

UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE CUENCA

CARRERA DE INGENIERÍA MECÁNICA AUTOMOTRIZ

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

Proyecto técnico:

DIAGNÓSTICO DE FALLAS DE UN MOTOR DE ENCENDIDO
PROVOCADO CORSA EVOLUTION 1.4L MEDIANTE EL
ANÁLISIS DE LAS SEÑALES DE LOS SENSORES MAP, TPS, VSS,
UTILIZANDO HERRAMIENTAS DE APRENDIZAJE Y
CLASIFICACIÓN

Autores:

Cepeda Landin Carlos Cesar

Rivera Caravajo Juan Andrés

Tutor:

Ing. Néstor Diego Rivera Campoverde MSc.

Cuenca, Agosto 2017

CESIÓN DE DERECHOS DE AUTOR

Nosotros, Carlos Cesar Cepeda Landin, con documento de identificación N° 0302467022, y Juan Andrés Rivera Caravajo, con documento de identificación N° 0105980015, manifestamos nuestra voluntad y cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del Trabajo de Titulación denominado: “DIAGNÓSTICO DE FALLAS DE UN MOTOR DE ENCENDIDO PROVOCADO CORSA EVOLUTION 1.4L MEDIANTE EL ANÁLISIS DE LAS SEÑALES DE LOS SENSORES MAP, TPS, VSS, UTILIZANDO HERRAMIENTAS DE APRENDIZAJE Y CLASIFICACIÓN”, mismo que ha sido desarrollado para optar por el título de: Ingeniero Mecánico Automotriz, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en nuestra condición de autores nos reservamos los derechos morales de la obra antes citada. En concordancia, suscribimos este documento en el momento que hacemos entrega del trabajo final en formato impreso y digital a la Biblioteca de la Universidad Politécnica Salesiana.



Carlos Cesar Cepeda Landin



Juan Andrés Rivera Caravajo

CERTIFICACIÓN

Yo, Ing. Néstor Diego Rivera Campoverde declaro que bajo mi tutoría fue desarrollado el Trabajo de Titulación denominado: “DIAGNÓSTICO DE FALLAS DE UN MOTOR DE ENCENDIDO PROVOCADO CORSA EVOLUTION 1.4L MEDIANTE EL ANÁLISIS DE LAS SEÑALES DE LOS SENSORES MAP, TPS, VSS, UTILIZANDO HERRAMIENTAS DE APRENDIZAJE Y CLASIFICACIÓN”, realizado por los autores, Carlos Cesar Cepeda Landin y Juan Andrés Rivera Caravajo, obteniendo el Proyecto Técnico que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana.



Ing. Néstor Diego Rivera Campoverde, M.Sc

DECLARATORIA DE RESPONSABILIDAD

Nosotros, Carlos Cesar Cepeda Landin, con documento de identificación N° 0302467022, y Juan Andrés Rivera Caravajo, con documento de identificación N° 0105980015, autores del Trabajo de Titulación denominado: “DIAGNÓSTICO DE FALLAS DE UN MOTOR DE ENCENDIDO PROVOCADO CORSA EVOLUTION 1.4L MEDIANTE EL ANÁLISIS DE LAS SEÑALES DE LOS SENSORES MAP, TPS, VSS, UTILIZANDO HERRAMIENTAS DE APRENDIZAJE Y CLASIFICACIÓN”, certificamos que el total contenido del Proyecto Técnico, son de nuestra exclusiva responsabilidad y autoría.



Carlos Cesar Cepeda Landin



Juan Andrés Rivera Caravajo

AGRADECIMIENTO

En primera instancia agradezco a Dios, que me ha brindado salud y vida a lo largo de mi vida, por permitirme disfrutar del cariño y apoyo de mi familia.

A mis padres Elena y Efraín, por su tiempo y dedicación hacía mí, por su apoyo desinteresado, por la confianza que han puesto en mi persona, a lo largo de mi carrera como estudiante.

A mis hermanos, Diego, Patricio, Eder y Steven, que me han brindado su amistad, consejos y momentos de familia, en los que no hemos descuidado a nuestros padres.

A mi abuelito Marino por estar junto a mí durante las diferentes etapas de mi vida.

A Ligia, por saber comprenderme y aceptarme como soy, quien en cada momento estuvo presente para brindarme su apoyo y regalarme momentos únicos e inolvidables, en la consecución de mis objetivos.

A mis Cuñadas Liliana, Gina y Karen, que de cierta forma se han convertido en un gran apoyo de mis padres y forman parte de mi familia.

A mis dos sobrinos Corina y Juan Sebastián, por las alegrías que han brindado a mi familia.

A mi tutor de tesis, el Ingeniero Néstor Rivera, que más que un profesor ha sido un amigo, por su amistad y sus consejos.

A mi amigo de tesis, Andrés Rivera, por haberme brindado la oportunidad de hacer este trabajo junto a él.

A mis amigos por haberme brindado su amistad en esta ciudad.

A los docente de la carrera de Ingeniería Mecánica Automotriz, por las horas de clases y sus consejos que me han ayudado a lo largo de mi carrera universitaria.

A la Universidad Politécnica Salesiana, por brindarme la oportunidad de formarme como profesional.

Carlos Cesar

AGRADECIMIENTO

Primeramente, agradezco a Dios, por brindarme salud, fortaleza a seguir adelante en mi carrera universitaria, permitirme crecer junto al amor de mi familia, y gracias a ello pude seguir con paso firme ante las adversidades de la vida.

A mis padres Catalina y Juan, quienes me han apoyado durante todo el transcurso de la vida universitaria, por su apoyo, su amor, comprensión y paciencia.

A una persona muy especial Michelle, mi hermanita menor que ha sido mi motivación principal para seguir adelante y darle un claro ejemplo que si se puede a pesar de las adversidades que se nos presentó.

A mis abuelitos Julia y Ángel que han sido mi motivación para cumplir mi sueño, de ser un ingeniero y quienes han sido un claro ejemplo que se puede ser una mejor persona cada día.

A toda mi familia, por su apoyo y consejos que me han ayudado a mejorar cada día y aplicarla a la vida.

Al ingeniero Néstor Rivera, un consejero un amigo, le dedico este agradecimiento por brindarme sus conocimientos durante el transcurso de mi carrera, por ayudarnos a resolver problemas universitarios. Gracias por brindarme su amistad y confianza.

Agradezco también a mi amigo Carlos Cesar con el que he realizado este trabajo de titulación y he vivido mi carrera universitaria con alegría, triunfos y derrotas, con el que siempre hemos salido adelante para lograr cumplir uno de nuestros sueños.

A mis amigos les hago llegar este agradecimiento por su amistad que me brindaron y los momentos que hemos compartido.

Y todos quienes han estado condicionalmente apoyándome y dando ánimos y motivación para seguir adelante en los momentos de desesperación, Gracias.

Andrés

DEDICATORIA

Este trabajo está dirigido a mis padres, Elena y Efraín, que han estado a lo largo de mi vida, brindándome su apoyo a lo largo de toda mi carrera como estudiante. Y han luchado de forma desinteresada por mí y mis hermanos, regalándonos su tiempo, su esfuerzo y sus años de vida a cinco hijos, a quienes formaron como profesionales y con valores de bien.

A mis hermanos por todos los momentos que hemos compartido a lo largo de nuestras vidas.

Carlos Cesar

DEDICATORIA

Dedico este trabajo de titulación a mis Padres Catalina y Juan, por su apoyo que me brindan para poder alcanzar mi meta, tanto profesional como personal, quienes han dado un claro ejemplo de honestidad, perseverancia y me han inculcado valores desde pequeño.

Estoy eternamente agradecido por todo el amor que siempre me han brindado. Los quiero muchísimo no dejare que nada malo les pase.

Andrés

RESUMEN

El presente trabajo inicia con la revisión del estado del arte y fundamentos teóricos referentes a la utilización de las herramientas de aprendizaje y clasificación utilizadas en el diagnóstico de fallas en motores de combustión, con el objetivo de determinar de forma más precisa el tamaño y ubicación del fallo, que conllevan a disminuir el costo de mantenimiento.

En el desarrollo de la metodología experimental, se comienza por realizar un análisis de las características técnicas de la unidad experimental y de los elementos a utilizar para obtener las señales de funcionamiento del motor, los diferentes equipos empleados para la obtención de las señales y la base de datos. Así mismo se citan conceptos teóricos referentes a las características de estos elementos.

Luego se realiza las diferentes corridas experimentales, para la obtención de las señales por medio del software Labview y para posterior realización de la base de datos, generando los fallos en el sistema de presión de combustible y en el sistema de encendido, estas afectaciones presentan una alteración en la emisión de los gases contaminantes generados en el vehículo y en las prestaciones del mismo.

Mediante las herramientas de aprendizaje y clasificación se desarrolla las diferentes corridas experimentales y análisis de los calores obtenidos de funcionamiento del motor, para nuestro estudio se utilizó las máquinas de soporte vectorial (SVM), que brindan una mejor respuesta al estudio realizado.

Mediante un programa estadístico se efectúa el análisis de la base de datos generada, para nuestro caso se utiliza el programa Minitab, de esta manera se determina la validez en la obtención de los datos y la relación que existe entre los valores obtenidos y los índices de incremento o disminución en los valores referentes a los límites de emisiones gases generados en las corridas experimentales.

Como punto final se presenta la comprobación de la validación de los valores obtenidos en el experimento, mediante la lectura y predicción de la lectura de las señales del motor.

ABSTRACT

The present work begins with a review of the state of the art and theoretical foundations regarding the use of the learning and classification tools used in the diagnosis of failures in combustion engines, in order to determine more precisely the size and location of the Failure, which lead to decrease the cost of maintenance.

In the development of the experimental methodology, an analysis of the technical characteristics of the experimental unit and of the elements to be used to obtain the signals of operation of the engine, the different equipment used to obtain the signals and the base of data. Likewise, theoretical concepts referring to the characteristics of these elements are cited.

Then the different experimental runs are performed, to obtain the signals through the software Labview and for later realization of the database, generating the failures in the system of fuel pressure and in the system of ignition, these affections present a Alteration in the emission of the polluting gases generated in the vehicle and in the performance of the same.

By means of the learning and classification tools we develop the different experimental runs and analysis of the heats obtained from motor operation, for our study we used the vector support machines (SVM), which provide a better response to the study.

By means of a statistical program the analysis of the generated database is made, for our case the Minitab program is used, in this way it determines the validity in obtaining the data and the relation that exists between the values obtained and the indexes of Increase or decrease in the values referring to the emission limits of gases generated in the experimental runs.

The final point is the verification of the validation of the values obtained in the experiment, by reading and predicting the reading of the motor signals.

