasifican en 5 familias las cuales son: Árboles de decisión, Maquinas de Soporte vectorial (SVM), K vecinos más cercanos (KNN), Redes Neuronales, Modelos de Ensamble, comparando cuál ofrece mejores resultados de precisión.

Después de seleccionar el mejor modelo, se realizan las predicciones utilizando los datos de prueba. Estas predicciones permiten observar cómo respondería el sistema ante nuevos casos y verificar si el modelo realmente aprendió de manera adecuada.

Finalmente, se evalúa el rendimiento del modelo mediante indicadores como la precisión, diagrama de dispersión, diagrama de coordenadas paralelas o la matriz de confusión. Con estos resultados se puede analizar qué tan efectivo fue el aprendizaje autónomo y mostrar de forma clara el desempeño obtenido, facilitando la interpretación de la información y la toma de decisiones.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO****3.3 Proceso de Validación**

Para garantizar la confiabilidad y capacidad de generalización de los modelos de aprendizaje autónomo, se establecerá un proceso de validación que permitirá evaluar su desempeño frente a datos no utilizados durante la etapa de entrenamiento. Este enfoque permitirá obtener una medida objetiva del comportamiento del modelo en condiciones similares a las de aplicación real.

La validación se llevará a cabo mediante el uso de un conjunto de datos independiente, el cual no será empleado durante el entrenamiento del modelo. Dicho conjunto estará conformado de manera balanceada entre las clases de estudio, con el fin de evaluar de forma equitativa el desempeño del modelo en cada una de ellas y evitar posibles sesgos en la evaluación.

Para la obtención de resultados, se utilizará la función de predicción del modelo, la cual permitirá determinar tanto la clase estimada como la probabilidad asociada a cada predicción. A partir de esta información, se analizará no solo la exactitud del modelo, sino también el nivel de confianza en sus decisiones, definido como la probabilidad máxima asignada a la clase predicha.

Adicionalmente, se empleará la matriz de confusión como herramienta principal para la evaluación del desempeño, permitiendo identificar los aciertos y errores de clasificación en cada clase, así como analizar el comportamiento del modelo en términos de precisión y posibles confusiones entre estados.

Este procedimiento permitirá establecer una base metodológica clara para la validación del modelo, asegurando que los resultados obtenidos reflejen de manera adecuada su desempeño en escenarios de aplicación práctica.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO****CAPÍTULO IV****RESULTADOS Y ANÁLISIS**

En este capítulo se presentan y analizan los resultados obtenidos a partir del estudio de señales de vibración en el dominio de la frecuencia, utilizando técnicas de aprendizaje autónomo para determinar el estado de un motor. La base de datos empleada está conformada por espectros previamente obtenidos mediante la Transformada Rápida de Fourier (FFT), los cuales representan tanto condiciones de funcionamiento normal como escenarios de falla.

4.1 Programación de LabVIEW

La adquisición de datos se realizó combinando acelerómetros (sensores de vibración) y un encoder, lo que permitió obtener simultáneamente información sobre la respuesta vibratoria del sistema y su posición angular a lo largo del ciclo de operación. Esta integración fue fundamental para cumplir con el objetivo planteado, ya que permitió analizar de forma conjunta el comportamiento dinámico y la sincronización mecánica del sistema.

Mediante una implementación desarrollada en LabVIEW, se capturaron las señales de los acelerómetros ubicados en distintos ejes, obteniendo datos representativos de las vibraciones en múltiples direcciones. En paralelo, el encoder proporcionó información precisa de la posición angular, lo que permitió vincular cada evento vibratorio con un punto específico dentro del ciclo de funcionamiento. Los resultados mostraron que esta adquisición simultánea facilitó establecer una correspondencia directa entre las variaciones de la señal vibratoria y la posición angular, relación clave para identificar patrones repetitivos asociados a fenómenos mecánicos como la combustión, la apertura y cierre de válvulas, los cuales se manifestaron como variaciones características en las señales registradas.

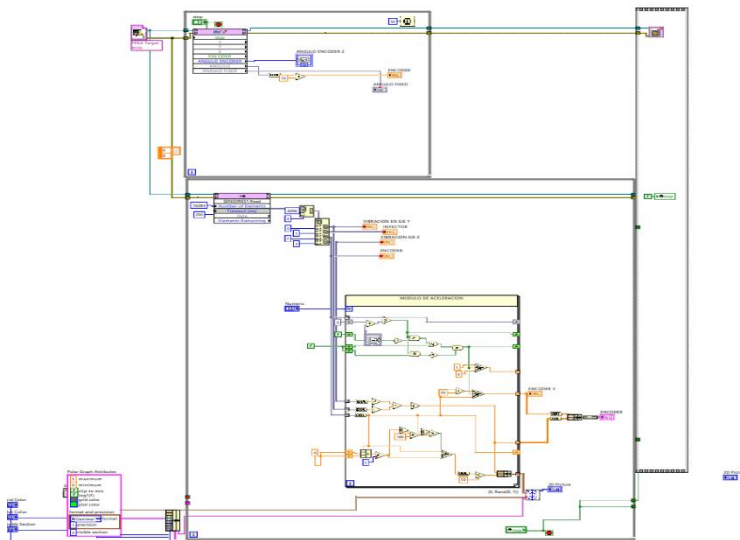
Además, se observó que la señal del encoder presentó un comportamiento periódico y estable, lo que la convirtió en una referencia ideal para sincronizar las señales de vibración. Esta sincronización permitió organizar los datos en función del ciclo de



operación, mejorando la precisión del análisis tanto en el dominio del tiempo como en el de la frecuencia.

En cuanto a la programación, el sistema desarrollado en LabVIEW integró de manera eficiente la adquisición y el procesamiento de las señales de los diferentes sensores. En el diagrama de bloques se implementaron módulos específicos para leer los datos de los acelerómetros y del Encoder como se observa en la **Figura 21**, así como para organizarlos y distribuirlos hacia distintos canales de visualización. La estructura del programa permitió manejar múltiples señales de forma simultánea, garantizando una correcta sincronización entre las variables de vibración y la señal angular.

Figura 21. Programación en LabVIEW



Asimismo, se incorporaron rutinas internas para el acondicionamiento de las señales y el cálculo de variables derivadas, como el módulo de aceleración. La programación también permitió la actualización continua de gráficas en tiempo real, reflejando el comportamiento dinámico del sistema durante su operación. La correcta integración entre la interfaz gráfica y el diagrama de bloques evidenció un funcionamiento estable, mostrando de manera clara y organizada las señales adquiridas, lo cual resultó fundamental para el análisis posterior.



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



Los datos obtenidos durante la adquisición fueron organizados y almacenados en formato tabular, tal como se observa en la **Figura 22**. En este caso, cada registro se estructura en dos columnas principales: la primera corresponde al ángulo de giro del motor, mientras que la segunda contiene el valor de vibración asociado a dicho ángulo. Esta forma de almacenamiento facilita el procesamiento posterior de la información, así como su análisis estadístico y espectral.

Figura 22. Datos obtenidos de LabVIEW

	A	B
1	ANGULO	VIBRACION
2	0.117	2.90386
3	0.12	3.04063
4	0.469	3.15186
5	0.82	3.23713
6	0.856	3.3125
7	0.874	3.37491
8	0.943	3.4214
9	1.523	3.45619
10	1.671	3.51944

En la elaboración de las tablas presentadas en este trabajo se ha optado por no utilizar tildes ni caracteres especiales. Esta decisión responde a limitaciones del entorno de programación empleado, específicamente MATLAB, el cual puede presentar inconvenientes en el manejo, visualización o exportación de datos que incluyen este tipo de caracteres, especialmente en la generación automática de tablas y archivos. Con el fin de garantizar la correcta lectura, compatibilidad y procesamiento de la información, se ha priorizado el uso de texto sin acentuación, sin que esto afecte la comprensión del contenido.

Durante la etapa de adquisición de datos se logró recopilar un total de 400 muestras, con el propósito de contar con una base suficientemente amplia y confiable para



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



el análisis. Se recopiló un total de 21 313 600 datos, correspondientes tanto al ángulo de giro del motor como a la señal de vibración registrada de manera simultánea.

Para facilitar la comparación entre distintos estados de operación, las muestras se dividieron en dos grupos iguales. Por un lado, se obtuvieron 200 muestras con el motor funcionando en condiciones normales, reflejando su comportamiento en buen estado. Por otro lado, se recopilaron 200 muestras adicionales en las que se simuló una falla, con el fin de observar cómo cambian las características de vibración cuando el motor presenta anomalías.


Esta forma de organizar los datos permite tener una visión más clara de las diferencias entre un motor en buen estado y uno con fallas. Además, resulta clave para el desarrollo del análisis posterior, ya que proporciona una base equilibrada que facilita la identificación de patrones y mejora la confiabilidad de los resultados obtenidos.

4.2 Análisis del Patrón Vibracional del Motor

En la **Figura 23**, se presenta la señal de vibración obtenida mediante un acelerómetro instalado en el motor de un vehículo Mazda BT-50 con motorización 2.4 L, en función del ángulo medido a través de un encoder. La adquisición simultánea de ambas variables permite establecer una relación directa entre el comportamiento vibracional del motor y su posición angular, lo cual resulta fundamental para el análisis del funcionamiento dinámico del sistema.



Figura 23. Dominio de la frecuencia



La señal registrada presenta un comportamiento oscilatorio continuo a lo largo del rango angular de 0° a 720° , correspondiente a un ciclo completo de operación de un motor de cuatro tiempos. Los valores de amplitud se encuentran aproximadamente entre 1.9 y 3.9 G, evidenciando variaciones que se mantienen dentro de un rango definido. Estas oscilaciones no son aleatorias, sino que muestran un patrón repetitivo a lo largo del ciclo, con cambios en la amplitud y frecuencia que se repiten de manera consistente en determinados intervalos angulares.

Este comportamiento se encuentra directamente asociado al ciclo termodinámico del motor, el cual comprende las fases de admisión, compresión, combustión y escape. Cada una de estas etapas genera diferentes niveles de esfuerzo mecánico y dinámico en los componentes internos, lo que se refleja en la señal de vibración. En particular, se observan incrementos en la amplitud vibracional en ciertos intervalos del ángulo, los cuales pueden relacionarse con los eventos de combustión, donde se produce una liberación significativa de energía y un aumento de presión en los cilindros.

De igual manera, se identifican regiones donde la señal presenta una menor amplitud relativa, asociadas a fases del ciclo en las que las fuerzas internas son más estables. La alternancia entre estas zonas de mayor y menor vibración confirma la



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



naturaleza cíclica del funcionamiento del motor y permite evidenciar la influencia de los procesos internos sobre la respuesta dinámica del sistema.

Un aspecto relevante es la repetitividad del patrón vibracional a lo largo del intervalo de 720° , lo que valida la sincronización entre la medición de vibración y la posición angular del motor. Esta consistencia en la señal indica que el motor opera en condiciones normales y estables, manteniendo un comportamiento dinámico uniforme en cada ciclo de funcionamiento.

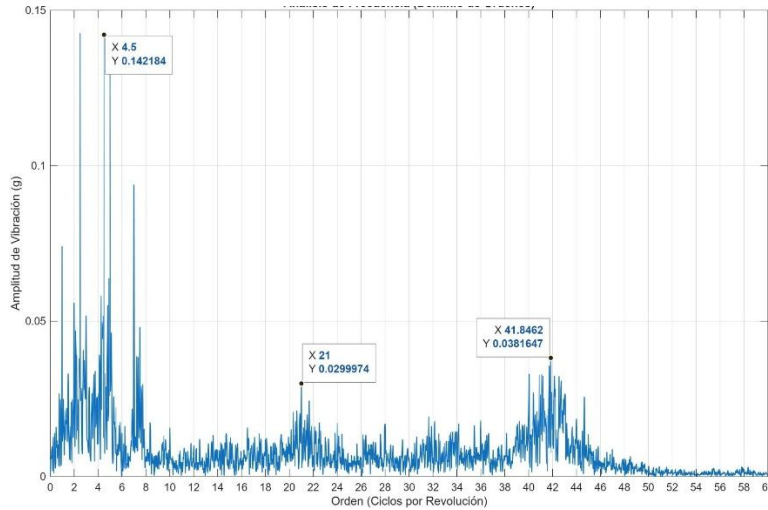
En este sentido, los resultados obtenidos demuestran que la integración de acelerómetros y encoders constituye una herramienta eficaz para caracterizar el patrón vibracional del motor en función de su posición angular. Esta metodología no solo permite comprender el comportamiento dinámico del sistema, sino que también establece una base sólida para futuros análisis orientados al monitoreo de condición y diagnóstico de fallas.

4.3 Aplicación de FFT a los Datos Obtenidos

Como primer paso, se realizó un tratamiento previo de los datos con el objetivo de asegurar su calidad y coherencia para el análisis. Posteriormente, se procedió a extraer características relevantes de los espectros, tales como amplitudes dominantes, como se muestra en la **Figura 24**. Estas características permiten describir de manera más clara el comportamiento vibracional del motor y sirven como base para el proceso de clasificación.



Figura 24. Gráfica de Análisis FFT con ciclos (órdenes)



4.4 Caracterización Vibracional

A partir de las tablas de caracterización vibracional **Tabla 8 y 9** obtenidas del motor en dos condiciones operativas buen estado y mal estado, se determinaron los parámetros representativos del comportamiento dinámico del sistema.

Tabla 8. Caracterización Vibracional BE

VARIABLES	Órdenes	Amplitud
Armónico 1	4.724	0.121
Armónico 2	20.799	0.033
Armónico 3	41.593	0.052

Tabla 9. Caracterización Vibracional ME

VARIABLES	Órdenes	Amplitud
Armónico 1	4.544	0.140
Armónico 2	20.570	0.037
Armónico 3	40.608	0.059

En cada una de estas tablas se identificaron tres armónicos, definidos a partir de dos variables fundamentales. La primera corresponde a la variable X, la cual representa la posición espectral o el orden de la vibración dentro del rango de frecuencias analizado.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

La segunda variable es la amplitud, que cuantifica la intensidad o amplitud de la respuesta vibratoria en cada uno de dichos puntos.

En consecuencia, para cada condición del motor, la caracterización vibratoria permitió establecer una relación directa entre los órdenes (X_1 , X_2 , X_3) y sus respectivos niveles de amplitud (Amplitud 1, Amplitud 2 y Amplitud 3), facilitando así la comparación del comportamiento vibracional entre ambos estados operativos del sistema.

En la caracterización de vibraciones del motor se identificaron tres armónicos principales, los cuales, según el análisis realizado, están asociados a distintos procesos del ciclo de funcionamiento. El primer armónico se relaciona con la operación de las válvulas de escape, el segundo con el proceso de combustión y el tercero con la acción de las válvulas de admisión. Esta correspondencia permite interpretar de manera más clara el origen de las vibraciones y facilita la detección de posibles anomalías en cada etapa del funcionamiento del motor.

4.5 Análisis de Amplitud

Al comparar los valores estadísticos de los armónicos entre las condiciones de buen estado (BE) y mal estado (ME), se observa un patrón consistente de incremento tanto en la amplitud media como en la desviación estándar, lo que evidencia una alteración clara en el comportamiento vibracional del sistema.

En la Amplitud, la media aumenta de 0.121 ordenes (BE) a 0.140 ordenes (ME), lo que representa un incremento aproximado del 15.7%. De igual manera, la desviación estándar pasa de 0.023 a 0.027 órdenes, indicando un aumento cercano al 17.4% en la variabilidad. Este armónico presenta no solo la mayor amplitud absoluta, sino también uno de los incrementos más significativos, lo que lo convierte en el indicador más sensible frente a cambios en la condición mecánica. Esto sugiere que los fenómenos asociados a este armónico (probablemente los más fundamentales del funcionamiento del motor) son los primeros en reflejar degradación.



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



En la Amplitud 2, los cambios son más moderados. La media pasa de 0.033 a 0.037 órdenes, equivalente a un incremento del 12.1%, mientras que la desviación estándar aumenta de 0.007 a 0.008, aproximadamente un 14.3%. Aunque el crecimiento es menor en términos absolutos, el comportamiento sigue la misma tendencia, indicando que este armónico también responde a la condición de fallo, pero con menor sensibilidad que el primero.

Por su parte, la Amplitud 3 presenta un incremento de la media desde 0.052 hasta 0.059 órdenes, lo que corresponde a un 13.5%, y en la desviación estándar de 0.011 a 0.013, es decir, un aumento cercano al 18.2%, siendo este el mayor incremento relativo en dispersión entre los tres armónicos. Esto indica que, aunque su amplitud no es la más alta, su comportamiento se vuelve considerablemente más inestable en condición de mal estado, lo que puede estar asociado a fenómenos más complejos o secundarios dentro del sistema mecánico.

Al realizar una comparación directa entre los distintos armónicos en ambas condiciones, se observa que el orden de magnitud se mantiene constante (Amplitud 1 > Amplitud 3 > Amplitud 2), tanto en buen como en mal estado, lo que indica que la estructura dinámica del sistema no cambia, pero sí su nivel de excitación. La **Tabla 10** corresponde a un resumen estadístico que muestra la media y la desviación estándar de 200 datos en condición de buen estado del motor y 200 datos en condición de mal estado. Sin embargo, en condición de mal estado (ME), la separación entre los valores de amplitud de las amplitudes se incrementa ligeramente, especialmente entre la Amplitud 1 y las demás, evidenciando que este componente se vuelve más dominante. Además, mientras que en BE las amplitudes presentan valores más estables y cercanos entre sí en términos de dispersión, en ME se observa una mayor divergencia en la desviación estándar, destacando el Amplitud 3 como el de mayor incremento relativo en variabilidad. Esto sugiere que, aunque todas las amplitudes responden al deterioro del sistema, lo hacen de manera diferenciada: el Amplitud 1 amplifica principalmente la energía vibracional, mientras que las amplitudes superiores reflejan una mayor complejidad e inestabilidad en


**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**
SUBDECANATO


la respuesta dinámica, permitiendo una caracterización más completa del estado mecánico del sistema.

Tabla 10. Comparación estadística de amplitud en condiciones BE y ME

	Media			Desviación Estándar		
	BE	ME	Diferencia Porcentual	BE	ME	Diferencia Porcentual
Amplitud 1	0.121	0.140	15.7%	0.023	0.027	17.4%
Amplitud 2	0.033	0.037	12.1%	0.007	0.008	14.3%
Amplitud 3	0.052	0.059	13.5%	0.011	0.013	18.2%

4.6 Análisis de Órdenes

A partir del análisis en el dominio de órdenes, se evaluaron las tres variables, correspondientes a los tres puntos de interés identificados en el espectro de vibración. Para cada una de estas variables se consideraron 200 muestras, a partir de las cuales se calcularon la media y la desviación estándar en condiciones de buen estado (BE) y mal estado (ME).

Los resultados obtenidos para la variable Orden 1 muestran que la media en condición BE es de 4.724, mientras que en condición ME disminuye a 4.544, lo que representa una diferencia de -0.180 ($\approx -3.81\%$). En cuanto a la desviación estándar, se observa una reducción de 0.247 en BE a 0.144 en ME, equivalente a una variación de -0.103 ($\approx -41.7\%$).

Para la variable Orden 2, la media presenta un valor de 20.799 en BE y 20.570 en ME, con una diferencia de -0.229 ($\approx -1.10\%$). A diferencia de Orden 1, la desviación estándar aumenta de 0.449 en BE a 0.554 en ME, lo que corresponde a un incremento de 0.105 ($\approx 23.4\%$).

En el caso de la variable Orden 3, la media en condición BE es de 41.593, mientras que en ME disminuye a 40.608, con una diferencia de -0.985 ($\approx -2.37\%$). La desviación



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



estándar también presenta una reducción, pasando de 0.558 en BE a 0.453 en ME, lo que representa una variación de -0.105 (\approx -18.8%).

De manera general, se observa que las tres variables presentan una disminución en sus valores medios en condición de mal estado como se observa en la **Tabla 11**. En relación con la dispersión, el comportamiento es diferenciado: las variables Orden 1 y Orden 3 muestran una reducción en la desviación estándar, mientras que Orden 2 presenta un incremento en su variabilidad.

Tabla 11. Comparación de Órdenes entre Buen Estado (BE) y Mal Estado (ME)

Variable	Media			Desviación Estándar		
	BE	ME	Diferencia Porcentual	BE	ME	Diferencia Porcentual
X1	4.724	4.544	-3.81%	0.247	0.144	-41.7%
X2	20.799	20.570	-1.10%	0.449	0.554	23.4%
X3	41.593	40.608	-2.37%	0.558	0.453	-18.8%

4.7 Análisis Estadístico de Datos de Amplitud y Ángulo

La **Figura 25** presenta un fragmento de la matriz de resultados generada a partir del procesamiento de los datos experimentales. En esta tabla se observan los parámetros estadísticos calculados para cada una de las muestras analizadas, incluyendo valores como RMS, varianza, media, mediana, curtosis, moda, asimetría, media cuadrática y desviación estándar. Cada fila corresponde a una muestra individual, mientras que la columna “ESTADO” permite identificar la condición del motor.



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



Figura 25. Resultados de análisis estadístico

RMS	Varianza	Media	Mediana	Curtosis	Moda	Asimetría	Mediacuadratica	Desviacion_estandar	ESTADO
406.045705	45717.7051	345.190191	334.824	1.73836893	134.777	0.099629735	406.0457046	213.8169896	BE
413.721062	46823.9885	352.621622	340.801	1.71695769	135.724	0.086279545	413.7210624	216.3885129	BE
397.467775	44628.1236	336.679887	308.809	1.78129709	133.414	0.200907083	397.4677746	211.2536949	BE
412.778136	46219.5213	352.373575	332.715	1.74159135	134.324	0.108049395	412.7781358	214.9872585	BE
396.987908	43831.2399	337.296579	312.324	1.84541592	143.647	0.193095811	396.9879081	209.359117	BE
402.263157	47344.2953	338.337467	316.543	1.70704108	139.666	0.177009742	402.2631573	217.5874428	BE
397.398951	43589.391	338.138069	305.293	1.8083808	136.944	0.220572629	397.3989511	208.7807246	BE
393.630386	42069.4663	335.970541	303.535	1.87550561	132.563	0.236086578	393.6303861	205.1084258	BE
392.154424	44211.5105	331.02026	300.371	1.82306636	131.806	0.240935011	392.1544245	210.2653337	BE
399.052351	45023.3431	337.964912	308.809	1.78703959	130.687	0.207352194	399.0523512	212.1870475	BE
402.700257	45971.2985	340.876901	315.84	1.75211228	131.231	0.178804051	402.700257	214.4091847	BE
388.594461	44263.7629	326.71505	296.152	1.81261949	134.398	0.269355773	388.5944612	210.3895504	BE
406.232903	47376.0579	343.001463	320.059	1.73505849	135.887	0.158521515	406.2329032	217.6604187	BE
412.198016	48796.5142	348.010929	330.957	1.67890836	134.44	0.112326525	412.1980162	220.8993305	BE
393.075704	47604.5527	326.963072	297.207	1.74587287	136.968	0.248542193	393.0757044	218.1846758	BE
404.788495	48922.5856	339.016311	317.949	1.6901655	133.408	0.159870402	404.7884953	221.1845059	BE
409.355201	46223.7566	348.351535	326.387	1.76430551	137.943	0.11725529	409.3552007	214.9971084	BE
406.168847	47939.8425	342.102602	318.652	1.72032137	129.965	0.159753082	406.1688475	218.9516899	BE
406.093854	47452.311	342.725544	321.113	1.73390495	135.454	0.150177831	406.0938538	217.8355137	BE
400.929996	47174.4804	337.003364	313.73	1.74099137	138.154	0.183285651	400.9299961	217.1968701	BE

Es importante destacar que este procedimiento se realizó de manera independiente para cada tipo de señal, generándose tablas específicas tanto para los datos de vibración como para los datos de ángulo. Esta separación permite un análisis más claro y detallado del comportamiento de cada variable, facilitando la identificación de patrones característicos en función del estado del motor.

Este formato de organización permite visualizar de manera estructurada cómo varían los indicadores estadísticos entre muestras, evidenciando pequeñas fluctuaciones propias del comportamiento dinámico del sistema. Asimismo, esta matriz constituye la base para el análisis posterior y la implementación de técnicas de diagnóstico, ya que resume de forma compacta la información más relevante extraída de las señales de vibración y ángulo.

4.7.1 Comparación de Resultados Estadísticos de Datos de Vibración

En la **Tabla 12**, para los valores en buen estado (BE), se presentan los valores promedio (media) y su respectiva desviación estándar para cada uno de los parámetros estadísticos calculados a partir de las muestras. Se observa que el valor RMS y la media cuadrática coinciden en 2.905, lo cual es consistente, ya que ambos representan la magnitud efectiva de la señal. La media (2.876) y la mediana (2.877) son muy cercanas


**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**
SUBDECANATO


entre sí, lo que indica una distribución equilibrada de los datos sin presencia de sesgos importantes.

Tabla 12. Comparación de resultados estadísticos de amplitud en BE y ME

Resultado Amplitud	Buen estado		Mal Estado		Diferencia Porcentual	
	Media	Desviación Estándar	Media	Desviación Estándar	Media	Desviación Estándar
RMS	2.905	0.068	2.866	0.065	1.33 %	3.71 %
VARIANZA	0.162	0.023	0.167	0.016	2.85 %	27.77 %
MEDIA	2.876	0.071	2.836	0.069	1.39 %	3.67 %
MEDIANA	2.877	0.084	2.846	0.086	1.07 %	1.62 %
CURTOSIS	2.333	0.086	2.337	0.036	0.16 %	57.61 %
MODA	2.912	0.357	2.857	0.229	1.88 %	35.34 %
ASIMETRIA	0.028	0.106	-0.025	0.114	190.7 %	7.07 %
DESVIACION ESTANDAR	0.402	0.028	0.408	0.020	1.54 %	27.58 %

Por otro lado, la varianza (0.162) y la desviación estándar global (0.402192) reflejan una baja dispersión en la señal de vibración, lo cual es característico de un motor operando en condiciones normales. La asimetría (0.028) cercana a cero confirma que la distribución es prácticamente simétrica, mientras que la curtosis (2.333) sugiere una distribución sin picos extremos, es decir, con un comportamiento estable y sin eventos anómalos significativos.

Por su parte, para los valores en mal estado (ME) se observan cambios sutiles pero importantes en los parámetros. El valor RMS disminuye ligeramente a 2.866, al igual que la media (2.836) y la mediana (2.846), lo que indica una leve reducción en la magnitud promedio de la señal. Sin embargo, la varianza aumenta a 0.167 y la desviación estándar global a 0.408, lo que evidencia una mayor dispersión en los datos, asociada a un comportamiento más irregular de la vibración.

La asimetría cambia de signo, tomando un valor negativo (-0.025), lo que indica una ligera inclinación de la distribución hacia valores menores. Además, aunque la curtosis (2.337) se mantiene cercana a la del buen estado, su ligera variación sugiere

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

cambios en la forma de la distribución. En conjunto, estos resultados reflejan la presencia de perturbaciones en la señal vibratoria cuando el motor se encuentra en condición de falla.

Al analizar los porcentajes de cambio mostrados en la **Tabla 12**, entre el Buen Estado (BE) y el Mal Estado (ME), se observa que los parámetros asociados a la media presentan variaciones relativamente pequeñas, generalmente del orden del 1 % al 2 %, como es el caso del RMS (-1.33 %), la media (-1.39 %) y la mediana (-1.07 %), lo que indica que el nivel promedio de la señal de vibración se mantiene prácticamente constante incluso en condición de falla. Sin embargo, existen excepciones notables como la asimetría, que presenta una variación significativa del -190.7 %, debido al cambio de signo, evidenciando una modificación importante en la forma de la distribución. Por otro lado, al analizar la desviación estándar, se identifican cambios mucho más pronunciados, destacando la reducción en la varianza (-27.77 %), la curtosis (-57.61 %) y la moda (-35.34 %), lo que refleja una alteración considerable en la dispersión y la forma de los datos. En conjunto, esta comparación pone en evidencia que, aunque los valores medios no varían de manera significativa, los parámetros relacionados con la variabilidad y distribución de la señal son mucho más sensibles a la presencia de fallas, convirtiéndose en indicadores clave para el diagnóstico del estado del motor.