ÍNDICE GENERAL

1. INTRODUCCIÓN	1
2. PROBLEMA	2
3. OBJETIVOS	2
3.1 Objetivo General	2
3.2 Objetivos específicos	2
4. FUNDAMENTOS TEÓRICOS	3
4.1 Diagnóstico de fallas en motores de encendido provocado	3
4.2 Diagnóstico y detección de falla	3
4.3 Inteligencia artificial.....	5
4.3.1 Inteligencia artificial convencional.....	6
4.3.2 Inteligencia artificial computacional	6
4.3.3 Características de la Inteligencia Artificial	7
4.3.4 Áreas de aplicación.....	7
4.4 Árboles de decisión	8
4.4.1 Construcción del árbol	8
4.5 Máquinas de soporte vectorial	10
4.5.1 Máquinas de soporte vectorial para clasificación binaria	12
4.5.1.1 Máquinas de soporte vectorial para la clasificación no lineal.....	12
4.5.1.2 Máquinas de soporte vectorial lineal con margen blando.....	14
4.5.2 Máquinas de soporte vectorial para clasificación multiclase	14
5. ESTADO DEL ARTE.....	15
5.1 Diagnóstico de fallas	15
5.2 Herramientas de aprendizaje y clasificación para motores de combustión interna	16

6.	MARCO METODOLÓGICO	18
6.1	Desarrollo del diseño experimental para la adquisición de datos	18
6.1.1	Planificación del experimento	18
6.1.2	Variables de entrada.....	18
6.1.3	Variables de bloqueo	19
6.1.4	Variables de ruido.....	19
6.1.5	Variables de respuesta.....	20
6.1.6	Unidad experimental.....	20
6.1.6.1	Vehículo de pruebas	20
6.1.6.2	Banco dinamométrico	21
6.1.6.3	Analizador de gases	22
6.1.6.4	Tarjeta de adquisición de datos	23
6.1.6.5	Presión de combustible	24
6.1.6.6	Sensores	25
6.1.6.6.1	Sensor MAP	25
6.1.6.6.2	Sensor TPS.....	25
6.1.6.6.3	Sensor VSS	26
6.1.7	Programa para la adquisición de datos.....	27
6.1.7.1	Software Labview.....	27
6.1.7.1.1	Ventajas de Labview	27
6.1.7.2	Tarjeta de adquisición de datos DAQ 6008	28
6.1.7.3	Software de adquisición de datos	30
6.1.7.3.1	Tiempo de muestreo	30
6.1.7.3.2	Adquisición de datos	31
6.1.7.3.3	Frecuencia de la señal.....	31
6.1.7.3.4	Generación de hoja de cálculo	32

6.1.7.3.5	Adquisición de datos	32
6.1.7.3.6	Disposición de los diferentes elementos para la experimentación	33
6.2	Desarrollo de las corridas experimentales mediante la obtención de las señales de los sensores MAP, TPS, VSS para la recolección de los datos con diferentes parámetros de funcionamiento del motor	33
6.2.1	Toma de datos.....	33
6.2.1.1	Protocolo de medición	34
6.2.1.2	Secuencia de corridas experimentales	35
6.2.2	Valores tomados en el desarrollo.....	37
6.2.2.1	Ubicación de los sensores utilizados en el vehículo de pruebas	37
6.2.2.2	Sensores utilizados en la experimentación.....	37
6.3	Análisis mediante herramientas de aprendizaje y clasificación de la base de datos para el diagnóstico de fallas de un motor de encendido provocado.....	40
6.3.1	Tratamiento de datos.....	40
6.3.1.1	Variables de entrada	40
6.3.1.2	Variables de salida.....	41
6.3.1.3	Base de datos utilizada en el estudio	41
6.3.2	Análisis de la base de datos mediante herramientas de aprendizaje y clasificación.....	42
6.3.2.1	Análisis del consumo de combustible en L/100km	43
6.3.2.1.1	Matriz de confusión para el consumo de combustible en L/100km	44
6.3.2.1.2	Diagrama de coordenadas paralelas para el consumo de combustible en L/100km	45
6.3.2.1.3	Curva operática del receptor para el consumo de combustible en L/100km	46
6.3.2.2	Análisis del consumo de combustible en L/h.....	47

6.3.2.2.1	Matriz de confusión para el consumo de combustible en L/h.....	48
6.3.2.2.2	Curva de características operáticas del receptor para el consumo de combustible en L/h	48
6.3.2.2.3	Diagrama de coordenadas paralelas para el consumo de combustible en L/h	49
6.3.2.3	Análisis de la fuerza tractora.....	50
6.3.2.3.1	Matriz de confusión para la fuerza tractora	51
6.3.2.3.2	Curva de características operativas del receptor para la fuerza tractora	52
6.3.2.3.3	Diagrama de coordenadas paralelas para la fuerza tractora.....	52
6.3.2.4	Análisis de la potencia del vehículo	53
6.3.2.4.1	Matriz de confusión para la potencia.....	54
6.3.2.4.2	Curva de características operativas del receptor para la potencia. .	55
6.3.2.4.3	Diagrama de coordenadas paralelas para la potencia	55
6.3.2.5	Análisis del monóxido de carbono (CO)	56
6.3.2.5.1	Matriz de confusión para el monóxido de carbono (CO)	57
6.3.2.5.2	Curva de características operativas del receptor para el monóxido de carbono (CO).....	58
6.3.2.5.3	Diagrama de coordenadas paralelas para el monóxido de carbono (CO)	58
6.3.2.6	Análisis de hidrocarburos no combustionados (HC)	59
6.3.2.6.1	Matriz de confusión para los hidrocarburos no combustionados (HC)	60
6.3.2.6.2	Curva de características operativas del receptor para los hidrocarburos no combustionados (HC).....	61
6.3.2.6.3	Diagrama de coordenadas paralelas para los hidrocarburos no combustionados (HC)	61
6.3.2.7	Análisis del dióxido de carbono (CO ₂).....	62

6.3.2.7.1	Matriz de confusión para el dióxido de carbono (CO ₂).....	63
6.3.2.7.2	Curva de características operativas del receptor para el dióxido de carbono (CO ₂)	64
6.3.2.7.3	Diagrama de coordenadas paralelas para el dióxido de carbono (CO ₂)	64
6.3.2.8	Análisis del oxígeno (O ₂).....	65
6.3.2.8.1	Matriz de confusión para el oxígeno (O ₂).....	66
6.3.2.8.2	Curva de características operativas del receptor para el oxígeno O ₂	67
6.3.2.8.3	Diagrama de coordenadas paralelas para el oxígeno (O ₂).....	67
6.3.2.9	Análisis del factor LAMBDA	68
6.3.2.9.1	Matriz de confusión para el factor LAMBDA	69
6.3.2.9.2	Curva de características operativas del receptor para el factor LAMBDA.....	70
6.3.2.9.3	Diagrama de coordenadas paralelas para el factor LAMBDA	70
6.3.2.10	Análisis del radio aire combustible (AFR)	71
6.3.2.10.1	Matriz de confusión para el radio aire combustible (AFR)	72
6.3.2.10.2	Curva de características operativas del receptor para el radio aire combustible AFR.....	73
6.3.2.10.3	Diagrama de coordenadas paralelas para el radio aire combustible AFR	73
6.4	Presentar los resultados obtenidos mediante métodos estadísticos y experimentales para la comprobación del software desarrollado	74
6.4.1	Análisis de las variables de respuesta mediante métodos estadísticos	74
6.4.1.1	Comportamiento del consumo de combustible en L/h	74
6.4.1.1.1	Gráficas de contorno de consumo de combustible en Litros/hora con vehículo en parámetros de correcto funcionamiento.....	75

6.4.1.1.2	Gráfica de contorno de consumo de combustible en Litros/hora con falla de dosado Rico	76
6.4.1.1.3	Gráfica de superficie de consumo de combustible en Litros/hora	76
6.4.1.1.4	Gráfica de superficie de consumo de combustible con respecto a los tipos de fallas.....	77
6.4.1.2	Gráfica de intervalos de monóxido de carbono.....	78
6.4.1.2.1	Gráficas de contorno de monóxido de carbono con el vehículo en parámetro de correcto funcionamiento	78
6.4.1.2.2	Gráfica de contorno de porcentaje de monóxido de carbono con falla de dosado Rico	79
6.4.1.2.3	Gráfica de superficie del monóxido de carbono.....	80
6.4.1.2.4	Gráfica de superficie de porcentaje de monóxido de carbono	80
6.4.1.3	Gráfica de intervalos de la relación estequiométrica (AFR).....	81
6.4.1.3.1	Gráficas de contorno de la relación estequiometrica con el vehículo en parámetros de correcto funcionamiento	81
6.4.1.3.2	Gráficas de contorno de la relación estequiometria con el vehículo en parámetros de correcto funcionamiento	82
6.4.1.3.3	Gráfica de superficie de la relación estequiométrica.....	82
6.4.1.3.4	Gráfica de superficie del porcentaje de la relación estequiométrica	83
6.4.1.4	Comportamiento de la fuerza tractora con respecto a los fallos generados	84
6.4.1.4.1	Gráfica de contorno de la fuerza tractora con el vehículo en parámetros de correcto funcionamiento.....	84
6.4.1.4.2	Gráfica de contorno de fuerza tractora del vehículo con dosado rico	85
6.4.1.4.3	Gráfica de contorno de fuerza tractora del vehículo con dosado pobre	86

6.4.1.4.4	Gráfica de superficie de fuerza tractora.....	86
6.4.2	Comprobación del software desarrollado	87
6.4.2.1	Predicción con presión de combustible de 60 psi.....	87
6.4.2.2	Predicción con presión de combustible de 40 psi.....	88
6.4.2.3	Predicción con un bajo voltaje de encendido	88
7.	CONCLUSIONES	89
8.	RECOMENDACIONES	90
10.	BIBLIOGRAFÍA.....	91
11.	ANEXOS	94
11.1	Comportamiento del monóxido de carbono.....	94
11.2	Comportamiento del consumo de combustible en L/100Km con respecto a los fallos generados.....	96
11.3	Comportamiento de la relación estequiométrica con respecto a los fallos generados	98
11.4	Comportamiento de la fuerza con respecto a las fallas provocadas	100

ÍNDICE DE FIGURAS

Figura 4.1. Esquema de diagnóstico de fallas	4
Figura 4.2. Esquema de detección de fallas.	5
Figura 4.3. Estructura del árbol de decisión.....	9
Figura 4.4. Metodología basada en MSV.....	11
Figura 4.5. Separación de datos mediante SVM.....	11
Figura 4.6. Ejemplo de un conjunto de datos linealmente no separables.	13
Figura 4.7. Transformación de los datos de entrada a un espacio de mayor dimensión.	13
Figura 4.8. Clasificación con SVM de margen máximo con datos entre los que existe un dato atípico.	14
Figura 5.1. Diagnóstico de Fallas en base a modelos.	15
Figura 6.1. Proceso del desarrollo de la planificación del experimento.	18
Figura 6.2. Vehículo de pruebas Chevrolet Corsa Evolution 1.4L.....	21
Figura 6.3. Banco dinamométrico MAHA LPS 3000.....	22
Figura 6.4. Analizador de gases Nextech NGA 6000.....	22
Figura 6.5. Tarjeta de adquisición de datos DAQ USB 6008.	23
Figura 6.6. Manómetro de presión de combustible.	24
Figura 6.7. Señal generada por el sensor MAP.....	25
Figura 6.8. Diagrama de funcionamiento del sensor TPS.....	26
Figura 6.9. Diagrama de funcionamiento del sensor VSS.	26
Figura 6.10. Lectura de señales.	27
Figura 6.11. Partes externas del dispositivo DAQ USB 6008.....	28
Figura 6.12. Diagrama de bloques de la tarjeta de adquisición de datos.	29
Figura 6.13. Pines de conexión.....	29
Figura 6.14. Interfaz de Labview utilizada en la elaboración del software.	30