4.7.2 Comparación de Resultados Estadísticos de Datos de Ángulo

En la **Tabla 13**, en los apartados correspondiente al ángulo en Buen Estado (BE) se presentan los valores promedio y la desviación estándar de los parámetros estadísticos calculados. Se observa que el valor RMS alcanza 401.31, lo que refleja la magnitud de la señal. La media (339.53) y la mediana (314.27) muestran una diferencia moderada, lo que indica cierta dispersión en los datos, propia del comportamiento cíclico del ángulo de giro. La varianza es de 45 776.7 y la desviación estándar global de 213.90, valores que evidencian una variabilidad considerable, pero esperada debido al rango completo de operación del ángulo (0° a 720°).


**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**
SUBDECANATO

Tabla 13. Comparación de resultados estadísticos de ángulo en BE y ME

Resultado Ángulo	Buen estado		Mal Estado		Diferencia Porcentual	
	Media	Desviación Estándar	Media	Desviación Estándar	Media	Desviación Estándar
RMS	401.31	6.868	407.15	7.102	1.45 %	3.40 %
VARIANZA	45 776.7	1 938.2	46 183.2	1 888.3	0.89 %	2.58 %
MEDIA	339.53	6.356	345.79	7.907	1.84 %	24.45 %
MEDIANA	314.21	11.21	324.88	11.57	3.38 %	3.27%
CURTOSIS	1.771	0.055	1.740	0.028	1.75 %	49.10 %
MODA	134.20	3.466	193.19	3.810	43.96 %	9.95 %
ASIMETRIA	0.183	0.049	0.140	0.048	23.5 %	1.83 %
DESVIACION ESTANDAR	213.90	4.549	214.88	2.548	0.46 %	43.98%

En cuanto a la forma de la distribución, la asimetría (0.183) indica una ligera inclinación hacia la derecha, mientras que la curtosis (1.771) sugiere una distribución sin picos pronunciados. La moda (134.206) muestra el valor más frecuente dentro de la distribución, aunque alejado de la media, lo cual es consistente con la naturaleza no uniforme del movimiento angular.

Por otro lado, en los apartados del ángulo en Mal Estado (ME), se observan variaciones en los parámetros que reflejan cambios en el comportamiento del motor. El valor RMS aumenta a 407.15, al igual que la media (345.79) y la mediana (324.88), lo que indica un ligero incremento en la magnitud general de la señal. La varianza (46 183.21) y la desviación estándar (214.88) también aumentan, evidenciando una mayor dispersión en los datos bajo condición de falla.

La asimetría disminuye a 0.140, manteniéndose positiva pero más cercana a una distribución simétrica, mientras que la curtosis (1.740) presenta una ligera reducción, indicando cambios sutiles en la forma de la distribución. Un aspecto destacable es el incremento en la moda (193.19), lo que sugiere un desplazamiento en los valores más frecuentes del ángulo.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

Al comparar ambas condiciones, se observa que los parámetros asociados a la media presentan incrementos moderados, como en el RMS (+1.45 %), la media (+1.84 %) y la mediana (+3.38 %), lo que indica un leve cambio en la posición central de los datos. Sin embargo, los cambios más relevantes se encuentran en los parámetros de dispersión, donde la desviación estándar presenta un incremento cercano al +0.46 % y la varianza un aumento de aproximadamente +0.89 %, reflejando una mayor variabilidad en el estado de falla.

En cuanto a la forma de la distribución, la asimetría disminuye (-23.5 %) y la curtosis presenta una ligera reducción (-1.75 %), lo que sugiere modificaciones en la distribución de los datos. Además, la moda experimenta un cambio significativo (+43.9 %), evidenciando un desplazamiento importante en los valores más frecuentes.

En conjunto, estos resultados muestran que, aunque los cambios en los valores medios del ángulo no son drásticos, sí existen variaciones en la dispersión y en la distribución de los datos, lo que permite diferenciar entre el estado normal y el estado con falla. Esto confirma que los parámetros estadísticos del ángulo, al igual que los de vibración, aportan información relevante para el diagnóstico del estado del motor.

4.8 Análisis de Árbol de Decisión

En el presente apartado se implementó un código en el entorno de MATLAB con el objetivo de procesar y analizar las señales de vibración obtenidas experimentalmente, así como facilitar la interpretación de su comportamiento tanto en el dominio angular como en el dominio de la frecuencia.

El código desarrollado inicia con la limpieza del entorno de trabajo, asegurando que no existan variables residuales que puedan interferir en el análisis. Posteriormente, se define una función destinada a la generación de gráficos, la cual permite representar la señal de vibraciones en función del ángulo de giro. Esta visualización resulta fundamental para identificar de manera preliminar patrones, irregularidades y variaciones en la respuesta vibratoria del sistema bajo diferentes condiciones de operación.



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



Adicionalmente, se implementa una función orientada al análisis en frecuencia mediante la Transformada Rápida de Fourier (FFT), adaptada específicamente para datos adquiridos en función del ángulo, los cuales pueden presentar irregularidades en el muestreo. Para ello, el código realiza un preprocesamiento de la señal que incluye el ordenamiento de los datos, la eliminación de valores angulares repetidos mediante promediado, y la generación de una señal angular uniforme a través de interpolación. Este procedimiento permite garantizar la adecuada aplicación del análisis espectral.

Una vez acondicionada la señal, se procede al cálculo de la FFT, obteniendo así el espectro de amplitud en función de la frecuencia angular. Este resultado permite identificar las componentes dominantes de vibración, las cuales están directamente relacionadas con fenómenos mecánicos del motor, tales como la combustión, el movimiento del cigüeñal y la apertura y cierre de válvulas.

Finalmente, el código **Figura 26** aplica este mismo procedimiento a distintos conjuntos de datos experimentales, correspondientes a diferentes condiciones operativas del motor, tales como funcionamiento normal, desconexión de un inyector y operación a un régimen específico de revoluciones. Para cada caso, se generan tanto las gráficas en el dominio angular como sus respectivos espectros de frecuencia, lo que permite realizar una comparación directa del comportamiento vibracional y sustentar el análisis basado en los armónicos previamente identificados.



Figura 26. Código para Árbol de Decisiones

```

C:\Users\ZenBook\Desktop\TESIS\Primer.m
1      clear, clc
2
3      function grafico_vibraciones(angulo, vibraciones, titulo_fig)
4          figure
5          plot(angulo, vibraciones, 'LineWidth', 1.5)
6          grid on
7
8          xlabel('Ángulo (°)')
9          ylabel('Vibraciones (g)')
10         title(titulo_fig)
11     end
12
13     |
14
15     function [f, P1] = fft_angular_irregular(angulo, vibraciones)
16         % FFT_ANGULAR_IRREGULAR
17         % FFT para vibraciones medidas con ángulo no uniforme y repetido
18         %
19         % angulo      -> ángulo en grados (puede tener repetidos)
20         % vibraciones -> vibraciones en g
21         %
22         % f -> frecuencia angular (ciclos/grado)
23         % P1 -> espectro de amplitud (g)
24
25         % Vectores columna
26         angulo = angulo(:);
27         vibraciones = vibraciones(:);
28
29

```

4.8.1 Árbol de Decisión de Amplitud

El árbol de decisión construido emplea como variables predictoras los tres primeros armónicos de la señal: Y1 correspondiente a la amplitud fundamental, Y2 a la segunda amplitud y Y3 a la tercera amplitud. A partir de estos componentes, el modelo genera una estructura jerárquica basada en reglas de decisión definidas por umbrales, lo que permite segmentar el conjunto de datos en función de las características de la señal.

En la raíz del árbol se observa que la primera partición se realiza utilizando el armónico Y1, con un valor umbral cercano a 0.143, lo que indica que este componente posee la mayor capacidad de discriminación inicial. Esta primera división establece dos grandes grupos dentro de los datos, a partir de los cuales se desarrollan subdivisiones sucesivas. En niveles posteriores, el modelo incorpora las amplitudes Y2 y Y3, evidenciando que estos aportan información complementaria para refinar la segmentación. En particular, la amplitud Y2 aparece de manera recurrente en niveles intermedios con valores de corte comprendidos aproximadamente entre 0.03 y 0.05, lo que sugiere su relevancia en la diferenciación de subconjuntos generados a partir del armónico fundamental, mientras que la amplitud Y3 interviene principalmente en niveles



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



más profundos del árbol, permitiendo capturar variaciones más sutiles de la señal mediante umbrales de menor magnitud.

La estructura resultante presenta múltiples niveles de ramificación, lo que evidencia la existencia de relaciones no lineales entre las amplitudes analizadas. Asimismo, la repetición de las variables Y_1 , Y_2 y Y_3 en distintos nodos indica que la interacción entre estos componentes es determinante en la construcción de las reglas de decisión. Cada trayectoria desde la raíz hasta una hoja define una combinación específica de condiciones sobre los valores de las amplitudes, delimitando regiones diferenciadas dentro del espacio de características **Figura 27**.

En términos de desempeño, el modelo basado en amplitudes alcanza una efectividad del 65%, lo que indica una capacidad moderada de clasificación. Este resultado sugiere que, si bien los armónicos permiten capturar información relevante de la señal, su uso exclusivo presenta ciertas limitaciones para representar completamente la variabilidad del sistema analizado.

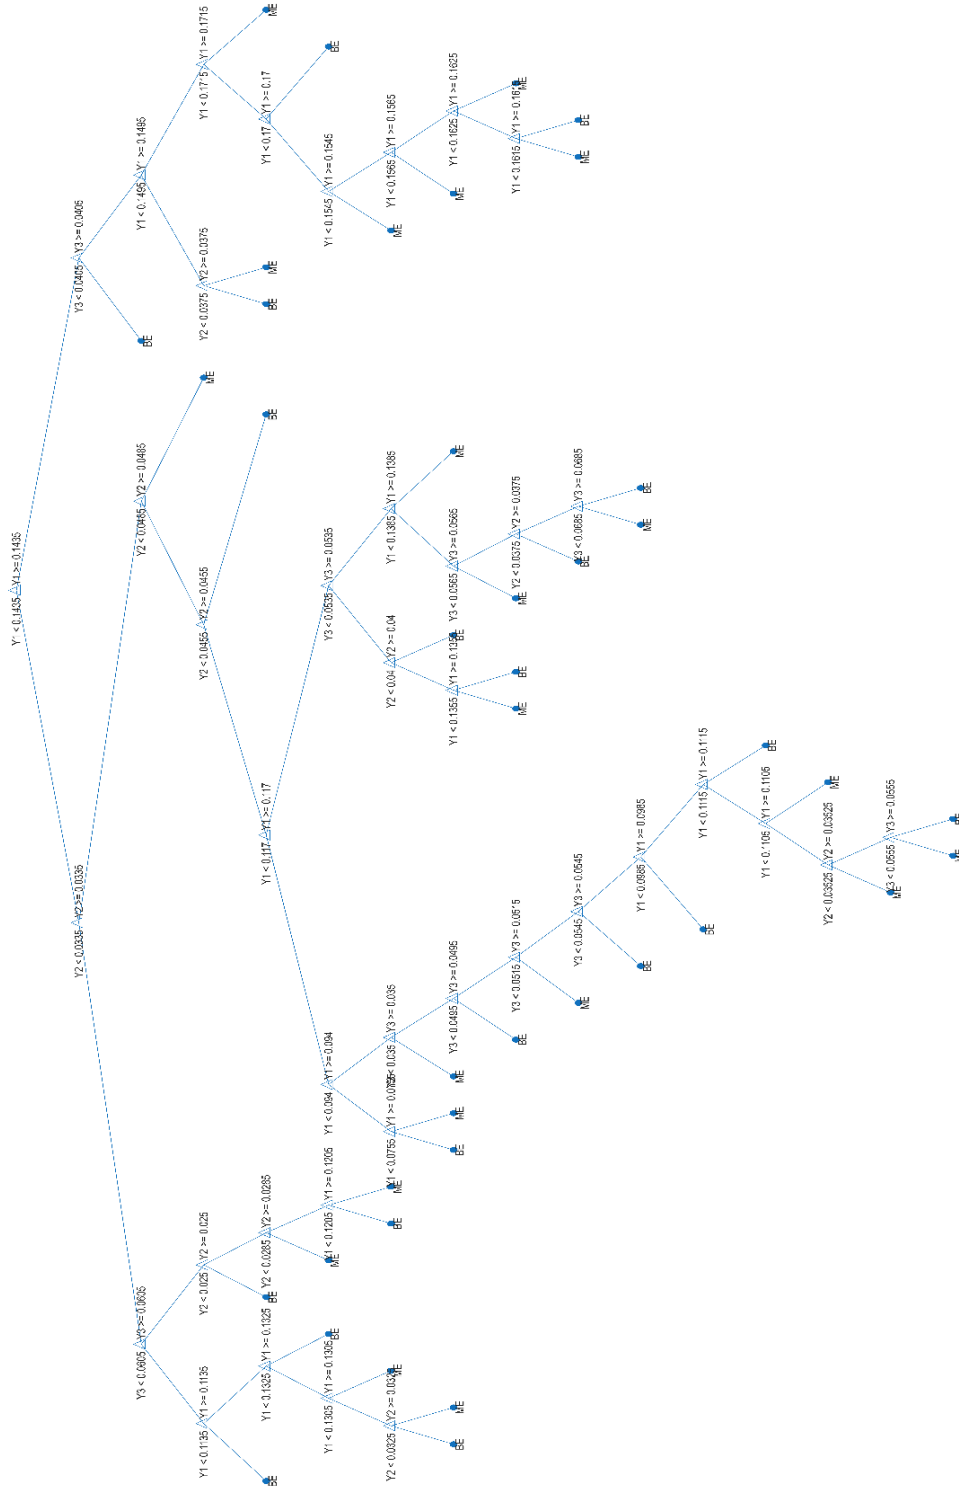


FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



Figura 27. Árbol de decisión de Amplitud





4.8.2 *Árbol de Decisión de Ordenes*

El árbol de decisión desarrollado utiliza como variables predictoras los órdenes X_1 , X_2 y X_3 , los cuales representan componentes característicos de la señal en el dominio de órdenes. A partir de estos parámetros, el modelo establece una serie de reglas de decisión basadas en umbrales que permiten estructurar el conjunto de datos en diferentes niveles jerárquicos.

A diferencia del modelo basado en armónicos, en este caso la variable que domina la partición inicial es el orden X_3 , con un umbral cercano a 41.445. Este comportamiento sugiere que los componentes asociados a órdenes superiores contienen información relevante desde las primeras etapas del proceso de segmentación. A partir de esta división inicial, el árbol desarrolla ramas en las que se combinan sucesivamente los órdenes X_1 y X_2 , generando regiones más específicas dentro del espacio de características.