Figura 6.15. Obtención del tiempo de muestreo en el software Labview.	30
Figura 6.16. Adquisición de datos.	31
Figura 6.17. Frecuencia de lectura de la señal.	31
Figura 6.18. Almacenamiento de los datos en la hoja de cálculo.	32
Figura 6.19. Función Continue Samples.	32
Figura 6.20. Disposición de los equipos de muestreo.	33
Figura 6.21. Banco de pruebas.	34
Figura 6.22. Secuencia de toma de datos.	35
Figura 6.23. Flujo de las señales hacia la tarjeta.	35
Figura 6.24. Proceso de filtrado de la señal.	36
Figura 6.25. Señales de análisis de los sensores.	36
Figura 6.26. Ubicación de los sensores de muestreo en el vehículo.	37
Figura 6.27. Plataforma de selección de variables predictoras y de respuesta.	42
Figura 6.28. Diagrama de dispersión del consumo de combustible en L/100km.	43
Figura 6.29. Matriz de confusión de consumo de combustible en L/100km.	44
Figura 6.30. Diagrama de coordenadas paralelas de consumo de combustible en L/100km.	45
Figura 6.31. Curva operativa de receptor para consumo de combustible en L/100km. .	46
Figura 6.32. Diagrama de dispersión del consumo de combustible en L/h.	47
Figura 6.33. Matriz de confusión para el consumo de combustible en litros/h.	48
Figura 6.34. Curva operativa de receptor para el consumo de combustible en L/h.	49
Figura 6.35. Diagrama de coordenadas paralelas del consumo de combustible en L/h.	50
Figura 6.36. Diagrama de dispersión de la fuerza tractora.	51
Figura 6.37. Matriz de confusión de la fuerza tractora.	51
Figura 6.38. Cuerva ROC de la fuerza tractora.	52
Figura 6.39. Diagrama de coordenadas paralelas de la fuerza tractora.	53

Figura 6.40. Diagrama de dispersión de potencia.....	54
Figura 6.41. Matriz de confusión de potencia.	54
Figura 6.42. Cuerva ROC de potencia.	55
Figura 6.43. Diagrama de coordenadas paralelas de potencia.....	56
Figura 6.44. Diagrama de dispersión para el CO.....	57
Figura 6.45. Matriz de confusión para el CO.	57
Figura 6.46. Curva ROC para el CO.....	58
Figura 6.47. Diagrama de coordenadas paralelas del CO.	59
Figura 6.48. Diagrama de dispersión para HC.	60
Figura 6.49. Matriz de confusión de HC.....	60
Figura 6.50. Curva ROC de HC.....	61
Figura 6.51. Diagrama de coordenadas paralelas de HC.	62
Figura 6.52. Diagrama de dispersión para el CO ₂	63
Figura 6.53. Matriz de confusión para el CO ₂	63
Figura 6.54. Curva ROC para el CO ₂	64
Figura 6.55. Diagrama de coordenadas paralelas de CO ₂	65
Figura 6.56. Diagrama de dispersión para el O ₂	66
Figura 6.57. Matriz de confusión para el O ₂	66
Figura 6.58. Curva ROC del O ₂	67
Figura 6.59. Diagrama de coordenadas paralelas para el O ₂	68
Figura 6.60. Diagrama de dispersión para el factor LAMBDA.	69
Figura 6.61. Matriz de confusión para el factor LAMBDA.	69
Figura 6.62. Curva de ROC para LAMBDA.....	70
Figura 6.63. Diagrama de coordenadas paralelas de LAMBDA.	71
Figura 6.64. Diagrama de dispersión para AFR.	72
Figura 6.65. Matriz de confusión para el AFR.	72

Figura 6.66. Curva de ROC para el AFR.	73
Figura 6.67. Diagrama de coordenadas paralelas de AFR.	74
Figura 6.68. Variación del consumo en L/h de acuerdo al fallo provocado.	75
Figura 6.69. Gráfica de contorno de consumo en L/H vs RPM y TPS.....	75
Figura 6.70. Gráfica de contorno del consumo en L/h con respecto a la falla de dosado rico.	76
Figura 6.71. Gráfica de superficie de consumo de combustible.....	77
Figura 6.72. Gráfica de superficie con respecto a los fallos generados.	77
Figura 6.73. Comportamiento del CO con respecto a los fallos provocados.	78
Figura 6.74. Gráfica de contorno del CO vs TPS y MAP.....	79
Figura 6.75. Gráfica de contorno del CO con mezcla de dosado rico.	79
Figura 6.76. Gráfica de superficie del CO.	80
Figura 6.77. Gráfica de superficie de porcentaje de monóxido de carbono.....	80
Figura 6.78. Comportamiento del AFR con respecto a los fallos provocados.....	81
Figura 6.79. Gráfica de contorno del AFR vs TPS y VSS.	81
Figura 6.80. Gráfica de contorno con respecto a la falla de dosado rico.	82
Figura 6.81. Gráfica de superficie de la relación estequiométrica.	83
Figura 6.82. Gráfica de superficie del AFR con respecto a los fallos generados.....	83
Figura 6.83. Comportamiento de la fuerza tractora con respecto a los fallos generados.	84
Figura 6.84. Gráfica de contorno de la fuerza tractora con el vehículo en perfectas condiciones.	85
Figura 6.85. Gráfica de contorno con dosado rico.....	85
Figura 6.86. Gráfica de contorno de la fuerza tractora con dosado pobre.	86
Figura 6.87. Gráfica de superficie de la fuerza tractora con respecto a los fallos.	87
Figura 6.88. Predicción de las variables de respuesta con el vehículo en estado OK. ...	87
Figura 6.89. Predicción de valores al aplicar un dosado rico en la mezcla.....	88

Figura 6.90. Predicción de valores al aplicar un dosado pobre en la mezcla.	88
Figura 6.91. Predicción con un bajo voltaje de encendido.....	88

ÍNDICE DE TABLAS

Tabla 6.1. Variables de entrada.	19
Tabla 6.2. Variables de bloqueo.	19
Tabla 6.3. Variables de ruido.	20
Tabla 6.4. Variables de respuesta.	20
Tabla 6.5. Especificaciones del vehículo.	21
Tabla 6.6. Especificaciones generales del analizador de gases.	23
Tabla 6.7. Rango de medición.	23
Tabla 6.8. Características tarjeta de adquisición DAQ USB 6008.	24
Tabla 6.9. Identificación de los sensores.....	38
Tabla 6.10. Mediciones aplicadas en el banco dinamométrico.	38
Tabla 6.11. Valores del analizador de gases.....	38
Tabla 6.12. Estado de pruebas del motor.	39
Tabla 6.13. Efectos que producen en el motor de combustión interna.	39
Tabla 6.14. (Continuación) Efectos que producen en el motor de combustión interna. .	40
Tabla 6.15. Extracto de la base de datos utilizada en el experimento.	41

ANEXOS

Figura A 1. Gráfica de contorno de contorno del monóxido de carbono.....	94
Figura A 2. Gráfica de contorno con respecto a la falla de dosado rico.	94
Figura A 3. Gráfica de superficie del monóxido de carbono con respecto al dosado pobre.	95
Figura A 4. Gráfica de superficie del monóxido de carbono con respecto a un bajo voltaje de encendido.....	95
Figura A 5. Gráfica de contorno del consumo de combustible en L/100Km con respecto a un dosado pobre.	96
Figura A 6. Gráfica de contorno del consumo de combustible en L/100Km con respecto a un bajo voltaje de encendido.	96
Figura A 7. Gráfica de superficie con respecto a un voltaje bajo de encendido.	97
Figura A 8. Gráfica de superficie con respecto a un dosado pobre.	97
Figura A 9. Gráfica de contorno de AFR con respecto a un dosado pobre.....	98
Figura A 10. Gráfica de contorno de AFR con respecto a un bajo voltaje de encendido.	98
Figura A 11. Gráfica de superficie de AFR con respecto a un dosado pobre.	99
Figura A 12. Gráfica de superficie de AFR con respecto a un dosado rico.	99
Figura A 13. Gráfica de superficie de fuerza con respecto a un bajo voltaje de encendido.	100
Figura A 14. Gráfica de contorno de fuerza con respecto a un bajo voltaje de encendido.	100
Figura A 15. Software para la adquisición de datos.	101
Figura A 16. Software para la predicción de valores.....	102

1. INTRODUCCIÓN

En el campo automotriz, la identificación de las anomalías de los vehículos automotores se realiza de forma visual y de acuerdo a la experiencia de los mecánicos, de esta forma en algunos de los casos no se precisa de forma exacta el fallo o elemento en mal funcionamiento dentro del motor de combustión interna, por lo que en muchas ocasiones se cometen errores, lo que conlleva a pérdidas de tiempo por parte de los usuarios y pérdidas económicas.

Considerando diferentes métodos de sistemas de inteligencia artificial, utilizados para el diagnóstico y detección de fallas en motores de combustión interna, a través de las señales emitidas por los sensores que establecen el funcionamiento del motor se establece un diseño experimental para el diagnóstico de fallas mediante el análisis de las señales de las variables, de esta forma se pretende determinar y detectar las fallas presentes en el motor de combustión interna de forma más exacta, generando de esta forma un ahorro de tiempo en la detección del fallo y en la corrección del mismo, optimizando el tiempo de trabajo por parte del usuario y pérdidas económicas.

Las herramientas de aprendizaje y clasificación nos facilitan una infinidad de aplicaciones para el estudio de las variables de entrada y salida del sistema a estudiar en base a las señales de funcionamiento del motor captadas por medio de los sensores. Mediante el entrenamiento del sistema se logra establecer las características de lectura y análisis de los valores obtenidos de la señal, y en base a la experiencia del operario se establece una solución para el problema planteado.

Mantener al motor de combustión interna funcionando dentro de los parámetros de correcto funcionamiento, garantiza tener un bajo nivel de emisiones contaminantes y el mejor desempeño en las prestaciones de vehículo automotor.

En la Universidad Politécnica Salesiana, se han desarrollado diversos trabajos referentes al diagnóstico de fallas en motores de combustión interna, analizando los diferentes parámetros de funcionamiento, buscando de esta forma garantizar el mejor desempeño del motor de combustión, reducir el nivel de emisiones contaminantes, optimizar los tiempos de mantenimiento y darle el mayor tiempo de duración mediante los estudios realizados a través del diseño experimental.

2. PROBLEMA

Durante el diagnóstico de motores de combustión interna se presenta deficiencia para la determinación de fallos presentes en el mismo, por lo que se recurre a la experticia del ser humano, esto conlleva en muchas ocasiones al error, al no tener claro la falla evidente en ese momento, esto genera una mayor utilización de tiempo y recursos. Al no contar con un sistema de diagnóstico de fallos para el motor de combustión interna no es posible determinar de forma acertada el problema, lo que conlleva a empeorar el mantenimiento predictivo y preventivo, realizando un diagnóstico de forma intrusiva y con un mayor costo.

3. OBJETIVOS

3.1 Objetivo General

- Diagnosticar el estado de un motor de encendido provocado Corsa Evolution 1.4L, mediante herramientas de aprendizaje y clasificación para la determinación de fallas en el funcionamiento del motor.

3.2 Objetivos específicos

- Plantear un diseño experimental mediante el software Labview para la adquisición de datos.
- Desarrollar las corridas experimentales mediante la obtención de las señales de los sensores MAP, TPS, VSS para la recolección de los datos con diferentes parámetros de funcionamiento del motor.
- Analizar mediante herramientas de aprendizaje y clasificación, la base de datos para el diagnóstico de fallas de un motor de encendido provocado.
- Presentar la validación de los resultados obtenidos mediante métodos estadísticos y experimentales para la comprobación del software desarrollado.

4. FUNDAMENTOS TEÓRICOS

El Diagnóstico de fallas en motores de encendido provocado a través del análisis de las señales de parámetros de funcionamiento de los sensores del motor, es una técnica experimental que tiene como objetivo determinar las fallas presentes en el motor de combustión interna de una forma no intrusiva y generando menor costo de mano de obra.

4.1 Diagnóstico de fallas en motores de encendido provocado

El principal objetivo del diagnóstico de fallas, es brindar confiabilidad y disponibilidad del proceso, brindando la seguridad en la operación, evitando accidentes y daños. El diagnóstico de fallas permite determinar la ubicación, duración, tamaño y tipo de falla, basándose en los síntomas que presenta el sistema en general o en particular. (Manuel González, 2012)

Ventajas de incorporar un sistema de diagnóstico de fallas.

- a) Detectar de forma temprana fallas pequeñas con comportamiento de tiempos abruptos.
- b) Diagnosticar las fallas en los actuadores, sensores y componentes del proceso.
- c) Presentar los resultados de diagnóstico de fallas detallados.
- d) Determinar la ubicación, lugar y tamaño de la falla.
- e) Presentar resultados en pocos segundos.

4.2 Diagnóstico y detección de falla

El diagnóstico de fallas permite conocer la ubicación, duración, tamaño y tipo de falla, basándose en los síntomas que presenta el sistema en general o en particular. Un esquema propuesto por (Rolf Isermann, 2007) para aplicar el diagnóstico de fallas en general se muestra en bloques en la figura 4.1.

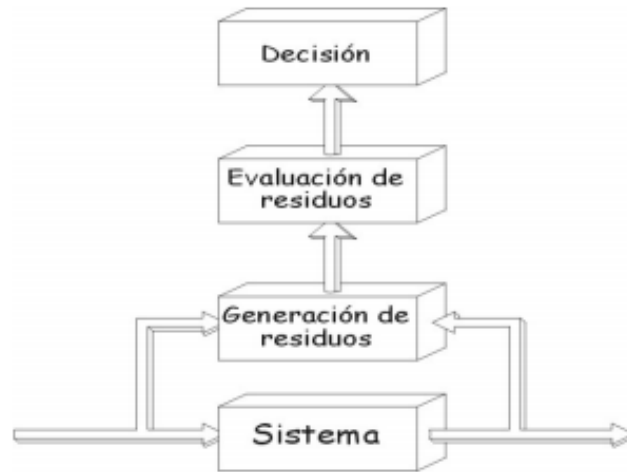


Figura 4.1. Esquema de diagnóstico de fallas

Fuente: (Rolf Isermann, 2007).

La detección de fallas se basa en el análisis de los residuos, para la determinación se utiliza un modelo de ecuaciones que relaciona la señal de salida del sistema. El análisis del residuo debe ser cuantificado y generar los síntomas del sistema. Lo que se busca con la evaluación de los residuos es determinar la falla o a su vez descartarla, esta etapa tiene por objetivo definir si hay o no una falla en el sistema. La decisión, constituye la última etapa en la que se determina y se clasifica las fallas de acuerdo a los métodos analíticos, inductivos, deductivos y experiencia del operador.

Métodos para detección de fallas. (Rolf Isermann, 2007)

- **Métodos basados en un modelo de señal:** procesan señales periódicas o estocásticas mediante el uso de funciones de correlación, análisis de Fourier, wavelets (pulsos de valor fijo basados en series de Fourier).
- **Métodos basados en el modelo del proceso:** se apoyan en señales de entrada y salida del proceso y un modelo matemático del proceso, con las comparaciones de señales se obtienen varios datos analíticos para la formulación de síntomas.

Los métodos de detección de fallas por medio de un modelo, son utilizados para detectar fallas en procesos que funcionen por medio de actuadores y sensores, obteniendo las variables de entrada y salida del sistema, en la figura 4.2, se muestra un modelo de la detección de fallas por medio de un modelo de proceso.

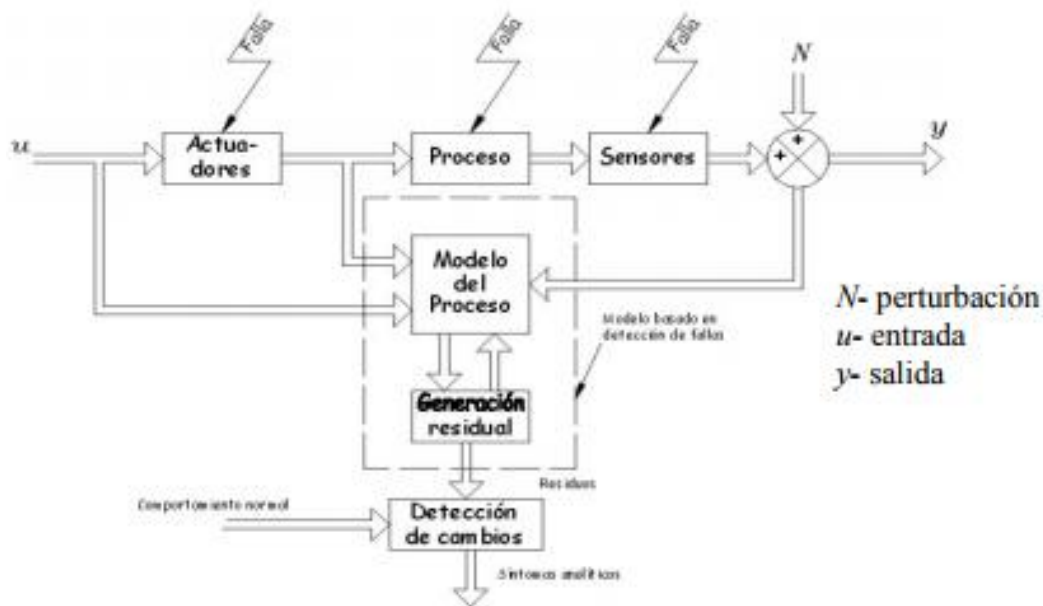


Figura 4.2. Esquema de detección de fallas.

Fuente: (Rolf Isermann, 2007)

4.3 Inteligencia artificial

La Inteligencia artificial “IA” son modelos computacionales con la capacidad de realizar actividades propias de los seres humanos, la IA se basa en dos características primordiales que son el razonamiento y la conducta. (Riobó & Ortega, 2012)

La IA tiene como finalidad que los modelos computacionales traten de simular la inteligencia humana como el conocimiento o las características propias del ser humano.

Herramientas de aprendizaje y clasificación inteligentes pueden utilizarse para examinar millones de datos que se generan en un banco en busca de patrones de comportamiento de sus clientes o para detectar tendencias en los mercados de valores.

Podemos dividir la inteligencia artificial en función de su forma de pensar y actuar en cuatro categorías. (McDermott & Charniak, 1985)

- Sistemas que piensan como humanos: Estos sistemas intentan imitar aproximadamente el pensamiento del ser humano. Uno de los ejemplos relacionados a las reacciones, modo de pensar, toma de decisiones y solución de problemas son la herramienta de redes neuronales.
- Sistemas que actúan como humanos: Existen sistemas inteligentes que imitan el comportamiento de los seres humanos, un claro ejemplo es aplicado en la robótica

en la que buscan mejorar la realización de tareas respectivas como el ensamblaje en serie de vehículos la cual mejora la realización de tareas repetitivas.

- Sistemas que piensan racionalmente: Estos sistemas tratan de imitar el pensamiento lógico racional del ser humano, el cual busca mejorar la calidad y rapidez en las respuestas para así mejorar la productividad. Los campos de aplicación más comunes son cálculos y árboles de decisión.
- Sistemas que actúan racionalmente: Este sistema tiene como finalidad asemejarse al comportamiento humano en forma racional. Los agentes inteligentes son entidades capaces de percibir su entorno y procesar sus percepciones en forma de datos de entrada y actuar de manera racional en dicho entorno.

4.3.1 Inteligencia artificial convencional

La inteligencia artificial convencional es conocida como IA simbólico-deductiva quien está basada en el análisis formal y estadístico para el comportamiento del ser humano al resolver diferentes problemas. (Takeyas & López, 2017)

4.3.2 Inteligencia artificial computacional

La inteligencia artificial computacional es conocida como “IA sub simbólica-inductiva” e “IA fuerte implica desarrollo o aprendizaje iterativo”. Este sistema se basa en el aprendizaje con datos empíricos. La IA computacional consta de varias herramientas para la toma de decisiones como son: (Takeyas & López, 2017)

- Máquina de soporte vectorial: Es un sistema que permiten el reconocimiento de patrones genéricos de gran potencia.
- Redes neuronales: Un sistema con grandes capacidades de reconocimiento de patrones o datos.
- Modelos ocultos de Markov: Este modelo de aprendizaje basado en dependencia temporal de eventos probabilísticos no utilizados en el campo automotriz.
- Sistemas difusos: Usa técnicas para lograr el razonamiento bajo incertidumbre. Este modelo se usa actualmente en la industria moderna y en productos de consumo masivo.

4.3.3 Características de la Inteligencia Artificial

Las características de la inteligencia artificial “IA” se presentan a continuación.

- Los métodos de IA, son el uso de símbolos no matemáticos, pero este método no es suficiente para distinguirlo completamente.
- El programa de IA especifica cómo encontrar la secuencia de pasos necesarios para resolver un problema dado. En contraste con los programas que no son de Inteligencia Artificial, que siguen un algoritmo definido, que especifica, explícitamente, cómo encontrar las variables de salida para cualquier variable dada de entrada.
- Los programas de IA no son fijos y son determinados parcialmente por las conclusiones intermedias alcanzadas durante las consideraciones al problema específico. Los lenguajes orientados al objeto comparten esta propiedad y se han caracterizado por su afinidad con la Inteligencia Artificial.
- Los programas de IA necesitan incorporar factores y relaciones de los seres humanos para su buen funcionamiento. Al contrario de los programas para propósito específico, como los de contabilidad y cálculos científicos; los programas de Inteligencia Artificial pueden distinguir entre el programa de razonamiento o motor de inferencia y base de conocimientos dándole la capacidad de explicar discrepancias entre ellas.
- Una de las características importantes de la IA es la aplicabilidad a datos y problemas mal estructurados ya que la inteligencia artificial logra solucionar estos problemas de una forma más rápida y eficaz.

4.3.4 Áreas de aplicación

Las primeras aplicaciones de la IA fue el desarrollo de algoritmos para juegos, en la actualidad es una rama netamente computacional que incluye áreas de rozamiento automático para la demostración de teoremas, los sistemas expertos, el procesamiento de lenguaje natural, robótica, lenguajes y ambientes de IA, aprendizaje, redes neuronales, algoritmos genéticos. Las áreas de aplicación de la IA tienen características similares, en la industria automotriz entre las que se pueden mencionar las siguientes (Ejíque & Valásquez, 2011)

1. La inteligencia artificial en la industria automotriz permite automatizar procesos para incrementar la productividad, un claro ejemplo son las ensambladoras de las partes del automóvil a través de una banda con sensores, en la que permite a las empresas alcanzar niveles de producción mayores con respecto a la mano de obra.
2. La IA permite mejorar la calidad al momento del ensamblaje del vehículo ya que puede alcanzar buenos niveles de precisión en el momento de la producción del vehículo.
3. Otra aplicación de la IA consiste en realizar pruebas para garantizar la seguridad del pasajero al momento de sufrir un accidente en el vehículo, y reducir al mínimo las lesiones en el momento de la colisión.