El orden X_1 aparece principalmente como un criterio de ajuste en niveles intermedios, introduciendo divisiones adicionales en torno a valores cercanos a 4.25 y 4.75. Por su parte, el orden X_2 adquiere mayor protagonismo en niveles más profundos del árbol, donde se observa una mayor densidad de umbrales en intervalos relativamente estrechos, lo que indica una alta sensibilidad del modelo a variaciones pequeñas en este parámetro. Esta distribución de las variables dentro del árbol sugiere que cada orden contribuye de manera diferenciada según el nivel de análisis, permitiendo una segmentación progresivamente más detallada.

La configuración del árbol refleja una estructura menos dependiente de una única variable dominante y más orientada a la combinación de múltiples criterios de decisión. Esto se traduce en una partición más equilibrada del espacio de características, donde las variables interactúan de forma más distribuida a lo largo de las distintas ramas del modelo

Figura 28.

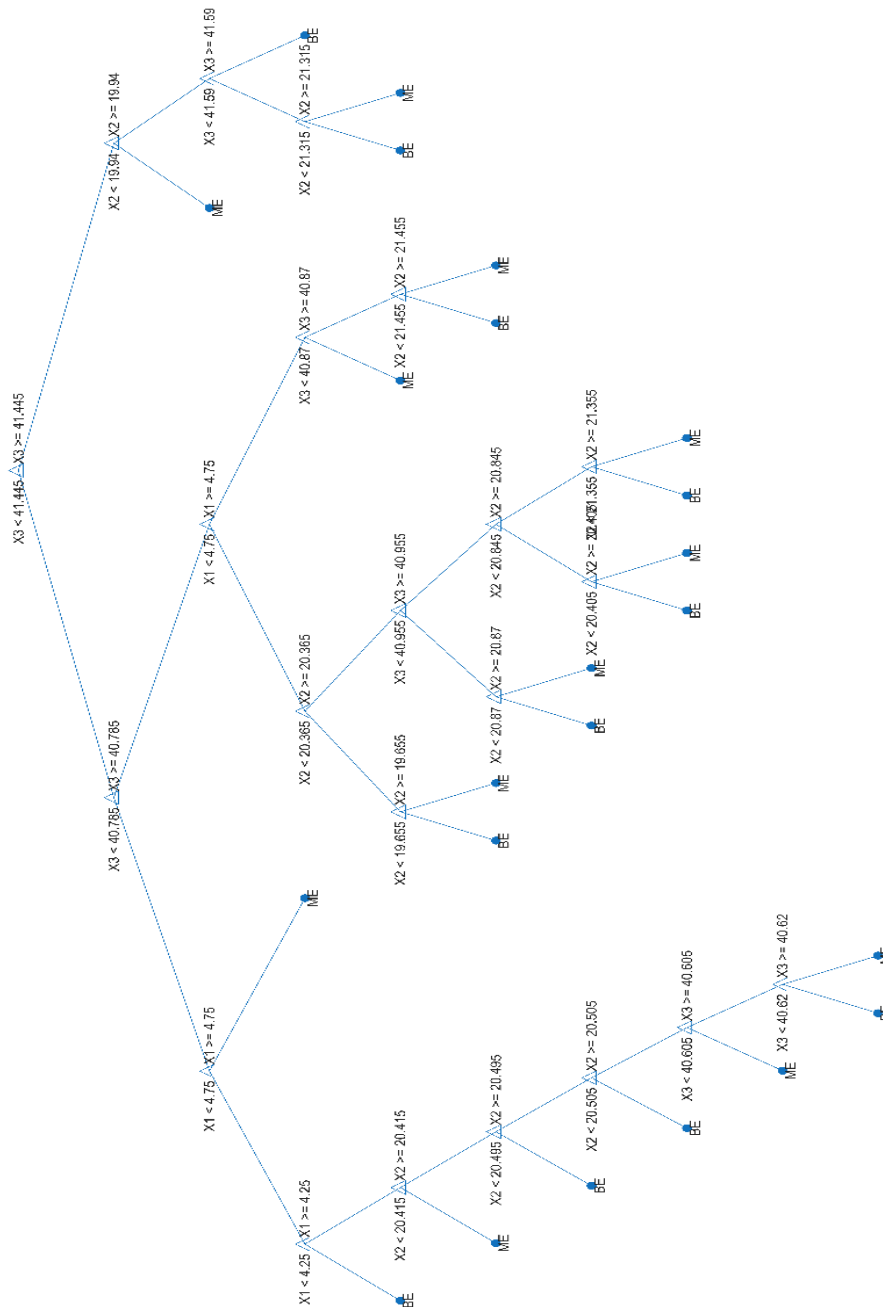


FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



Figura 28. Árbol de Decisión de Ordenes



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

En términos de desempeño, el modelo basado en órdenes alcanza una efectividad del 75%, lo que representa una mejora respecto al modelo basado en armónicos. Este incremento en la efectividad sugiere que la representación en el dominio de órdenes permite capturar con mayor precisión las características relevantes de la señal, favoreciendo una segmentación más consistente dentro del conjunto de datos.

4.8.3 Árbol de Decisión de Variables Estadísticas de Amplitud

El árbol de decisión construido se basa en parámetros estadísticos extraídos de la señal, entre los que se incluyen la curtosis, media, varianza, asimetría, valor RMS y desviación estándar. Cabe destacar que la variable correspondiente a la moda fue excluida del modelo, debido a que la naturaleza cíclica de la señal (720 grados) favorece la repetición frecuente de ciertos valores. Estas repeticiones pueden estar asociadas tanto a la periodicidad propia del sistema como a posibles inconsistencias en la adquisición de datos, lo que reduce su utilidad como descriptor discriminante dentro del modelo.

La estructura del árbol muestra que la curtosis actúa como el criterio inicial de segmentación, con un umbral cercano a 2.27. Este resultado indica que la forma de la distribución de la señal, particularmente su grado de concentración y la presencia de valores extremos, constituye un factor clave en la diferenciación inicial de los datos. A partir de esta primera división, el modelo desarrolla ramas en las que se integran progresivamente otros parámetros estadísticos.

En niveles posteriores, la media adquiere relevancia como variable de partición, estableciendo subdivisiones adicionales que permiten organizar los datos en función de su tendencia central. A medida que se profundiza en el árbol, aparecen variables como la asimetría y la varianza, las cuales permiten caracterizar la dispersión y la forma de la distribución de la señal. La asimetría introduce criterios relacionados con la distribución de los valores respecto a la media, mientras que la varianza y la desviación estándar aportan información sobre la variabilidad interna de los datos.

Por otro lado, el valor RMS se incorpora en determinadas ramas como un indicador complementario de la magnitud global de la señal, contribuyendo a la definición



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



de regiones específicas dentro del espacio de características. La combinación de estos parámetros a distintos niveles del árbol evidencia una estrategia de segmentación basada en múltiples descriptores estadísticos que capturan diferentes aspectos del comportamiento de la señal **Figura 29**.

La configuración del árbol presenta una distribución heterogénea de las variables, lo que indica que distintos parámetros adquieren relevancia dependiendo del nivel de análisis y de la región del espacio de características considerada. En este sentido, el modelo no depende de un único descriptor dominante, sino que integra de manera conjunta información relacionada con la forma, dispersión y magnitud de la señal.

En términos de desempeño, el modelo alcanza una efectividad del 77.5%, lo que refleja una adecuada capacidad para estructurar y segmentar los datos a partir de los parámetros estadísticos seleccionados.

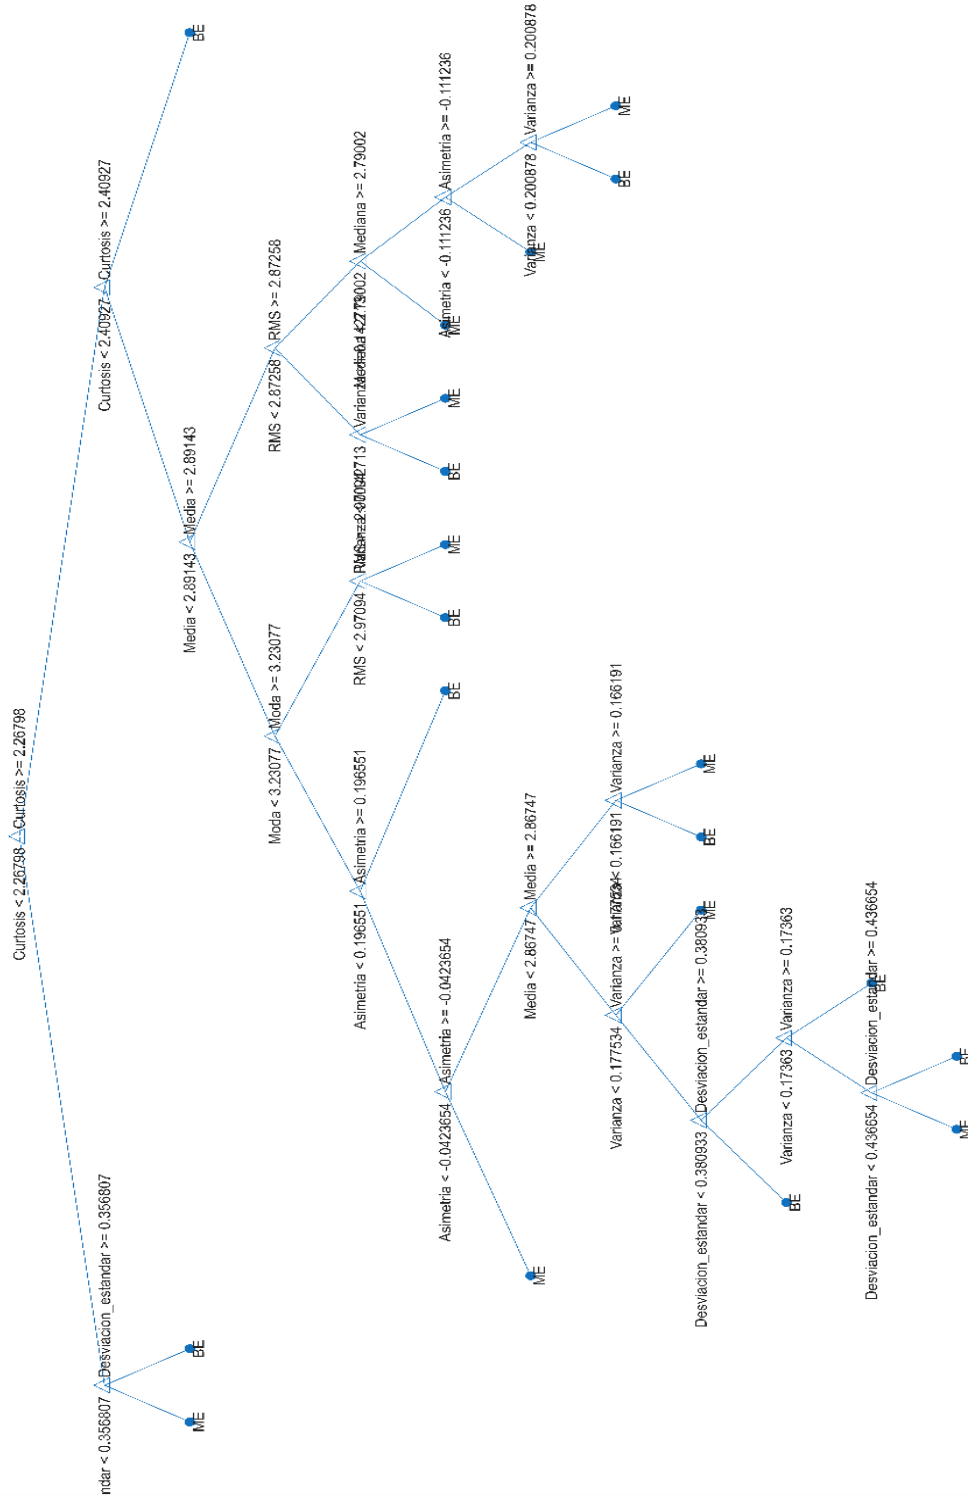


FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



Figura 29. Árbol de Decisión Variables de Amplitud





4.8.4 *Árbol de Decisión de Variables Estadísticas de Ángulo*

El árbol de decisión desarrollado se construye a partir de parámetros estadísticos obtenidos de la señal angular, incluyendo la mediana, media, curtosis, asimetría, varianza, valor RMS y desviación estándar. Estos descriptores permiten caracterizar la señal desde diferentes perspectivas, tales como su tendencia central, dispersión y forma de distribución, facilitando la identificación de patrones dentro del conjunto de datos.

En este modelo, la variable que define la primera partición es la mediana, con un umbral cercano a 324.556, lo que indica que este parámetro constituye el punto de partida para la segmentación inicial. A partir de esta división, el árbol se ramifica incorporando principalmente la asimetría y el valor RMS, lo que sugiere que la distribución de los valores y la magnitud de la señal juegan un papel relevante en las primeras etapas de análisis.

A medida que se profundiza en la estructura del árbol, se integran variables adicionales como la curtosis, la varianza y la media, las cuales permiten una caracterización más detallada de los datos. La curtosis introduce criterios asociados a la concentración de los valores y la presencia de extremos, mientras que la varianza y la desviación estándar aportan información sobre la dispersión. Por su parte, la media aparece en diferentes niveles como un elemento de ajuste que contribuye a delimitar regiones específicas dentro del espacio de características.

La configuración del árbol muestra una distribución equilibrada de las variables a lo largo de sus ramas como se puede observar en la **Figura 30**, lo que evidencia que la segmentación no depende exclusivamente de un único parámetro, sino de la combinación de múltiples descriptores estadísticos. Esta interacción entre variables permite capturar tanto comportamientos globales como variaciones locales de la señal angular.

Asimismo, la presencia de múltiples niveles de decisión indica que la estructura del modelo responde a relaciones complejas entre los parámetros considerados, permitiendo una partición progresiva del espacio de datos. Cada trayectoria dentro del



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



árbol define un conjunto particular de condiciones que describen distintas configuraciones de la señal.

En términos de desempeño, el modelo alcanza una efectividad del 70.83%, lo que refleja una capacidad adecuada para organizar y segmentar la información a partir de los parámetros estadísticos asociados a los ángulos.