4.4 Árboles de decisión

Esta técnica se centra más en métodos para el aprendizaje de modelos comprensibles, que se basan en sistemas de reglas. Este método es uno de los más fáciles de utilizar y entender, ya que está organizado de una manera jerárquica, donde la decisión final a tomar se puede determinar seleccionando condiciones que se cumplan desde el nodo raíz del árbol hasta alguna de las hojas, simulando el razonamiento normal del ser humano. (Maldonado & Guevara, 2012)

Las ventajas de los árboles de decisión es que toman decisiones dependiendo de las opciones posibles a partir de una determinada condición. Los árboles permiten llegar a una sola acción o decisión a tomar dependiendo la situación o el camino del árbol. (Maldonado & Guevara, 2012)

4.4.1 Construcción del árbol

Un árbol de decisión está constituido de un conjunto de nodos y arcos. Un árbol contiene un nodo raíz el que representa la población y arcos de entrada y también está constituido por nodos terminales que representan la partición final. (Hernandez & Cardona, 2015)

Nodos intermedios cuyos arcos salientes apuntan a los nodos hijos. El algoritmo de clasificación traduce la información en un diagrama recursivo que se traduce en los siguientes pasos:

1. El nodo raíz es dividido en subgrupos ya sea de dos o más, determinados por la partición de una variable predictora elegida, generado por nodos hijos.
2. Los nodos hijos se encuentran divididos en particiones de una nueva variable. El proceso recursivo se repite para los nuevos nodos hijos sucesivamente hasta que se cumpla alguna condición de parada del árbol de decisión.
3. Algunos de los nodos resultantes son terminales, mientras que otros nodos continúan dividiéndose hasta llegar a un nodo terminal.
4. En cada árbol se cumple la propiedad de tener un camino único entre el nodo raíz y cada uno de los demás nodos del árbol.

El la figura 4.3, se muestra la estructura básica de un árbol de decisión.

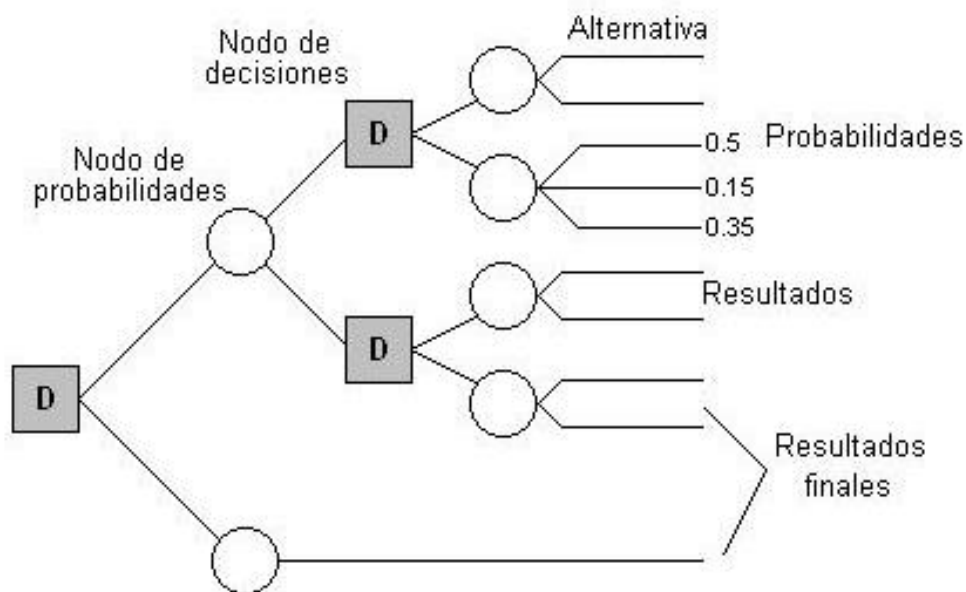


Figura 4.3. Estructura del árbol de decisión.

Fuente: (Hernandez & Cardona, 2015)

Una de las partes fundamentales de los árboles de decisión es la unión de los nodos que se realizan mediante ramas, que son las que brindan los posibles caminos de acuerdo con las decisiones que se tomen en cada nodo.

Para resolver el problema con el árbol de decisión hay que calcular el valor de cada uno de los resultados, evaluando las consecuencias inciertas en los nodos de probabilidad

multiplicando el valor en esos nodos por la probabilidad de que ocurran los sucesos. Cuando se tiene todos los resultados se puede tomar la decisión más beneficiosa.

Las ventajas de este método son:

- Plantear el problema de manera clara con todas sus opciones.
- Se basa en un esquema que cuantifica el coste de cada resultado y la probabilidad de que éste suceda.
- Se analizan todas las consecuencias de las decisiones tomadas.

4.5 Máquinas de soporte vectorial

Las máquinas de soporte vectorial “SVM” es un sistema de aprendizaje utilizado para la clasificación y regresión de conjuntos de datos de alta dimensión.

Las MSV tienen grandes capacidades de resolución de problemas con gran cantidad de datos, pocas muestras de datos y problemas no lineales. Este sistema es utilizado para problemas de clasificación binaria. (Liu, Hou , Pingjie , Banteng , & Huayi, 2013)

La idea central de esta técnica es determinar una separación lineal (hiperplano separador), el cual es orientado en dirección tal que su distancia a los puntos de datos más cercanos en cada una de las dos clases sea la máxima. Los puntos de datos más cercanos son conocidos como vectores de soporte. (Andre, Beltrame, & Wainer)

Las SVM consisten en generar datos de entrada para el entrenamiento y validación del sistema. Las corridas de las SVM es adecuado este se encuentra listo para recibir datos de prueba. A continuación se muestra un resumen del funcionamiento del sistema propuesto para dicha corrida experimental. (Acosta & Nieto , 2014)

1. Se genera una base de datos en modo de operación normal del equipo, máquina, etc.
2. Genera una base de datos en modo de falla del equipo a analizar.
3. Se entrena a las Máquinas de Soporte Vectorial con el comando Toolbox.
4. Se evalúa su desempeño, si no es aceptable con valores menores a 60% de aprobación regrese al paso anterior, si es aceptable continúe con valores mayores a un 70%.
5. Se toman datos de prueba.
6. Se prueban los datos con SVM, si no detecta alguna falla regrese al paso anterior.

7. Diagnóstico, muestra la variable en falla y su localización.

En la figura 4.4, se realiza el proceso del sistema propuesto.

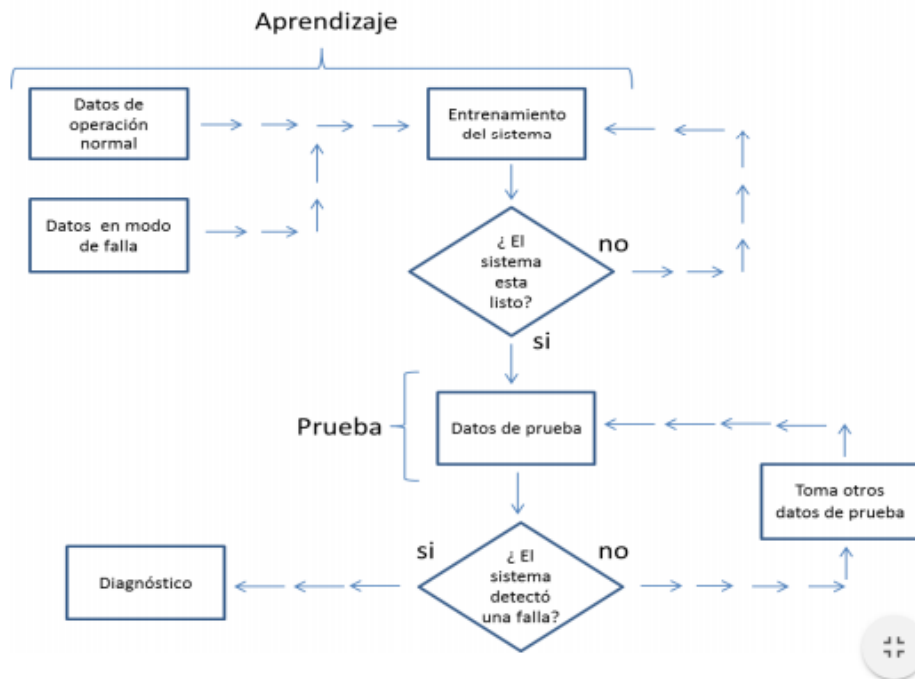


Figura 4.4. Metodología basada en MSV.

Fuente: (Acosta & Nieto , 2014)

La SVM muestra varias clases como se muestra en la figura 4.5, que representan datos de cuadrados azules y círculos verdes separados por el hiperplano que maximiza la distancia entre ellos. Esta distancia es la marcada como margen, que es máxima para el hiperplano obtenido en este caso, cualquier otro hiperplano presentaría un margen de separación de clases menor y por lo tanto sería menos adecuado.

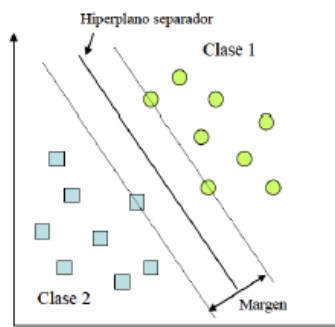


Figura 4.5. Separación de datos mediante SVM.

Fuente: (Acosta & Nieto , 2014)

Tras el aprendizaje se comprueba el error cometido tomando una nueva muestra de datos y comparando la salida que obtenemos con su clase real. De cada muestra de datos se suele tomar un 75% como vectores de aprendizaje y el 25% de los vectores restantes se utilizan para poder contrastar la fiabilidad de la frontera de decisión obtenida.

Para que los modelos sean sólidos y brinden fiabilidad es necesario la calibración del modelo. En el momento que los resultados no sean los deseados se deberán aumentar los datos de entrenamiento hasta obtener una correcta clasificación.

La dificultad al momento de entrenar las SVM es hacerlo con un mínimo de datos de entrenamiento, ya que a más datos mayor es el coste de aprendizaje, de este modo se consigue mayores índices de fiabilidad/coste.

4.5.1 Máquinas de soporte vectorial para clasificación binaria

Las SVM para clasificación binaria binaria consta de 2 clases:

Clase positiva ($y = 1$) y clase negativa ($y = -1$) este tipo de clases son limitaciones en el lenguaje de programación, donde podría tomar pareja de valores tanto como positiva (1), negativa (-1), positiva (0), negativa (0). (Riobó & Ortega, 2012)

Las SVM tienen varios métodos para resolución más cómoda y eficaz en cuanto al tipo de datos, cantidad que tengamos, ya que dichos datos sean linealmente separables pero las entradas es muy posible que sean no separables linealmente o que exista un cierto nivel de ruido en las medidas que las distorsione al momento de la recopilación de los datos. En estas situaciones se pueden emplear distintos tipos de SVM que se explicarán en los siguientes ítems:

- SVM para la clasificación no lineal.
- SVM con margen blando.

4.5.1.1 Máquinas de soporte vectorial para la clasificación no lineal

Es posible que los datos de entrada no sean linealmente separables (Burges C. , A Tutorial on Support Vector Machines for Pattern Recognition, 2012) como se muestra en la figura 4.6.




Figura 4.6. Ejemplo de un conjunto de datos linealmente no separables.

Fuente: (Burges C. , A Tutorial on Support Vector Machines for Pattern Recognition, 2012)

Cuando un conjunto de datos linealmente no separables tiene la posibilidad de transformar los datos a un espacio ζ de mayor dimensión en el que los puntos si pueden ser separados por un hiperplano. Para ello, se utiliza una función Φ , tal que:

- $\Phi: \mathcal{R}^d \rightarrow \zeta$
- $x \rightarrow \Phi(x)$

La función Φ , como muestra la figura 4.7, mueve los datos de entrada que no son linealmente separables a un espacio de mayor dimensión de 3D donde si podremos encontrar un hiperplano que los separe y se pueda visualizar de mejor manera.

La frontera de decisión resultante en el espacio de entrada ya no será lineal y vendrá dada por otro tipo de función que puede ser polinómica de grado distinto a 1, gaussiana. La función núcleo o kerner se usan para poder resolver esta transformación.




Figura 4.7. Transformación de los datos de entrada a un espacio de mayor dimensión.

Fuente: (Burges C. , A Tutorial on Support Vector Machines for Pattern Recognition, 2012)

4.5.1.2 Máquinas de soporte vectorial lineal con margen blando

Los casos de máquinas de soporte vectorial lineal con margen blando se utilizan cuando puede existir ruido debido a errores en la toma de los datos o por la presencia de algún dato atípico. En estos casos no se utiliza las SVM por que los datos se ajustan totalmente.

En la figura 4.8, contienen dos conjuntos de datos y la frontera de decisión que se obtendría con las máquinas de soporte vectorial de margen máximo. El conjunto de puntos amarillos se encuentran agrupados con excepción de un punto que se encuentra muy próximo a los datos de la otra clase, el cual corresponde con un dato atípico o que el punto que ha sido clasificado por error, este punto debería ser considerado para hallar la frontera de decisión ya que podría alterar los resultados deseados y nos llevaría a clasificaciones incorrectas.




Figura 4.8. Clasificación con SVM de margen máximo con datos entre los que existe un dato atípico.

Fuente: (Burges C. , A Tutorial on Support Vector Machines for Pattern Recognition, 2012)

4.5.2 Máquinas de soporte vectorial para clasificación multiclase

Cada modelo u obtención de datos representa una categoría distinta, ya que al momento de la adquisición de los datos en la lectura real del sensor solo coinciden con un modelo dado, por lo que se resolverá de tantas clases como modelos creados.

Una de las soluciones para resolver este problema multiclase es convertirlo en varios binarios. Para ello, existen 2 métodos distintos:

- Clasificación 1-v-r (one-versus-rest): en cada uno de los problemas se considera una clase positiva y las demás negativas, por lo que habrá que hallar tantos hiperplanos como clases existan.
- Clasificación 1-v-1 (one-versus-one): para cada problema se toman 2 clases de las K totales. Se compara cada clase con cada una de las restantes, lo que supone realizar $K(K - 1)/2$ clasificaciones.

La clasificación tipo 1-v-r es el más habitual y en el que se realizan menos comparaciones, lo que se traduce en menos gasto computacional en comparación de la clasificación 1-v-1.

5. ESTADO DEL ARTE

5.1 Diagnóstico de fallas

Es el proceso completo que permite detectar una falla y las acciones posteriores realizadas en base a la información obtenida, puede dividirse en tres etapas principales: detección, diagnóstico y corrección. (Basseville, 1998)

El Diagnóstico de fallas es el uso de modelos. Este método se basa en el empleo de modelos del proceso para el estado normal y/o para cada una de las diferentes fallas que se desean observar, y posteriormente analizar qué tan parecidas son las estimaciones de cada modelo con las observaciones realizadas del proceso real, tal como se muestra en la figura 5.1. La forma de analizar las diferencias entre los modelos y las observaciones, llamados residuos, es muy variada, pasando desde los sistemas expertos, hasta complejas redes neuronales, máquinas de soporte vectorial. (Carrasco, 2007)

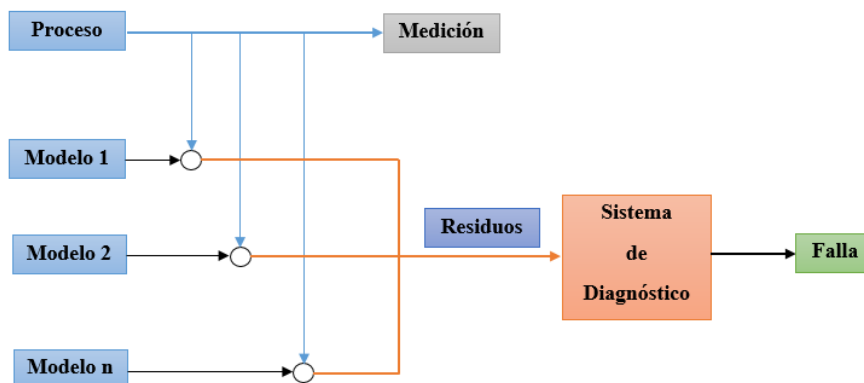


Figura 5.1. Diagnóstico de Fallas en base a modelos.

Fuente: (Carrasco, 2007)

5.2 Herramientas de aprendizaje y clasificación para motores de combustión interna

El motor de combustión interna (ICE) es un tipo especial de máquina alternativa y giratoria que es una parte esencial de cada automóvil e industria en nuestra vida moderna diseñadas principalmente para el transporte de persona, transporte de carga, etc, donde cuentan con sistemas paralelos de apoyo que permiten identificar fallas y posibles riesgos durante el funcionamiento de los mismos. Esto permite evitar la necesidad de poner en peligro la vida de las personas que realizan el diagnóstico y mantenimiento. También permiten incrementar la vida útil de los motores de combustión interna, ya que reduce la necesidad de realizar detenciones rutinarias de revisión, pues son los propios sistemas los que se encargan de realizar un diagnóstico de sus estados y de las posibles complicaciones que se presenten.

Existe un gran número de investigaciones, tanto teórico como práctico, de sistemas de detección y diagnóstico de fallas aplicadas a motores de combustión interna. La mayoría de estas investigaciones se encuentran enfocados al diagnóstico de fallos con herramientas de aprendizaje y clasificación en motores de combustión interna, ya que cada investigador busca una forma diferente de resolver el problema en estos sistemas ya sea en motores de encendido provocado o motores de encendido por compresión.

Una de las investigaciones que se ha realizado es sobre el diagnóstico de fallas en motores de combustión interna utilizando modelos matemáticos y computacionales respecto a las redes neuronales. En este artículo de (Mahmood, 2014), se propone una técnica eficaz y automatizada para diagnosticar las fallas. A diferencia de los métodos existentes en este campo, la señal emitida de la "ICE" se explota como el portador de información de las fallas, la descomposición de paquetes wavelet se utiliza como herramienta de extracción de características, y, finalmente, la extensión artificial de las redes neuronales "ENN" la cual es utilizada para la clasificación de las características extraídas. Las ENN constan de dos parámetros como la capa de entrada y la capa de salida. Estos parámetros de estructura simple de la "ENN" mejoran el rendimiento en comparación con las redes neuronales tradicionales y nos permite insertar fácilmente cualquier nueva información, como una nueva falla o nueva característica del motor de combustión interna a analizar. Por lo tanto, "ENN" es adaptable para nueva información simplemente agregando nuevos nodos sin afectar a la red construida previamente.

Un artículo similar de (Bo & Qin, 2010), dice que con el fin de mejorar la efectividad del diagnóstico y la calidad de mantenimiento, es primordial estudiar el método de diagnóstico de fallas para motores de combustión interna con máquinas de soporte vectorial de mínimos cuadrados. La cual es llamada LSSVM es modificación de las máquinas de soporte vectorial “SVM”, que utilizan un conjunto de ecuaciones lineales en lugar de un problema de programación cuadrático. El artículo sobre las máquinas de soporte vectorial de mínimos cuadrados se propone para diagnosticar fallas de motores de automóvil. El modelo de diagnóstico LSSVM incluye dos LSSVM que se utilizan para reconocer los tres estados del motor del automóvil las que se dividen en el estado normal, misfire (fuego perdido) de bajo grado y misfire (fuego perdido) grave.

Los grados de fuego perdido se presentan para probar la capacidad de diagnóstico del método propuesto. Los resultados obtenidos indican que el método LSSVM utilizado puede hacer una interpretación eficaz en el diagnóstico de fallas del motor de un automóvil más efectiva que “SVM”.

Usando un sistema diferente de herramientas de aprendizaje y clasificación, (Luini Leonardo Hurtado-Cortés, 2016), presenta el estado actual de las técnicas de inteligencia artificial y su aplicación al campo de la detección y diagnóstico de fallas en sistemas dinámicos. Inicialmente, se explica una breve descripción de lo que se considera un mecanismo para la detección y diagnóstico de fallas, y los enfoques actuales para el estudio y la implementación de tales mecanismos. Posteriormente, se presentan los resultados más importantes de las diversas técnicas de inteligencia artificial aplicadas a la detección y diagnóstico de fallas. Finalmente, se presenta un análisis comparativo basado en las características deseadas de los mecanismos de detección y diagnóstico de fallas.

Otro de los métodos utilizados se basa en árboles de decisión que permite el diagnóstico de la condición de la máquina basada en el sistema experto. En este trabajo, se construye y experimenta un sistema experto - árbol de decisión para diagnosticar y detectar defectos de los motores de combustión interna. El objetivo principal de este estudio es proporcionar una forma sencilla de monitorear el estado de la máquina mediante la síntesis de los conocimientos y experiencias sobre los casos diagnósticos de la maquinaria rotativa. Se ha construido un árbol tradicional de decisiones utilizando insumos basados en vibraciones. (Ngoc-Tu Nguyen, 2007)

6. MARCO METODOLÓGICO

6.1 Desarrollo del diseño experimental para la adquisición de datos

6.1.1 Planificación del experimento

Para el desarrollo del experimento se debe determinar los diferentes parámetros que se van a analizar y los resultados que se desea obtener, a más de esto los diferentes factores que pueden intervenir en las respuestas que se obtienen del sistema. Entre los factores que intervienen en el desarrollo del sistema se tienen las siguientes variables de análisis. Entre las que se tiene las variables de entrada, bloqueo, ruido y respuesta, como se muestra en la figura 6.1. (Rivera & Chica, 2015)

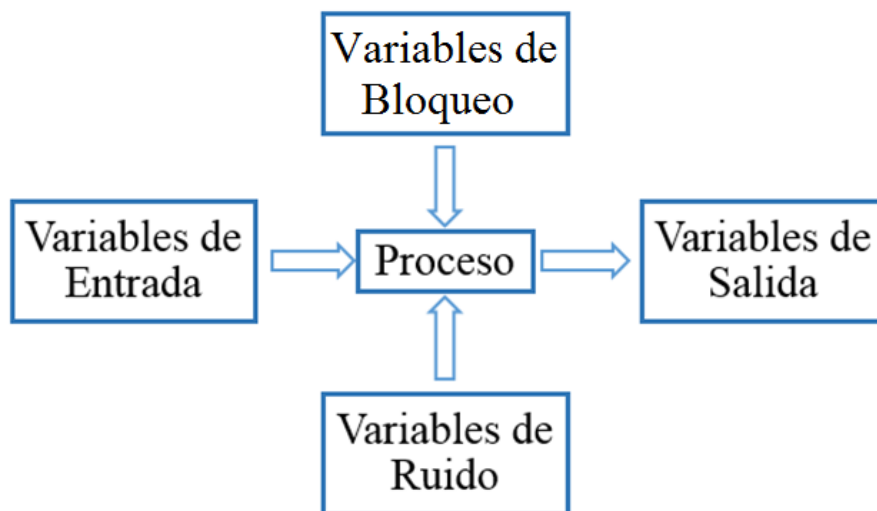


Figura 6.1. Proceso del desarrollo de la planificación del experimento.

Fuente: Autores.

6.1.2 Variables de entrada

Son también conocidos con el nombre de variables de estudio, son aquellos factores que influyen de forma directa en las variables de respuesta del sistema, estas no deben tener dependencia entre sí, es decir la variación de un factor de estudio no debe influir en la variación de otro factor de estudio, de esta manera se evita errores durante el desarrollo del experimento, en la tabla 6.1, se establece los parámetros utilizados como variables de entrada.

Tabla 6.1. Variables de entrada.

Fuente: Autores.

Variables de entrada	Abreviación	Condición de funcionamiento
Fala 1: dosado rico	falla 1	60 psi
Falla 2: dosado pobre	falla 2	40 psi
Falla: voltaje de encendido bajo	falla 3	Apertura de 1.3 mm
Sensor de presión de aire	MAP	4.8 a 5.2 volt
Sensor de posición de mariposa	TPS	4.8 a 5.2 volt
Revoluciones del motor	RPM	0 a 5 volt
Sensor de velocidad del motor	VSS	3.2 volt

6.1.3 Variables de bloqueo

Son también denominadas como los factores controlables, de igual forma son variables de entrada del sistema a experimentar, pero en este caso estas no influyen sobre las respuestas que se desea obtener del sistema, en la tabla 6.2, se especifica las variables de bloqueo analizadas en nuestro experimento.