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



En una primera etapa, se realizó un análisis comparativo utilizando árboles de decisión con el objetivo de evaluar el desempeño de distintos conjuntos de variables extraídas del sistema. Como se muestra en la **Tabla 14**, se consideraron variables relacionadas con la amplitud, órdenes, estadísticas de vibración y estadísticas de ángulo, obteniendo diferentes valores de eficiencia para cada caso. Este análisis permitió identificar que el conjunto de variables estadísticas de vibración, en específico la variable de curtosis, presentó el mayor porcentaje de eficiencia, alcanzando un valor de 77.5 %, lo que indica una mejor capacidad para representar el comportamiento del sistema en comparación con las demás alternativas evaluadas.

A partir de estos resultados, se seleccionó este conjunto de variables como base para la siguiente etapa del proceso. De esta manera, se procedió a realizar el entrenamiento de modelos de aprendizaje automático utilizando únicamente las variables que demostraron mayor eficiencia en el análisis previo. Esta selección permitió enfocar el proceso de entrenamiento en la información más relevante, optimizando el desempeño de los modelos y reduciendo la influencia de variables menos significativas.

Tabla 14. Comparación de Eficiencia de Árboles de Decisión

Árbol de Decisión	Eficiencia (%)
Amplitud	65
Órdenes	75
VARIABLES ESTADÍSTICAS DE VIBRACIÓN	77.5
VARIABLES ESTADÍSTICAS DE ÁNGULO	70.83

4.9 Evaluación y Selección del modelo de Aprendizaje Autónomo

Una vez realizado el análisis mediante árbol de decisión para cada grupo de datos, se procedió al entrenamiento y validación de los modelos de aprendizaje autónomo. Este proceso se llevó a cabo en dos etapas: primero, utilizando el conjunto completo de datos,



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



y posteriormente, empleando únicamente la variable seleccionada por el árbol de decisión. Como resultado, se obtuvieron tablas comparativas para cada prueba, en las cuales se presentan el porcentaje de precisión y el costo total de cada modelo de aprendizaje, entendiendo este último como los recursos requeridos para su implementación.

Tras el proceso de entrenamiento y validación, se observa que varios modelos alcanzan los niveles más altos de precisión, destacándose principalmente aquellos con valores alrededor del 83.25% de eficiencia, fueron 8 modelos con similar porcentaje de eficiencia como se puede observar en la **Tabla 15**.

Tabla 15. Tabla comparativa eficiencia de modelos

Variables de Aprendizaje	Numero de Modelo	Nombre del Modelo	Precisión %	Costo de Validación
Armónicos	2.10	Naive Bayes	72	112
	2.4	Discriminant	83.25	67
Ordenes	2.6	Binary GLM	83.25	67
	2.7	Logistic Regression	83.25	67
		Efficient Logistic Regression		
	2.9	Naive Bayes	83.25	67
	2.15	SVM	83.25	67
	2.16	SVM	83.25	67
	2.19	KNN	83.25	67
	2.25	Ensemble	83.25	67
Estadísticos Angulo	2.10	Naive Bayes	82.75	69
Estadísticos Vibraciones	2.10	Naive Bayes	80.5	78
	2.24	Ensemble	80.5	78
Estadísticos Vibraciones Curtosis	2.3	Tree	68.25	127

Posteriormente, se realizó una nueva comparativa considerando el tiempo de entrenamiento como criterio principal, con el objetivo de identificar los modelos más



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



eficientes en términos computacionales. A partir de los resultados obtenidos, se observa que los modelos que presentan los menores tiempos son SVM, KNN y, en menor medida, Ensemble.

En particular, el modelo SVM destaca significativamente, alcanzando el menor tiempo de entrenamiento (alrededor de 0.5 s en su mejor caso) como muestra la **Tabla 16**, lo que lo posiciona como la alternativa más eficiente dentro de esta comparación. De forma similar, KNN también muestra un desempeño favorable, con un tiempo bajo cercano a 1 segundo, lo que lo convierte en una opción rápida y práctica. Por otro lado, aunque el modelo Ensemble tiene un tiempo mayor que los anteriores, sigue siendo considerablemente más eficiente que modelos como regresión logística o análisis discriminante.

Tabla 16. Tabla de selección modelo más eficiente

Número de Modelo	Nombre de modelo	Tiempo de entrenamiento
2.4	Linear Discriminant	18.98 s
2.6	Binary GLM Logistic Regression	17.72 s
2.7	Efficient Logistic Regression	16.28 s
2.9	Naive Bayes	14.38 s
2.15	SVM	0.5 s
2.16	SVM	1.89 s
2.19	KNN	1.12 s
2.25	Ensemble	11.15 s

En contraste, los modelos basados en regresión logística y discriminante lineal presentan los mayores tiempos de entrenamiento, superando ampliamente los 15 segundos, lo que implica un mayor costo computacional. Aunque estos modelos pueden ofrecer buen rendimiento en precisión, su tiempo de entrenamiento los hace menos convenientes cuando se prioriza la rapidez.

En conjunto, estos resultados indican que, si el criterio principal es minimizar el tiempo de entrenamiento, SVM se posiciona como la mejor opción como se observa en



la **Tabla 16**, seguido por KNN, ya que ambos logran un equilibrio adecuado entre rapidez y desempeño, facilitando su implementación en escenarios donde el tiempo es un factor crítico.


4.10 Evaluación del Modelo de Clasificación Seleccionado

4.10.1 Diagrama de Dispersión

En la **Figura 31**, los puntos en color azul corresponden a la clase BE, mientras que los puntos en color naranja representan la clase ME. Asimismo, la diferenciación entre aciertos y errores se indica mediante la forma de los marcadores: los círculos representan clasificaciones correctas, mientras que las “X” señalan predicciones incorrectas.

A partir de la distribución observada, se evidencia que el modelo logra una separación razonablemente clara entre ambas clases, especialmente en regiones donde los datos presentan menor solapamiento. Sin embargo, en la zona central del gráfico se aprecia una mayor concentración de errores como se aprecia en la **Figura 31**, lo que coincide con los resultados previamente obtenidos en la matriz de confusión.

Figura 31. Diagrama de Dispersión





FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



Es importante destacar que esta zona intermedia, donde se produce el solapamiento de los datos, corresponde a una región de transición entre el buen estado (BE) y el mal estado (ME). En este intervalo, las características de ambas clases tienden a ser más similares, reflejando un cambio gradual en las condiciones del sistema analizado, en lugar de una separación abrupta entre estados.

En conjunto con los resultados anteriores, esta representación gráfica refuerza la idea de que el modelo tiene un buen desempeño general, pero presenta limitaciones en aquellas regiones donde las clases no están claramente diferenciadas. En particular, en esta zona de transición resulta difícil discernir con total precisión entre el buen estado y el mal estado, lo que explica la presencia de algunas clasificaciones incorrectas. A pesar de ello, la mayoría de los puntos son clasificados correctamente, lo que confirma la consistencia y confiabilidad del modelo en la tarea de clasificación planteada.

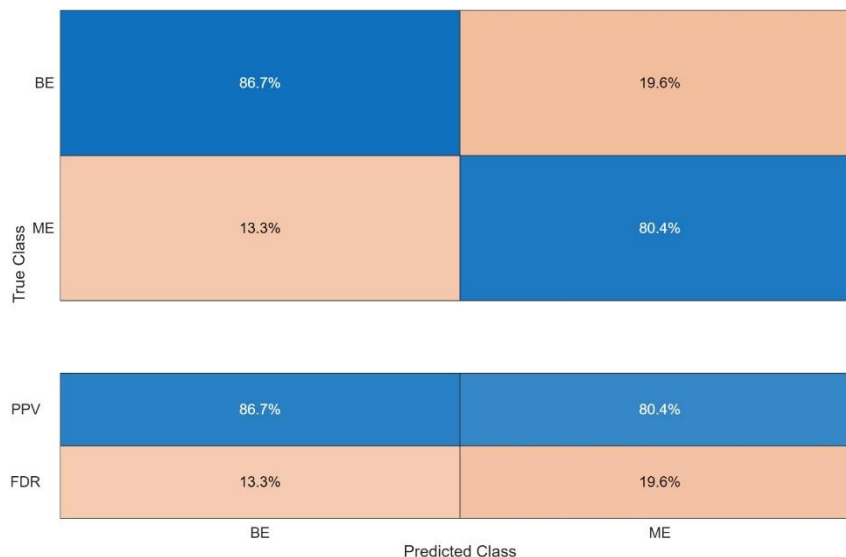
4.10.2 Matriz de Confusión

Como resultado de la validación final del modelo, se obtuvo la matriz de confusión, la cual permite evaluar de manera detallada el desempeño del clasificador en términos de aciertos y errores para cada clase.

En la **Figura 32** se observan dos clases: BE y ME. Los valores ubicados en la diagonal principal representan las clasificaciones correctas, mientras que los valores fuera de la diagonal corresponden a errores de clasificación.



Figura 32. Diagrama de confusión



Para la clase BE, el modelo logra una tasa de acierto del 86.7%, lo que indica que la mayoría de las instancias pertenecientes a esta clase fueron correctamente identificadas. Sin embargo, un 13.3% de los casos de BE fueron clasificados erróneamente como ME. Por otro lado, en la clase ME, el modelo alcanza un 80.4% de acierto, mientras que el 19.6% de las instancias fueron incorrectamente clasificadas como BE.

Adicionalmente, se incluyen métricas complementarias como el PPV (Valor Predictivo Positivo) y el FDR (False Discovery Rate). El PPV muestra valores de 86.7% para BE y 80.4% para ME como se muestra en la **Figura 32**, lo que refleja la proporción de predicciones positivas que realmente son correctas en cada clase. En contraste, el FDR presenta valores de 13.3% y 19.6%, respectivamente, indicando la proporción de predicciones incorrectas dentro de cada clase.

En términos generales, el modelo presenta un buen desempeño, con una mayor capacidad para identificar correctamente la clase BE en comparación con ME. No obstante, se observa una ligera tendencia a confundir instancias de la clase ME como BE, lo que sugiere que existe cierto solapamiento en las características de ambas clases. A pesar de ello, los resultados obtenidos son satisfactorios y evidencian que el modelo es confiable para la tarea de clasificación planteada.

FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO




En complemento al análisis de la matriz de confusión, se presenta la visualización de los datos en un espacio bidimensional definido por las variables X3 y X2, donde se distinguen las predicciones realizadas por el modelo.

4.10.3 Curva PRC

Una vez entrenado el modelo de Máquina de Vectores de Soporte (SVM) con kernel gaussiano medio (Modelo 2.15), se procedió a evaluar su capacidad de clasificación mediante la curva de Precisión-Recall (PR). Esta curva es especialmente útil cuando las clases están desbalanceadas, ya que refleja mejor que la curva ROC el rendimiento real sobre la clase positiva.

En la **Figura 33** se presenta la curva PR de validación para el modelo 2.15. En ella se comparan dos variantes del modelo: BE (PR-AUC = 0.928) y ME (PR-AUC = 0.859). Como puede observarse, el modelo BE supera claramente al ME en términos del área bajo la curva, lo que indica una mejor compensación entre precisión y recall a lo largo de diferentes umbrales de decisión.

Figura 33. Curva Precision-Recall



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

Al analizar la curva punto por punto, se ve que ambos modelos mantienen una precisión muy alta (superior al 0.88) incluso para valores bajos de recall. Por ejemplo, con un recall cercano a 0.04, la precisión del BE es de 0.88, mientras que la del ME es similar (0.88 también). Sin embargo, a medida que el recall aumenta hacia 0.28, la precisión del BE se mantiene más estable y alcanza valores de 1.00 en el punto óptimo de operación, mientras que el ME muestra una ligera tendencia a la baja antes de ese punto.

El punto de operación seleccionado para ambos modelos se encuentra en un recall de aproximadamente 0.28 con una precisión perfecta (1.00). Esto significa que, en ese umbral, el modelo nunca se equivoca cuando predice un positivo, pero solo logra detectar el 28% de los casos positivos reales. En otras palabras, el modelo es extremadamente conservador: prefiere no arriesgar falsos positivos, aunque eso implique dejar muchos positivos sin detectar.

En resumen, la curva PR demuestra que el modelo SVM con kernel gaussiano medio (BE) tiene un excelente desempeño en términos de precisión, con un área bajo la curva de 0.928, superando a la versión ME. La elección del punto de operación dependerá de las necesidades específicas de la aplicación: priorizar precisión o buscar un mayor recall.

4.10.4 Curva ROC

La curva ROC (Receiver Operating Characteristic) obtenida para dos configuraciones del modelo, identificadas como BE (línea azul) y ME (línea naranja), junto con sus respectivos puntos de operación, permite evaluar el desempeño del modelo en términos de la relación entre la tasa de verdaderos positivos (TPR) y la tasa de falsos positivos (FPR).

En primer lugar, se observa que ambas curvas se sitúan claramente por encima de la línea diagonal discontinua (línea de referencia aleatoria), lo que indica que ambos modelos presentan una capacidad predictiva significativamente superior al azar. Este



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



comportamiento confirma que el proceso de entrenamiento fue efectivo y que el modelo logró aprender patrones relevantes en los datos.

Analizando punto por punto, en el rango inicial de FPR cercano a 0, el modelo BE muestra un incremento más rápido en la TPR, alcanzando valores cercanos a 0.6 con muy pocos falsos positivos. Esto sugiere que BE es ligeramente más conservador, priorizando una buena detección inicial con bajo costo de error. En contraste, el modelo ME comienza con un crecimiento más gradual en este mismo rango, indicando una menor sensibilidad inicial.


Sin embargo, a medida que aumenta la tasa de falsos positivos (aproximadamente entre 0.1 y 0.3), el modelo ME presenta un incremento más pronunciado en la TPR, superando levemente al modelo BE en esta región. Esto refleja que ME logra capturar una mayor proporción de verdaderos positivos cuando se permite un mayor margen de error, lo que puede ser deseable dependiendo del contexto del problema.

En cuanto a los puntos de operación marcados en la gráfica, ambos modelos se ubican en una zona de buen equilibrio entre sensibilidad y especificidad. El punto del modelo BE se encuentra aproximadamente en una TPR de 0.78 con FPR cercano a 0.15, mientras que el modelo ME alcanza una TPR ligeramente superior (~ 0.87) con un FPR también mayor (~ 0.23). Esto indica que ME es más agresivo en la detección, a costa de un incremento en falsos positivos.

Respecto al desempeño global, ambos modelos presentan un valor de AUC (Área Bajo la Curva) prácticamente idéntico, aproximadamente 0.9052, lo que indica una capacidad discriminativa muy alta y equivalente entre ambos enfoques. Este resultado sugiere que, en términos generales, ninguno de los modelos domina claramente al otro, y la elección entre ellos dependerá del balance deseado entre sensibilidad y especificidad. Este comportamiento se observa claramente en la **Figura 34**, donde se aprecia tanto la cercanía entre las curvas como la ubicación de los puntos de operación.



Figura 34. Curva ROC



4.11 Validación de modelo de aprendizaje

Como siguiente paso, se implementó un código de validación final utilizando el modelo previamente entrenado, con el objetivo de evaluar su desempeño sobre un conjunto de datos de prueba. En esta etapa, se emplea la función `predictFcn`, la cual permite obtener tanto las predicciones del modelo como las probabilidades asociadas a cada clase para cada muestra evaluada como se muestra en la **Figura 35**.

Figura 35. Código de uso para predicción

```
[resultado, probabilidad] = trainedModel.predictFcn(Datos_De_Prueba);

for i = 1:length(resultado)
    fprintf('Muestra %d -> Estado: %s | Confianza: %.2f%%\n', ...
        i, char(resultado(i)), max(probabilidad(i,:))*100);
end
```

El código recorre cada uno de los resultados obtenidos mediante un ciclo `for`, mostrando en pantalla información detallada por cada muestra. En particular, para cada dato de prueba se imprime: el número de muestra, el estado o clase predicha por el modelo



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



y el nivel de confianza asociado a dicha predicción. Esta confianza se calcula tomando la probabilidad máxima entre todas las clases posibles y expresándola en porcentaje.

De manera general, este procedimiento permite no solo verificar qué tan acertadas son las predicciones del modelo, sino también medir el grado de seguridad con el que se realizan. Esto resulta fundamental en la validación final, ya que un modelo no solo debe ser preciso, sino también consistente en sus decisiones. En este sentido, valores de confianza altos indican que el modelo distingue claramente entre las clases, mientras que valores bajos podrían sugerir ambigüedad o necesidad de mejora.

Una vez entrenado el modelo, se procedió a evaluar su desempeño real utilizando un conjunto independiente de 100 muestras no empleadas durante la fase de entrenamiento como se observa en el **Anexo 10**. Este conjunto de prueba estuvo compuesto por 50 muestras correspondientes a la clase BE (buen estado) y 50 muestras correspondientes a la clase ME (mal estado), garantizando así un balance adecuado para evaluar el comportamiento del modelo en ambas categorías. Para cada muestra, se aplicó la función `predictFcn`, la cual devuelve no solo la clase estimada (Estado: BE o ME), sino también el nivel de confianza asociado, entendido como el valor máximo de probabilidad entre todas las clases posibles, expresado en porcentaje. Este enfoque permite analizar tanto la precisión del modelo como el grado de seguridad con el que realiza cada clasificación, aspecto fundamental en aplicaciones donde se requiere consistencia en la toma de decisiones.

Los resultados obtenidos mostraron un nivel de confianza promedio del 87.9% para la clase BE y del 90.2% para la clase ME, con un valor global promedio del 89.05%. Estos valores indican que, en términos generales, el modelo clasifica las nuevas muestras con un grado de certeza alto y bastante equilibrado entre ambas clases. La confianza mínima observada fue del 51.7% (correspondiente a una muestra BE), mientras que la máxima alcanzó el 99.5% (en una muestra ME), lo cual demuestra que el modelo es capaz de emitir predicciones extremadamente seguras en la mayoría de los casos, aunque existen algunos pocos ejemplos con mayor ambigüedad.



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



Al analizar individualmente las predicciones, se observa que la mayoría de las muestras presentan niveles de confianza superiores al 90%, como ocurre en numerosas muestras de ambos grupos. Estos casos reflejan situaciones donde el modelo distingue claramente la clase a partir de las características de entrada. Por el contrario, se identificaron muestras con confianza baja, inferior al 60%, como las muestras 5 (57.8%), 19 (54.3%), 32 (51.7%), 50 (59.9%), 53 (54.7%) y 81 (52.7%) en la clase BE, así como las muestras 36 (64.7%), 58 (53.5%) y 71 (66.8%) en la clase ME. Estos valores reducidos pueden deberse a que dichas muestras se ubican cerca de la frontera de decisión entre ambas clases, o bien a la presencia de ruido o datos atípicos en el conjunto de prueba.

Es importante destacar que, aunque existen algunas predicciones con confianza baja, estas representan menos del 10% del total de muestras. La gran mayoría de las clasificaciones se realizan con un nivel de certeza superior al 80%, lo cual respalda la fiabilidad del modelo. Valores de confianza altos indican que el modelo ha aprendido patrones suficientemente separables entre las clases BE y ME como se observa en la **Figura 36**, mientras que los casos de confianza intermedia o baja ofrecen oportunidades para futuras mejoras, como la inclusión de más muestras en regiones de ambigüedad o el refinamiento de las características de entrada.

Figura 36. Validación de modelo

Muestra 1 -> Estado: BE Confianza: 98.29%
Muestra 2 -> Estado: BE Confianza: 93.45%
Muestra 3 -> Estado: BE Confianza: 95.80%
Muestra 4 -> Estado: BE Confianza: 97.19%
Muestra 5 -> Estado: BE Confianza: 57.78%
Muestra 6 -> Estado: BE Confianza: 99.39%
Muestra 7 -> Estado: BE Confianza: 97.23%
Muestra 8 -> Estado: ME Confianza: 92.68%
Muestra 9 -> Estado: BE Confianza: 97.27%
Muestra 10 -> Estado: BE Confianza: 96.25%
Muestra 11 -> Estado: BE Confianza: 97.76%
Muestra 12 -> Estado: BE Confianza: 98.07%
Muestra 13 -> Estado: ME Confianza: 88.55%
Muestra 14 -> Estado: BE Confianza: 98.96%
Muestra 15 -> Estado: BE Confianza: 95.94%
Muestra 16 -> Estado: BE Confianza: 87.89%
Muestra 17 -> Estado: BE Confianza: 90.37%
Muestra 18 -> Estado: ME Confianza: 97.47%
Muestra 19 -> Estado: BE Confianza: 54.34%
Muestra 20 -> Estado: ME Confianza: 82.25%

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO****CAPÍTULO V****CONCLUSIONES Y RECOMENDACIONES****5.1 Conclusiones**

Se implementó exitosamente un sistema de adquisición de datos basado en el uso conjunto de acelerómetros y un encoder, lo que permitió registrar de manera simultánea señales de vibración y posición angular. Esta integración resultó fundamental, ya que posibilitó establecer una relación directa entre los fenómenos vibratorios y el ciclo de funcionamiento del sistema. Durante esta etapa se logró recopilar un total de 400 muestras, de las cuales 200 corresponden a condiciones de buen estado (BE) y 200 a condiciones de mal estado (ME), garantizando un conjunto de datos balanceado. Se obtuvo un total de 21 313 600 datos, proporcionando un alto nivel de detalle en la representación de las señales. Cabe recalcar que estas muestras fueron obtenidas a partir de los puntos de mayor interés del funcionamiento del motor, específicamente asociados a procesos como la combustión, el trabajo del motor y la operación de las válvulas, lo cual permitió capturar información altamente representativa del comportamiento del sistema.

El procesamiento de las señales incluyó la aplicación de técnicas como la Transformada Rápida de Fourier (FFT) y el análisis de series temporales, lo que permitió extraer características relevantes de las señales adquiridas. Estas características evidenciaron diferencias claras entre los estados de operación, facilitando la identificación de patrones distintivos en cada condición. No obstante, también se observaron zonas donde las características tienden a solaparse, reflejando la existencia de regiones de transición entre el buen y el mal estado, lo que evidencia la complejidad inherente al proceso de detección de fallas en sistemas reales. La caracterización vibracional muestra que el Armónico 1 presenta la mayor amplitud en ambos estados (BE: 0.121; ME: 0.140), posicionándose como la variable más representativa para la discriminación entre condiciones, al reflejar de manera más clara las variaciones en la energía vibracional del sistema. Por otro lado, los armónicos 2 y 3 presentan amplitudes considerablemente menores y más cercanas entre sí, lo que sugiere una menor capacidad

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

discriminativa y una mayor propensión al solapamiento entre estados. Asimismo, aunque los valores de órdenes se mantienen relativamente consistentes entre BE y ME, las diferencias en amplitud, especialmente en el primer armónico, refuerzan su relevancia como indicador clave para la identificación del estado operativo.

Se realizó una evaluación comparativa de distintos algoritmos de aprendizaje autónomo, considerando métricas como precisión, costo de validación y tiempo de entrenamiento. Los resultados mostraron que varios modelos alcanzaron desempeños similares en términos de precisión, alrededor del 83.25% en la variable de órdenes, destacándose el modelo SVM por presentar un menor tiempo de entrenamiento, aproximadamente de 0.5 s.

La validación del modelo mediante un conjunto independiente de datos confirmó su capacidad de generalización. Se obtuvo un nivel de confianza promedio global del 89.05%, con valores equilibrados entre ambas clases (87.9% para BE y 90.2% para ME), lo que indica que el modelo es capaz de clasificar nuevas muestras con un alto grado de certeza. Sin embargo, en las regiones de transición entre estados se presenta una mayor probabilidad de error, lo cual es consistente con el comportamiento observado en la matriz de confusión y en la representación gráfica de los datos. En estas zonas resulta más difícil distinguir entre el buen estado y el mal estado debido a la similitud en sus características.

5.2 Recomendaciones

A partir de los resultados obtenidos en la presente investigación, se recomienda incrementar el tamaño del conjunto de datos, incorporando un mayor número de muestras bajo diversas condiciones de operación del sistema. Esto permitiría capturar una mayor variabilidad en el comportamiento del motor, contribuyendo a mejorar la capacidad de generalización del modelo y a reducir posibles sesgos derivados de un conjunto de datos limitado.

Asimismo, resulta conveniente considerar la inclusión de nuevas variables o sensores adicionales, tales como mediciones de temperatura, presión u otras magnitudes físicas relevantes. La integración de estas variables complementarían la información



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



obtenida a partir de las señales de vibración y posición angular, proporcionando una caracterización más completa del sistema y favoreciendo una mejor discriminación entre los estados de operación.

De igual manera, se sugiere explorar modelos de aprendizaje más avanzados, como redes neuronales profundas o enfoques híbridos, los cuales tienen la capacidad de capturar relaciones no lineales más complejas en los datos. Esto podría ser especialmente beneficioso en las zonas de transición, donde se presenta solapamiento entre las clases y aumenta la dificultad en la clasificación.

Finalmente, se sugiere realizar un análisis más profundo de las regiones de solapamiento entre clases, ya que estas representan los casos más complejos para el modelo. Un estudio detallado de estas zonas podría contribuir a mejorar la capacidad de clasificación en condiciones de transición y, en consecuencia, aumentar la confiabilidad del sistema propuesto.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO****REFERENCIAS BIBLIOGRÁFICAS.**

- [1] “Objetivos y metas de desarrollo sostenible - Desarrollo Sostenible”, ONU. Consultado: el 19 de noviembre de 2024. [En línea]. Disponible en: <https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/>
- [2] Secretaría Nacional de Planificación, “Plan de Desarrollo para el Nuevo Ecuador”, Consultado: el 19 de noviembre de 2024. [En línea]. Disponible en: <https://www.planificacion.gob.ec/plan-de-desarrollo-para-el-nuevo-ecuador-2024-2025/>
- [3] M. S. Elio, R. Hidalgo Batista, C. Carlos, B. Rodríguez, C. Fernando, y R. Proenza, *Relación entre los fallos y las variables de diagnóstico en motores diesel*, vol. 24, núm. 2.
- [4] M. M. A. Nouby M. Ghazaly, “A Review on Engine Fault Diagnosis through Vibration Analysis”, *International Journal on Recent Technologies in Mechanical and Electrical Engineering*, vol. 9, núm. 2, pp. 01–06, feb. 2022, doi: 10.17762/ijrmee.v9i2.364.
- [5] J. Rodríguez-Matienzo, “Diagnosis of IC Engines using vibrations Diagnóstico por vibraciones en motores de combustión interna”, *Ingeniería Mecánica*, vol. 21, núm. 2, pp. 82–92, 2018, [En línea]. Disponible en: <http://www.ingenieriamecanica.cujae.edu.cu82ArtículoOriginal>
- [6] O. Criollo y H. Matute, “Diagnóstico de fallos en la combustión para motores de combustión interna alternativos diesel por análisis de vibraciones”, *Universidad Politécnica Salesiana Sede Cuenca*, mar. 2014.
- [7] K. L. P. Tharanga, S. Liu, S. Zhang, y Y. Wang, “Diesel Engine Fault Diagnosis with Vibration Signal”, *Journal of Applied Mathematics and Physics*, vol. 08, núm. 09, pp. 2031–2042, 2020, doi: 10.4236/jamp.2020.89151.