Tabla 6.2. Variables de bloqueo.

Fuente: Autores.

Variables de bloqueo	Valor	Unidad
Temperatura del líquido refrigerante	92	°C
Temperatura de la banda de rodadura	30	°C
Temperatura del lubricante	95	°C

6.1.4 Variables de ruido

Estas variables son las que presentan mayor dificultad durante el desarrollo del experimento, no son fáciles de controlar, el funcionamiento del sistema se verá afectado de acuerdo a las condiciones climáticas de la ciudad de Cuenca, al desarrollar el estudio sin controlar estas variables se tendrá comportamientos inadecuados en la respuestas del sistemas, en la tabla 6.3, se detallan las variables de ruido presentes durante el desarrollo del estudio.

Tabla 6.3. Variables de ruido.

Fuente: Autores.

VARIABLES DE RUIDO	SÍMBOLO	UNIDAD
Temperatura del aire	T_{aire}	°C
Temperatura del combustible	T_{comb}	°C
Humedad relativa del aire	H_{rel}	%
Presión atmosférica	P_{atm}	Pa

6.1.5 Variables de respuesta

Son las variables de salida del sistema, lo que se busca es encontrar la mejor manera de adecuar las respuestas a las necesidades del usuario para lograr la identificación del fallo y su posterior corrección, en la tabla 6.4, se muestra las variables de salida analizadas en el estudio.

Tabla 6.4. Variables de respuesta.

Fuente: Autores.

VARIABLES DE RESPUESTA	SÍMBOLO	UNIDAD
Monóxido de carbono	CO	%
Dióxido de carbono	CO ₂	%
Oxígeno	O ₂	%
Hydrocarburos no combustionados	HC	ppm
Óxidos nitrosos	NOx	ppm
Fuerza	F	N
Potencia	P	Kw
Consumo 1	-	L/h
Consumo 2	-	L/100Km
Velocidad	V	Km
RPM	RPM	rev/min

6.1.6 Unidad experimental

6.1.6.1 Vehículo de pruebas

El vehículo utilizado en la realización de las pruebas es un vehículo marca Chevrolet Corsa Evolution 1.4L, que se muestra en la figura 6.2. El vehículo fue utilizado para el muestreo en parámetros de correcto funcionamiento, posteriormente para el desarrollo del experimento se aplicaron algunas alteraciones en el funcionamiento del mismo.



Figura 6.2. Vehículo de pruebas Chevrolet Corsa Evolution 1.4L.

Fuente: Autores.

En la tabla 6.5, se detallan las diferentes características del vehículo utilizado:

Tabla 6.5. Especificaciones del vehículo.

Fuente: (Granda & Herrera, 2017)

Especificación	Detalle
Modelo	Corsa Evolution
Tipo	Powertech 1,4 SOHC
Potencia máxima	83,7 HP @ 6000 RPM
Torque	113,56 N.m @ 3000 RPM
Cilindrada	1398 cm ³
Sistema de inyección	Multipunto
Relación de compresión	9,5 : 1
Número de cilindros	4 en line
Distribución	SOHC
Neumáticos	165/70 R13

6.1.6.2 Banco dinamométrico

Para el desarrollo del experimento se utiliza el banco dinamométrico MAHA LPS 3000, tanto para la generación de carga y la toma de datos, el banco está constituido por un freno dinamométrico, el mismo que genera carga y arroja los valores en las pruebas de fuerza tractora y potencia del vehículo en las pruebas.

El banco está constituido por una consola de sensores que permite monitorear en todo momento las condiciones de trabajo durante las pruebas, como son la presión atmosférica,

temperatura del aire y la humedad relativa. La visualización de los resultados obtenidos se da por medio del monitor de un computador. (Rivera & Chica, 2015)



Figura 6.3. Banco dinamométrico MAHA LPS 3000.

Fuente: Autores.

6.1.6.3 Analizador de gases

En la figura 6.4, se muestra el analizador de gases modelo Nextech NGA 6000, utilizado para obtener los valores de gases de combustión durante las pruebas realizadas, gases como CO, HC, CO₂, O₂ y valores de LAMBDA Y AFR.



Figura 6.4. Analizador de gases Nextech NGA 6000.

Fuente: Autores.

En la tabla 6.6, y 6.7, se detallan las características del analizador de gases utilizado.

Tabla 6.6. Especificaciones generales del analizador de gases.

Fuente: (Setamer, 2017)

Especificación	Detalle
Elementos de medición	CO, CO ₂ , HC, O ₂ , LAMBDA, AFR, NO _x
Método de medición	CO, HC, CO ₂ , método NDIR O ₂ , NO _x , célula electroquímica
Fuente de alimentación	AC 110V
Consumo de energía	50W
Temperatura de operación	0°C – 40°C
Dimensiones	420 x 200 x 100 mm

Tabla 6.7. Rango de medición.

Fuente: (Setamer, 2017)

Medición	Rango de medición
CO	0.00-9.99%
HC	0-9.999%
CO ₂	0.0-20%
O ₂	0.0-20%
LAMBDA (λ)	0-2000
AFR	0.0-99.0
Nox	0-5.000ppm

6.1.6.4 Tarjeta de adquisición de datos

En la figura 6.5, se presenta la tarjeta de adquisición de datos DAQ USB 6008, utilizada para la recopilación de datos.



Figura 6.5. Tarjeta de adquisición de datos DAQ USB 6008.

Fuente: (National Instruments, 2017)

En la tabla 6.8, se especifican las características técnicas de la tarjeta de adquisición de datos.

Tabla 6.8. Características tarjeta de adquisición DAQ USB 6008.

Fuente: (National Instruments, 2017)

Especificación	Detalle
Tipo de medida	Voltaje
Canales de entrada analógica	8
Resolución de entrada analógica	12 bits
Rango de voltaje máximo en la entrada analógica	-10 V hasta 10 V
Precisión del voltaje máximo en la entrada analógica	7.73 mV
Rango de voltaje mínimo en la entrada analógica	-1 V hasta 1 V
Precisión del voltaje mínimo en la entrada analógica	37.5 mV
Canales de salida analógica	2
Resolución de salida analógica	12 bits
Rango de voltaje máximo en la salida analógica	0 V hasta 5 V
Precisión del voltaje máximo en la salida analógica	7 mV
Rango de voltaje mínimo en la salida analógica	0 V hasta 5 V
Precisión del voltaje mínimo en la entrada analógica	7 mV
Capacidad de corriente total	10 mA

6.1.6.5 Presión de combustible

Para el desarrollo del experimento se utilizó un manómetro, cuya función primordial es la de mantener la presión de combustible para el funcionamiento del motor, en la figura 6.6, se especifica el manómetro utilizado para variar la presión de combustible, utilizado durante las pruebas realizadas.




Figura 6.6. Manómetro de presión de combustible.

Fuente: Autores.

6.1.6.6 Sensores

La principal función de un sensor es transformar una magnitud física en magnitud eléctrica, son dispositivos o elementos electrónicos encargados de enviar las señales de funcionamiento a la unidad de control ECU, para determinar el estado de funcionamiento del motor y tomar medidas de corrección para garantizar un buen desempeño del motor.

6.1.6.6.1 Sensor MAP

El sensor MAP, o sensor de presión absoluta del colector de admisión, es el encargado de determinar la presión absoluta en el interior del colector de admisión, la presión medida es transformada en una señal eléctrica, que es enviada a la unidad de control ECU, con información que calcula el nivel de carga del motor, avance del punto de encendido y tiempo de inyección. En la figura 6.7, se puede observar la señal generada por el sensor MAP. (Gonzalez, 2015)




Figura 6.7. Señal generada por el sensor MAP.

Fuente: (Gonzalez, 2015)

6.1.6.6.2 Sensor TPS

El TPS o sensor de posición del acelerador tiene como su principal función enviar a la ECU una señal que indica la posición de la mariposa de aceleración.

El sensor está montado en el cuerpo de aceleración y convierte el ángulo de posición de la mariposa del cuerpo de aceleración en una señal eléctrica. De acuerdo a la posición de la mariposa, si esta se abre el voltaje de la señal incrementa, si la mariposa del cuerpo de

aceleración reduce su apertura el voltaje disminuye. En la figura 6.8, se detalla el diagrama de funcionamiento del sensor TPS. (Gonzalez, 2015)

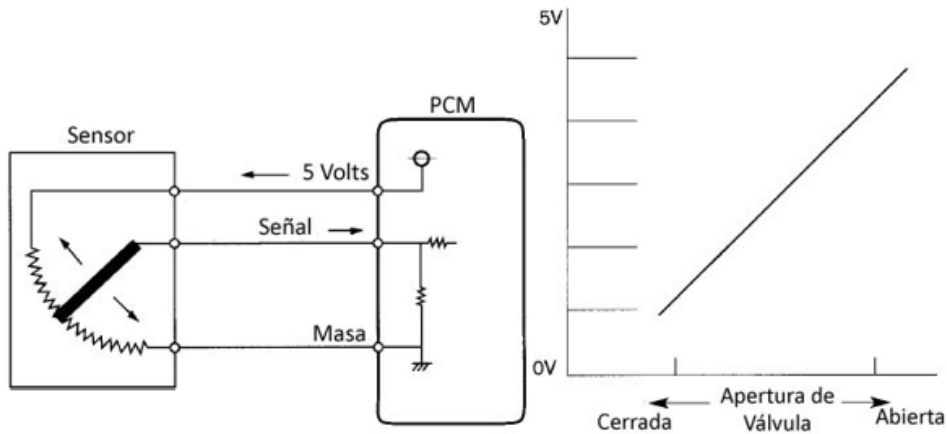


Figura 6.8. Diagrama de funcionamiento del sensor TPS.

Fuente: (Gonzalez, 2015)

6.1.6.6.3 Sensor VSS

El sensor de velocidad del vehículo o VSS, es el encargado de medir la velocidad de transmisión, el sensor proporciona una señal de corriente alterna a la ECU la cuál es interpretada como velocidad del vehículo. Este sensor es un generador de imán permanente montado en el transeje, el imán genera una onda de corriente alterna que es directamente proporcional a la velocidad del vehículo. Al aumentar la velocidad del vehículo aumenta la frecuencia, entonces la ECU toma esta información, la cual informa al usuario de la velocidad de desplazamiento del vehículo automotor. En la figura 6.9, se muestra el sensor utilizado en el vehículo de pruebas. (Gonzalez, 2015)




Figura 6.9. Diagrama de funcionamiento del sensor VSS.

Fuente: (Gonzalez, 2015)

6.1.7 Programa para la adquisición de datos

Para la elaboración del experimento se desarrolla un programa de adquisición de datos, el mismo que se elaboró en el software Labview, mediante este programa se extraen las señales de funcionamiento de los sensores del vehículo a analizar, como son los sensores TPS, VSS y MAP, la función del programa es leer las señales en un determinado tiempo de muestreo y almacenar los datos de funcionamiento en una hoja de cálculo para su posterior clasificación y análisis.

6.1.7.1 Software Labview

El software Labview (Laboratory Virtual Instrument Engineering Workbench), es un lenguaje de programación gráfico diseñado para desarrollar aplicaciones de pruebas, control, medidas y adquisición de datos. La principal función es de adquirir los datos, mediante la medición con un computador, estos datos adquiridos son productos de fenómenos eléctricos como físicos, como es el caso de voltaje, corriente, temperatura, presión o sonido. (National Instruments, 2017)



Figura 6.10. Lectura de señales.