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



- [8] C. Hua, B. Yan, D. Dong, y M. Xu, “A new vector method to diagnose individual misfiring cylinder based on crankshaft angular vibration”, en *Proceedings - 2010 International Conference on Optoelectronics and Image Processing, ICOIP 2010*, 2010, pp. 75–78. doi: 10.1109/ICOIP.2010.120.
- [9] G. Xiong, W. Ma, N. Zhao, J. Zhang, Z. Jiang, y Z. Mao, “Multi-Type Diesel Engines Operating Condition Recognition Method Based on Stacked Auto-Encoder and Feature Transfer Learning”, *IEEE Access*, vol. 9, pp. 31043–31052, 2021, doi: 10.1109/ACCESS.2021.3057399.
- [10] K. M. Lee, J. Choi, y Y. B. Bang, “Shaft position measurement using dual absolute encoders”, *Sens. Actuators A Phys.*, vol. 238, pp. 276–281, feb. 2016, doi: 10.1016/j.sna.2015.12.027.
- [11] E. Secundino, *Motores*. Macmillan Iberia, S.A., 2011. [En línea]. Disponible en: <https://elibro.net/es/lc/utnorte/titulos/101844>
- [12] BOSCH, *Manual de la Técnica del Automóvil*, 3ra ed. Editorial Reverté, S.A., 1996.
- [13] F. Payri y J. M. Desantes, Eds., *Motores de Combustión Interna Alternativos*. Universitat Politècnica de València, 2011.
- [14] Ediciones Ceac, *Manual Ceac del automóvil*, Grupo Planeta (GBS). 2007.
- [15] J. M. Molina Mengibar, *Electricidad, electromagnetismo y electrónica aplicados al automóvil: mantenimiento de los sistemas eléctricos y electrónicos de vehículos (UF1099)*. IC Editorial, 2015. [En línea]. Disponible en: <https://elibro.net/es/lc/utnorte/titulos/43650>
- [16] S. Medina, *Sensores Automotrices*. 2018. doi: 10.13140/RG.2.2.11558.98883.
- [17] J. Alonso, *Técnicas del Automóvil, Equipo Eléctrico*, Paraninfo. Madrid, 2004.
- [18] J. Alonso, *Técnicas del Automóvil, Inyección de Gasolina y Dispositivos Anticontaminación*, Thonson. 2002.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

- [19] G. Hemógenes, *Sistemas de inyección de gasolina*, Ceac. 2002.
- [20] J. Santander, *Mecánica y Electrónica Automotriz*, Diseli. 2005.
- [21] E. Agueda, *Fundamentos Tecnológicos del Automóvil*, Thonson. 2002.
- [22] V. Rodríguez, “Diagnosis y comprobación del sensor de temperatura de aire de admisión”.
- [23] T. Zonta, C. A. da Costa, R. da Rosa Righi, M. J. de Lima, E. S. da Trindade, y G. P. Li, “Predictive maintenance in the Industry 4.0: A systematic literature review”, *Comput. Ind. Eng.*, vol. 150, p. 106889, dic. 2020, doi: 10.1016/j.cie.2020.106889.
- [24] P. Nunes, J. Santos, y E. Rocha, “Challenges in predictive maintenance – A review”, *CIRP J. Manuf. Sci. Technol.*, vol. 40, pp. 53–67, feb. 2023, doi: 10.1016/j.cirpj.2022.11.004.
- [25] T.-F. Wang, Y.-J. Yan, H.-C. Chiang, T. L. Chen, y M. Ou-Yang, “Coding optimization for the absolute optical rotary encoder”, en *2018 International Automatic Control Conference (CACCS)*, IEEE, nov. 2018, pp. 1–5. doi: 10.1109/CACCS.2018.8606741.
- [26] C. N. Mafla-Yépez, C. F. Morales-Bayetero, E. P. Hernández-Rueda, y I. B. Benavides-Cevallos, “Vehicle maintenance management based on machine learning in agricultural tractor engines”, *Dyna (Medellin)*, vol. 90, núm. 225, pp. 22–28, mar. 2023, doi: 10.15446/dyna.v90n225.103612.
- [27] Y. Castro, “MANTENIMIENTO PREDICTIVO”, Universidad de Atacama, Copiapó, 2022.
- [28] F. Arena, M. Collotta, L. Luca, M. Ruggieri, y F. G. Termine, “Predictive Maintenance in the Automotive Sector: A Literature Review”, *Mathematical and Computational Applications*, vol. 27, núm. 1, p. 2, dic. 2021, doi: 10.3390/mca27010002.



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



- [29] C. Mafla-Yépez, C. Castejon-Sisamon, y H. Rubio-Alonso, “Vibration Analysis in Agricultural Vehicles for Fault Detection”, en *Proceedings of the XV Ibero-American Congress of Mechanical Engineering*, Cham: Springer International Publishing, 2023, pp. 70–76. doi: 10.1007/978-3-031-38563-6_11.
- [30] S. Krishnaveni, S. S. Raja, T. Jayasankar, y P. S. Babu, “Analysis and control of the motor vibration using arduino and machine learning model”, en *Materials Today: Proceedings*, Elsevier Ltd, 2021, pp. 2551–2555. doi: 10.1016/j.matpr.2020.11.261.
- [31] M. Paolanti, L. Romeo, A. Felicetti, A. Mancini, E. Frontoni, y J. Loncarski, “Machine Learning approach for Predictive Maintenance in Industry 4.0”, en *2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA)*, IEEE, jul. 2018, pp. 1–6. doi: 10.1109/MESA.2018.8449150.
- [32] A. Ellin y G. Dolsak, “The design and application of rotary encoders”, *Sensor Review*, vol. 28, núm. 2, pp. 150–158, mar. 2008, doi: 10.1108/02602280810856723.
- [33] S. Buhai y T. Shipeng, “A transmission algorithm applicable to incremental and absolute encoder and its implementation”, en *2017 2nd International Conference on Advanced Robotics and Mechatronics (ICARM)*, IEEE, ago. 2017, pp. 299–304. doi: 10.1109/ICARM.2017.8273178.
- [34] D. F. Rodríguez Palacios y H. E. Peñarete Rodríguez, “Medición y control de posición angular empleando Synchro - Resolver”, 2011, *Pontificia Universidad Javeriana*. [En línea]. Disponible en: <http://hdl.handle.net/10554/7069>
- [35] J. C. Lötters, W. Olthuis, P. H. Veltink, y P. Bergveld, “The mechanical properties of the rubber elastic polymer polydimethylsiloxane for sensor applications”, *Journal of Micromechanics and Microengineering*, vol. 7, núm. 3, pp. 145–147, sep. 1997, doi: 10.1088/0960-1317/7/3/017.

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

- [36] S. Naduvinamani y N. C. Iyer, “Design and simulation of PZT based MEMS piezoelectric accelerometer”, en *2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*, IEEE, mar. 2016, pp. 3715–3721. doi: 10.1109/ICEEOT.2016.7755403.
- [37] N. Yazdi, F. Ayazi, y K. Najafi, “Micromachined inertial sensors”, *Proceedings of the IEEE*, vol. 86, núm. 8, pp. 1640–1659, 1998, doi: 10.1109/5.704269.
- [38] K. E. Petersen, “Silicon as a mechanical material”, *Proceedings of the IEEE*, vol. 70, núm. 5, pp. 420–457, may 1982, doi: 10.1109/PROC.1982.12331.
- [39] E. P. Carden y P. Fanning, “Vibration Based Condition Monitoring: A Review”, *Struct. Health Monit.*, vol. 3, núm. 4, pp. 355–377, dic. 2004, doi: 10.1177/1475921704047500.
- [40] T. Sugii, T. Yamazaki, T. Fukano, y T. Ito, “Epitaxially grown base transistor for high-speed operation”, *IEEE Electron Device Letters*, vol. 8, núm. 11, pp. 528–530, nov. 1987, doi: 10.1109/EDL.1987.26717.
- [41] K. K. O *et al.*, “On-Chip Antennas in Silicon ICs and Their Application”, *IEEE Trans. Electron Devices*, vol. 52, núm. 7, pp. 1312–1323, jul. 2005, doi: 10.1109/TED.2005.850668.
- [42] S. M. M. Rahman, R. Ikeura, M. Nobe, y H. Sawai, “Controlling a power assist robot for lifting objects considering human’s unimanual, bimanual and cooperative weight perception”, en *2010 IEEE International Conference on Robotics and Automation*, IEEE, may 2010, pp. 2356–2362. doi: 10.1109/ROBOT.2010.5509321.
- [43] S. M. Patole, M. Torlak, D. Wang, y M. Ali, “Automotive radars: A review of signal processing techniques”, *IEEE Signal Process. Mag.*, vol. 34, núm. 2, pp. 22–35, mar. 2017, doi: 10.1109/MSP.2016.2628914.



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



- [44] W. Hernandez, “A Survey on Optimal Signal Processing Techniques Applied to Improve the Performance of Mechanical Sensors in Automotive Applications”, *Sensors*, vol. 7, núm. 1, pp. 84–102, ene. 2007, doi: 10.3390/s7010084.
- [45] D. Butusov, T. Karimov, A. Voznesenskiy, D. Kaplun, V. Andreev, y V. Ostrovskii, “Filtering Techniques for Chaotic Signal Processing”, *Electronics (Basel)*, vol. 7, núm. 12, p. 450, dic. 2018, doi: 10.3390/electronics7120450.
- [46] V. S. Tutatchikov, “Two-dimensional fast Fourier transform: Butterfly in analog of Cooley-Tukey algorithm”, en *2016 11th International Forum on Strategic Technology (IFOST)*, IEEE, jun. 2016, pp. 495–498. doi: 10.1109/IFOST.2016.7884163.
- [47] M. J. Spilsbury y A. Euceda, “Transformada Rápida de Fourier”, *Revista de la Escuela de Física*, vol. 4, núm. 2, pp. 45–52, sep. 2019, doi: 10.5377/ref.v4i2.8276.
- [48] U. Oberst, “The fast Fourier transform”, *SIAM J. Control Optim.*, vol. 46, núm. 2, pp. 496–540, 2007.
- [49] S. G. Johnson y M. Frigo, “A Modified Split-Radix FFT With Fewer Arithmetic Operations”, *IEEE Transactions on Signal Processing*, vol. 55, núm. 1, pp. 111–119, ene. 2007, doi: 10.1109/TSP.2006.882087.
- [50] M. Unser, “Sampling-50 years after Shannon”, *Proceedings of the IEEE*, vol. 88, núm. 4, pp. 569–587, abr. 2000, doi: 10.1109/5.843002.
- [51] T. Jeffrey y K. Jim, “LabVIEW for Everyone: Graphical Programming Made Easy and Fun (3rd Edition) (National Instruments Virtual Instrumentation Series)”, *Review of Scientific Instruments*, vol. 79, pp. 1–1032, 2006, Consultado: el 3 de febrero de 2025. [En línea]. Disponible en: <http://www.ncbi.nlm.nih.gov/pubmed/21133479>
- [52] J. Rafael. Lajara Vizcaíno y J. Pelegrí Sebastiá, “LabVIEW: entorno gráfico de programación”, p. 470, 2011, Consultado: el 3 de febrero de 2025. [En línea]. Disponible en:

**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS****SUBDECANATO**

https://books.google.com/books/about/LabVIEW_Entorno_gr%C3%A1fico_de_programaci%C3%B3n.html?hl=es&id=NnkwnsnG0UUC

- [53] T. Communications, “LabVIEW™ Core 1 Manual de Curso”, 2010, Consultado: el 3 de febrero de 2025. [En línea]. Disponible en: <http://www.apache.org/>
- [54] S. Brown y Z. Vranesic, “Fundamentals of Digital Logic with VHDL Design THIRD EDITION”, vol. 12, núm. 1, p. 29532, 2008, Consultado: el 3 de febrero de 2025. [En línea]. Disponible en: www.mhhe.com
- [55] A. Boutros y V. Betz, “FPGA Architecture: Principles and Progression”, *IEEE Circuits and Systems Magazine*, vol. 21, núm. 2, pp. 4–29, abr. 2021, doi: 10.1109/MCAS.2021.3071607.
- [56] J. Eriksson, L. Hermansen, R. Mellander, H. Zelaya, L. Parra, y M. Ekström, “Rapid prototyping-development and evaluation of Field Oriented Control using LabView FPGA”.
- [57] W. Chen y L. Tang, “Closed-Loop Control System of a Contactor Based on Single-Board RIO”, *Lecture Notes in Electrical Engineering*, vol. 889 LNEE, pp. 177–186, 2022, doi: 10.1007/978-981-19-1528-4_18.
- [58] D. McDonald, “Session 1B Work In Progress Introductory LabVIEW Real Time Data Acquisition Laboratory Activities”.
- [59] M. G. Rodríguez, *Introducción rápida a Matlab y Simulink para ciencia e ingeniería*. Ediciones Díaz de Santos, 2003.
- [60] A. Gilat, *Matlab: Una introducción con ejemplos prácticos*. Reverté, 2006.
- [61] C. N. Mafla-Yépez, C. F. Morales-Bayetero, E. P. Hernández-Rueda, y I. B. Benavides-Cevallos, “Vehicle maintenance management based on machine learning in agricultural tractor engines”, *Dyna (Medellin)*, vol. 90, núm. 225, pp. 22–28, mar. 2023, doi: 10.15446/dyna.v90n225.103612.
- [62] E. C. Jiménez, *Introducción al machine learning con MATLAB*. Marcombo, 2021.



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



- [63] C. Mafla-Yépez, J. Melo, P. Hernández, C. Castejón, y D. Teran-Pineda, “Fault Diagnosis Based on Vibrations of Mechanical Diesel Injection Pumps in Old Agricultural Tractors Using SVM: A Modernization Approach”, *Machines*, vol. 14, núm. 5, p. 505, may 2026, doi: 10.3390/machines14050505.
- [64] C. Mafla-Yépez, C. Castejon, H. Rubio, y C. Morales, “A Vibration Analysis for the Evaluation of Fuel Rail Pressure and Mass Air Flow Sensors on a Diesel Engine: Strategies for Predictive Maintenance”, *Sensors*, vol. 24, núm. 5, p. 1551, feb. 2024, doi: 10.3390/s24051551.

ANEXOS

Anexo 1 Código de programación árbol de decisión



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



```

1 % =====
2 % Árbol de Decisión para Diagnóstico de Fallos por Vibraciones
3 % Conversión Forzada a Matriz Numérica
4 % =====
5
6 % Limpiamos todo EXCEPTO la tabla importada
7 %clearvars esta_b;
8 %clc; close all;
9
10 %% 1. Lectura y Conversión Forzada de Datos
11 datos = Apren_Vibra;
12
13 % Comprobamos cómo guardó MATLAB la variable en tu Workspace
14 if istable(datos)
15     nombres_variables = datos.Properties.VariableNames(1:8);
16
17     % Extraemos X y forzamos su conversión a números matemáticos
18     X_bruto = table2array(datos(:, 1:8));
19     if iscell(X_bruto) || isstring(X_bruto)
20         X = str2double(X_bruto); % Convierte texto a números
21     else
22         X = double(X_bruto);    % Asegura el formato double
23     end
24
25     % Extraemos Y y forzamos el formato categórico
26     Y_bruto = table2array(datos(:, 9));
27     if iscell(Y_bruto) || isstring(Y_bruto)
28         Y = categorical(cellstr(Y_bruto));
29     else
30         Y = categorical(Y_bruto);
31     end
32
33 elseif iscell(datos)
34     % Si MATLAB lo importó como Cell Array en lugar de Tabla
35     nombres_variables = {'RMS', 'Varianza', 'Media', 'Mediana', 'Curtosis', 'Moda', 'Asimetria',
36     'Desviacion_estandar'};
37
38     % Intentamos convertir las celdas a matriz numérica
39     try
40         X = cell2mat(datos(:, 1:8));
41     catch
42         X = str2double(datos(:, 1:8)); % Fuerza la lectura numérica
43     end
44
45     Y = categorical(cellstr(datos(:, 9)));
46 else
47     error('El formato de los datos no es compatible. Revisa el Workspace.');
```



FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

SUBDECANATO



```

60 Y_train = Y(training(cv), :);
61 X_test = X(test(cv), :);
62 Y_test = Y(test(cv), :);
63
64 %% 3. Entrenamiento del Árbol de Decisión
65 modelo_arbol = fitctree(X_train, Y_train, ...
66     'PredictorNames', nombres_variaciones, ...
67     'SplitCriterion', 'gdi', ...
68     'MaxNumSplits', 100);
69
70
71 %% 4. Evaluación del Modelo
72 Y_pred = predict(modelo_arbol, X_test);
73 precision = sum(Y_pred == Y_test) / length(Y_test);
74
75 fprintf('\n--- RESULTADOS DEL ENTRENAMIENTO ---\n');
76 fprintf('La precisión del árbol de decisión es: %.2f%%\n\n', precision * 100);
77
78 %% 5. Visualización de Resultados
79 figure('Name', 'Evaluación del Diagnóstico', 'Color', 'w', 'Position', [100, 100, 900, 400]);
80
81 % Subplot A: Matriz de Confusión
82 subplot(1, 2, 1);
83 matriz_confusion = confusionchart(Y_test, Y_pred);
84 matriz_confusion.Title = 'Matriz de Confusión';
85 matriz_confusion.RowSummary = 'row-normalized';
86 matriz_confusion.ColumnSummary = 'column-normalized';
87
88 % Subplot B: Importancia de los Armónicos
89 subplot(1, 2, 2);
90 importancia = predictorImportance(modelo_arbol);
91 bar(importancia, 'FaceColor', [0.2 0.6 0.8]);
92 set(gca, 'XTick', 1:8, 'XTickLabel', nombres_variaciones, 'XTickLabelRotation', 45);
93 title('Importancia de cada Armónico');
94 ylabel('Puntuación de Importancia');
95 grid on;
96
97 % Figura 2: Gráfico Estructural
98 view(modelo_arbol, 'Mode', 'graph');
99
100

```



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



Anexo 2 Tabla de eficiencia de entrenamientos para amplitud

Model Number	Model Type	Status	Accuracy % (Validation)	Total Cost (Validation)
1	Tree	Trained	60	160
2.1	Tree	Trained	60	160
2.2	Tree	Trained	64.75	141
2.3	Tree	Trained	63.75	145
2.4	Discriminant	Trained	69.25	123
2.5	Discriminant	Trained	70.75	117
2.6	Binary GLM Logistic Regression	Trained	69	124
2.7	Efficient Logistic Regression	Trained	68.75	125
2.8	Efficient Linear SVM	Trained	50	200
2.9	Naive Bayes	Trained	70.75	117
2.10	Naive Bayes	Trained	72	112
2.11	SVM	Trained	70.5	118
2.12	SVM	Trained	70.75	117
2.13	SVM	Trained	66.5	134
2.14	SVM	Trained	64	144
2.15	SVM	Trained	70.75	117
2.16	SVM	Trained	69.75	121
2.17	KNN	Trained	61.25	155
2.18	KNN	Trained	71	116
2.19	KNN	Trained	70	120
2.20	KNN	Trained	68.75	125
2.21	KNN	Trained	68.75	125
2.22	KNN	Trained	67	132
2.23	Ensemble	Trained	66.25	135
2.24	Ensemble	Trained	63.25	147
2.25	Ensemble	Trained	69.5	122
2.26	Ensemble	Trained	63.5	146
2.27	Ensemble	Trained	66	136
2.28	Neural Network	Trained	68.5	126
2.29	Neural Network	Trained	60	160
2.30	Neural Network	Trained	59.25	163
2.31	Neural Network	Trained	63.5	146
2.32	Neural Network	Trained	64.5	142
2.33	Kernel	Trained	56	176
2.34	Kernel	Trained	52	192



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



Anexo 3 Tabla de eficiencia de entrenamientos para ordenes

Model Number	Model Type	Status	Accuracy % (Validation)	Total Cost (Validation)
1	Tree	Trained	80.75	77
2.1	Tree	Trained	80.75	77
2.2	Tree	Trained	82.25	71
2.3	Tree	Trained	81.25	75
2.4	Discriminant	Trained	83.25	67
2.5	Discriminant	Trained	83	68
2.6	Binary GLM Logistic Regression	Trained	83.25	67
2.7	Efficient Logistic Regression	Trained	83.25	67
2.8	Efficient Linear SVM	Trained	68.5	126
2.9	Naive Bayes	Trained	83.25	67
2.10	Naive Bayes	Trained	83	68
2.11	SVM	Trained	82.75	69
2.12	SVM	Trained	82	72
2.13	SVM	Trained	82.5	70
2.14	SVM	Trained	81.5	74
2.15	SVM	Trained	83.25	67
2.16	SVM	Trained	83.25	67
2.17	KNN	Trained	77.25	91
2.18	KNN	Trained	83	68
2.19	KNN	Trained	83.25	67
2.20	KNN	Trained	82.75	69
2.21	KNN	Trained	82.5	70
2.22	KNN	Trained	80.5	78
2.23	Ensemble	Trained	79	84
2.24	Ensemble	Trained	80.5	78
2.25	Ensemble	Trained	83.25	67
2.26	Ensemble	Trained	78.5	86
2.27	Ensemble	Trained	81.75	73
2.28	Neural Network	Trained	80.5	78
2.29	Neural Network	Trained	75.25	99
2.30	Neural Network	Trained	77.75	89
2.31	Neural Network	Trained	79	84
2.32	Neural Network	Trained	79.25	83
2.33	Kernel	Trained	67	132
2.34	Kernel	Trained	66.25	135



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



Anexo 4 Tabla de eficiencia de entrenamientos para datos estadísticos de ángulo

Model Number	Model Type	Status	Accuracy % (Validation)	Total Cost (Validation)
2.1	Tree	Trained	72.5	110
2.2	Tree	Trained	71.25	115
2.3	Tree	Trained	69.75	121
2.4	Discriminant	Trained	76.75	93
2.5	Discriminant	Trained	80.5	78
2.6	Binary GLM Logistic Regression	Trained	78	88
2.7	Efficient Logistic Regression	Trained	64.25	143
2.8	Efficient Linear SVM	Trained	64	144
2.9	Naive Bayes	Trained	82	72
2.10	Naive Bayes	Trained	82.75	69
2.11	SVM	Trained	77.5	90
2.12	SVM	Trained	80.25	79
2.13	SVM	Trained	74	104
2.14	SVM	Trained	74	104
2.15	SVM	Trained	82.25	71
2.16	SVM	Trained	79.75	81
2.17	KNN	Trained	74.25	103
2.18	KNN	Trained	79.25	83
2.19	KNN	Trained	79	84
2.20	KNN	Trained	81.5	74
2.21	KNN	Trained	76.75	93
2.22	KNN	Trained	79.5	82
2.23	Ensemble	Trained	76.25	95
2.24	Ensemble	Trained	80	80
2.25	Ensemble	Trained	77.25	91
2.26	Ensemble	Trained	62.75	149
2.27	Ensemble	Trained	71	116
2.28	Neural Network	Trained	73.75	105
2.29	Neural Network	Trained	74.5	102
2.30	Neural Network	Trained	75.75	97
2.31	Neural Network	Trained	77.75	89
2.32	Neural Network	Trained	74.25	103
2.33	Kernel	Trained	68.75	125
2.34	Kernel	Trained	70	120



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



Anexo 5 Tabla de eficiencia de entrenamientos para datos estadísticos de vibración

Model Number	Model Type	Status	Accuracy % (Validation)	Total Cost (Validation)
2.1	Tree	Trained	76.75	93
2.2	Tree	Trained	77.25	91
2.3	Tree	Trained	73.75	105
2.4	Discriminant	Trained	71	116
2.5	Discriminant	Trained	77.75	89
2.6	Binary GLM Logistic Regression	Trained	71.25	115
2.7	Efficient Logistic Regression	Trained	71	116
2.8	Efficient Linear SVM	Trained	70.5	118
2.9	Naive Bayes	Trained	79.75	81
2.10	Naive Bayes	Trained	80.5	78
2.11	SVM	Trained	70.5	118
2.12	SVM	Trained	76.25	95
2.13	SVM	Trained	72.5	110
2.14	SVM	Trained	68	128
2.15	SVM	Trained	77.75	89
2.16	SVM	Trained	73.75	105
2.17	KNN	Trained	66.75	133
2.18	KNN	Trained	73	108
2.19	KNN	Trained	68.25	127
2.20	KNN	Trained	70	120
2.21	KNN	Trained	75.5	98
2.22	KNN	Trained	72.75	109
2.23	Ensemble	Trained	80	80
2.24	Ensemble	Trained	80.5	78
2.25	Ensemble	Trained	71	116
2.26	Ensemble	Trained	76.5	94
2.27	Ensemble	Trained	78.25	87
2.28	Neural Network	Trained	73	108
2.29	Neural Network	Trained	72.5	110
2.30	Neural Network	Trained	73	108
2.31	Neural Network	Trained	70.5	118
2.32	Neural Network	Trained	71.25	115
2.33	Kernel	Trained	66	136
2.34	Kernel	Trained	69.25	123



FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS

SUBDECANATO



Anexo 6 Tabla de eficiencia de entrenamientos para datos estadísticos de vibración en la variable de curtosis

Model Number	Model Type	Status	Accuracy % (Validation)	Total Cost (Validation)
2.1	Tree	Trained	56	176
2.2	Tree	Trained	65	140
2.3	Tree	Trained	68.25	127
2.4	Discriminant	Trained	51.5	194
2.5	Discriminant	Trained	68	128
2.6	Binary GLM Logistic Regression	Trained	51.5	194
2.7	Efficient Logistic Regression	Trained	51.5	194
2.8	Efficient Linear SVM	Trained	50	200
2.9	Naive Bayes	Trained	68	128
2.10	Naive Bayes	Trained	67.5	130
2.11	SVM	Trained	52	192
2.12	SVM	Trained	52.25	191
2.13	SVM	Trained	45	220
2.14	SVM	Trained	67.75	129
2.15	SVM	Trained	67.5	130
2.16	SVM	Trained	63	148
2.17	KNN	Trained	57.25	171
2.18	KNN	Trained	59.5	162
2.19	KNN	Trained	66.75	133
2.20	KNN	Trained	50	200
2.21	KNN	Trained	59.5	162
2.22	KNN	Trained	56.75	173
2.23	Ensemble	Trained	65.25	139
2.24	Ensemble	Trained	57.25	171
2.25	Ensemble	Trained	51.5	194
2.26	Ensemble	Trained	57.25	171
2.27	Ensemble	Trained	65.75	137
2.28	Neural Network	Trained	67.75	129
2.29	Neural Network	Trained	65.25	139
2.30	Neural Network	Trained	66.75	133
2.31	Neural Network	Trained	65.75	137
2.32	Neural Network	Trained	64	144
2.33	Kernel	Trained	41.5	234
2.34	Kernel	Trained	53.25	187



**FACULTAD DE INGENIERÍA EN CIENCIAS
APLICADAS**

SUBDECANATO



Anexo 7 Tabla de validación de datos

Muestra	Estado	Confianza_%
1	BE	98.28517875
2	BE	93.45080047
3	BE	95.79676817
4	BE	97.19313848
5	BE	57.78376508
6	BE	99.38793693
7	BE	97.23108472
8	ME	92.68381908
9	BE	97.26922083
10	BE	96.24657154
11	BE	97.75615011
12	BE	98.06749713
13	ME	88.54831843
14	BE	98.95861755
15	BE	95.93719874
16	BE	87.89085563
17	BE	90.37467101
18	ME	97.46712306
19	BE	54.34266633
20	ME	82.25234716
21	ME	84.75447657
22	BE	98.22699436
23	BE	58.55978161
24	BE	84.72664311
25	BE	96.85412086
26	BE	89.52218915
27	BE	99.42072045
28	BE	87.17113098
29	BE	91.90954027
30	BE	90.19341596
31	BE	77.10486782
32	BE	51.72184097
33	BE	93.52363799
34	BE	93.07305062
35	BE	87.4267917
36	ME	64.69134816
37	BE	97.91096731
38	BE	94.19571658

Muestra	Estado	Confianza_%
39	BE	89.35548707
40	BE	97.49671303
41	BE	87.0709341
42	BE	96.02765561
43	BE	96.70293145
44	BE	97.15929059
45	BE	90.59429914
46	BE	95.14421025
47	BE	76.77152663
48	BE	94.042781
49	BE	96.40100187
50	BE	59.97340214
51	ME	68.61340508
52	ME	99.48084546
53	BE	54.66684992
54	ME	97.70178062
55	ME	76.42930799
56	ME	96.76063452
57	ME	91.78851344
58	ME	53.53443703
59	ME	97.5149397
60	BE	83.9577332
61	ME	80.35673359
62	ME	89.6649404
63	ME	98.01626585
64	ME	97.91143554
65	ME	87.93625968
66	ME	82.67836208
67	ME	72.91079848
68	ME	94.78590679
69	ME	92.29099591
70	ME	99.34787172
71	ME	66.80323914
72	ME	97.13510674
73	ME	97.74259646
74	ME	70.98365701
75	ME	92.14057493
76	ME	90.95172245

Muestra	Estado	Confianza_%
77	ME	94.85893794
78	ME	95.10297124
79	ME	75.18010015
80	ME	98.16409353
81	BE	52.70838991
82	ME	98.13821523
83	ME	89.58268924
84	ME	98.47764771
85	ME	78.03460911
86	ME	99.19115897
87	BE	85.37693004
88	BE	98.02223437
89	ME	93.94014197
90	ME	97.31734239
91	ME	97.11861377
92	ME	90.90269569
93	ME	89.84212937
94	ME	86.05712318
95	ME	89.69587534
96	ME	98.64423013
97	ME	99.50799731
98	ME	98.09578504
99	ME	84.63594573
100	ME	94.72539218