Fuente: (National Instruments, 2017)

6.1.7.1.1 Ventajas de Labview

- La programación se realiza de forma gráfica.
- Se permiten actualizaciones de hardware y software.
- El sistema no requiere de mayor experiencia ya que su programación es intuitiva.
- Se pueden generar sistemas complejos.
- El sistema integra funciones de adquisición, análisis y presentación de datos.
- El software permite trabajar a velocidades muy altas de procesamiento de datos.

6.1.7.2 Tarjeta de adquisición de datos DAQ 6008

En el desarrollo del software para la toma de datos se, utilizó una tarjeta de adquisición de datos para la lectura de señales de funcionamiento de los sensores del vehículo automotor, la tarjeta de adquisición de datos DAQ 6008, es utilizada para aplicaciones como registro de datos, medidas portátiles y experimentos académicos de laboratorio.

La tarjeta de adquisición de datos está constituida de la siguiente manera, tiene una entrada y una salida analógica, así como una entrada y una salida digital, un cable de conexión por puerto USB al computador, en la figura 6.11, se aprecia las partes dispuestas por la tarjeta DAQ USB 6008.




Figura 6.11. Partes externas del dispositivo DAQ USB 6008.

Fuente: (Targera.daq, 2015)

1. Etiqueta de superposición con guías de orientación de alfileres.
2. Enchufe del conector del terminal de tornillo.
3. Etiqueta de señal.
4. Cable USB.

En la figura 6.12, se puede identificar los bloques de constitución de la tarjeta.




Figura 6.12. Diagrama de bloques de la tarjeta de adquisición de datos.

Fuente: (Targera.daq, 2015)

A continuación en la figura 6.13, se muestra los pines de conexión de la tarjeta.




Figura 6.13. Pines de conexión.

Fuente: (Targera.daq, 2015)

6.1.7.3 Software de adquisición de datos

En la figura 6.14, se muestra la interfaz utilizada en el software Labview con los diferentes comandos que tienen una función específica dentro del programa, en los puntos a continuación se detalla la función de cada bucle.




Figura 6.14. Interfaz de Labview utilizada en la elaboración del software.

Fuente: Autores.

6.1.7.3.1 Tiempo de muestreo

El tiempo de muestreo contiene un Bucle While, es una estructura que repite una sección de código hasta que se cumpla una condición determinada, en este caso la función principal del bucle es grabar el tiempo de muestreo de las pruebas a realizar. En la figura 6.15, se muestra la configuración del tiempo de muestreo.




Figura 6.15. Obtención del tiempo de muestreo en el software Labview.

Fuente: Autores.

6.1.7.3.2 Adquisición de datos

La función Index Array, es utilizada para la adquisición de datos y devuelve el dato de la posición en la que se ha indicado en el programa LABVIEW como se indica en la figura 6.16.




Figura 6.16. Adquisición de datos.

Fuente: Autores.

6.1.7.3.3 Frecuencia de la señal

El Timing and Transition Measurements mide los parámetros de sincronización y transición en impulsos individuales y en bordes ascendentes y descendentes.

Si la señal incluye un solo impulso positivo o negativo o un tren de impulsos, puede medir la frecuencia del pulso, el período ($1 / \text{frecuencia}$), la duración y el ciclo de trabajo. En la figura 6.17, se muestra el bloque que calcula la frecuencia de las señales de los sensores en Hertz.

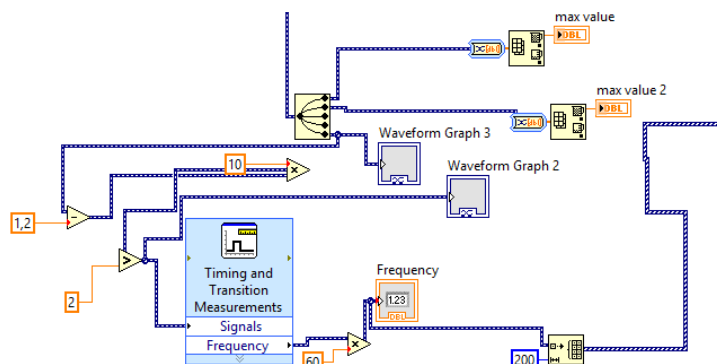


Figura 6.17. Frecuencia de lectura de la señal.

Fuente: Autores.

6.1.7.3.4 Generación de hoja de cálculo

El Case Structure, permite el almacenamiento de datos que se obtiene con la corridas experimentales en una hoja de cálculo, a través de un comando como se muestra en la figura 6.18.

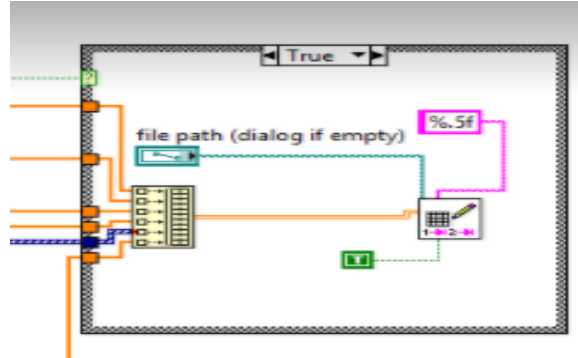


Figura 6.18. Almacenamiento de los datos en la hoja de cálculo.

Fuente: Autores.

6.1.7.3.5 Adquisición de datos

La función Continue Samples o modo de adquisición, se ocupa para grabar los datos de forma continua en la tarjeta de adquisición de datos DAQ, para el que se determina una frecuencia de toma de muestreo de 2k, esta función es la recomendada para la lectura de las señales de campo automotriz. En la figura 6.19, se muestra la configuración de la función Continue Samples.

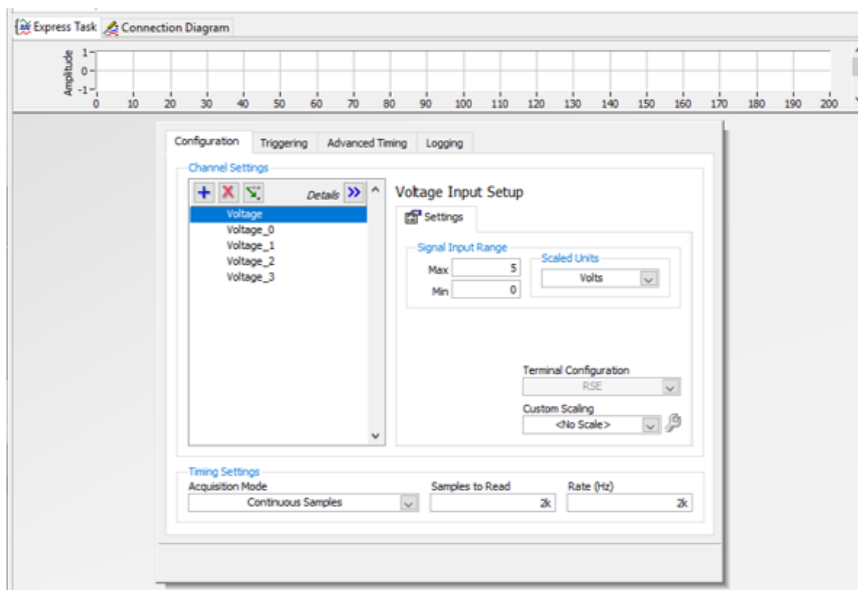


Figura 6.19. Función Continue Samples.

Fuente: Autores.

6.1.7.3.6 Disposición de los diferentes elementos para la experimentación

Para la toma de datos se dispuso del montaje del vehículo en el banco dinamométrico MAHA LPS 3000, donde se realizó la conexión de los sensores del vehículo al computador por medio de la tarjeta de adquisición de datos, también se ubicó el analizador de gases para la lectura de los valores de emisiones de gases generados durante las pruebas, en la figura 6.20, se puede apreciar la disposición de los equipos de muestreo.




Figura 6.20. Disposición de los equipos de muestreo.

Fuente: Autores.

6.2 Desarrollo de las corridas experimentales mediante la obtención de las señales de los sensores MAP, TPS, VSS para la recolección de los datos con diferentes parámetros de funcionamiento del motor

6.2.1 Toma de datos

Las pruebas correspondientes a las corridas experimentales se desarrollaron en los laboratorios de la Carrera de Ingeniería Mecánica Automotriz de la Universidad Politécnica Salesiana Sede Cuenca.

Para las pruebas el vehículo debe estar correctamente ubicado y asegurado con las correas de sujeción en el banco dinamométrico, así como los equipos de adquisición de datos debidamente conectados, equipos de seguridad y disponer las herramientas necesarias para efectuar los cambios entre corridas como se muestra en la figura 6.21.



Figura 6.21. Banco de pruebas.

Fuente: Autores.

6.2.1.1 Protocolo de medición

Para garantizar la reproducibilidad y repetitividad del experimento las muestras fueron tomadas siguiendo el protocolo que se describe a continuación.

- Preparar los instrumentos de adquisición de los datos DAQ USB 6008.
- Verificar el estado del motor como las bujías, gases contaminantes y la presión de combustible.
- Encender el vehículo.
- El motor debe estar en su temperatura de funcionamiento óptimo para la extracción de datos.
- Seleccionar la prueba a realizar.
- Variar la presión del combustible con 40 psi y 60 psi.
- Variar la distancia de los electrodos de las bujías con un GAUGE a 1.3 mm.
- Establecer el régimen de giro del motor en el banco dinamométrico igual a 4000 RPM.
- Adquirir los datos arrojados del analizador de gases Nextech NGA 6000.
- Adquirir los datos de potencia proporcionado por el banco dinamométrico.
- Establecer el régimen de giro del motor en ralentí.
- Seleccionar la prueba a realizar como la variación de presión de combustible y distancia de electrodos.
- Adquirir los datos del analizador de gases y potencia de motor.
- Mantener el motor funcionando por dos minutos.

Los datos obtenidos del banco dinamométrico, analizador de gases, son almacenados en un ordenador con un formato que permita corresponder los datos de medición con tratamiento y que es compatible con el software de análisis estadístico Minitab® para el posterior tratamiento de datos.

6.2.1.2 Secuencia de corridas experimentales

Para realizar la toma de muestras se realiza un diagrama del proceso a seguir, el cual parte de la muestra hasta la exposición del resultado como se muestra en la figura 6.22.




Figura 6.22. Secuencia de toma de datos.

Fuente: Autores.

El flujo que siguen las señales hacia la tarjeta de adquisición, parte desde la toma de las muestras a través de los sensores que son instalados en el motor y se dirige hacia la tarjeta de adquisición de datos, en donde se almacenan para su posterior análisis, el flujo de datos se puede observar en la figura 6.23.

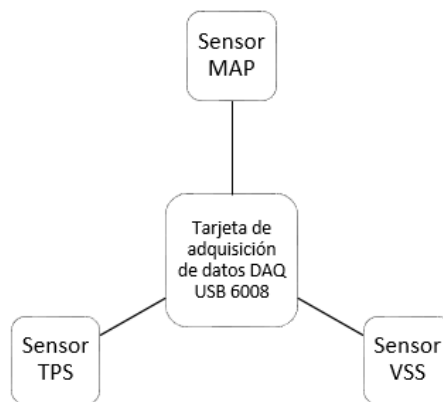


Figura 6.23. Flujo de las señales hacia la tarjeta.

Fuente: Autores.

Una vez que se obtienen las señales, se forma una matriz general con los datos obtenidos, para luego realizar un proceso de filtrado, en donde se obtienen señales con la mínima cantidad de ruido, las cuales pueden ser graficadas, esto se puede observar en la figura 6.24.

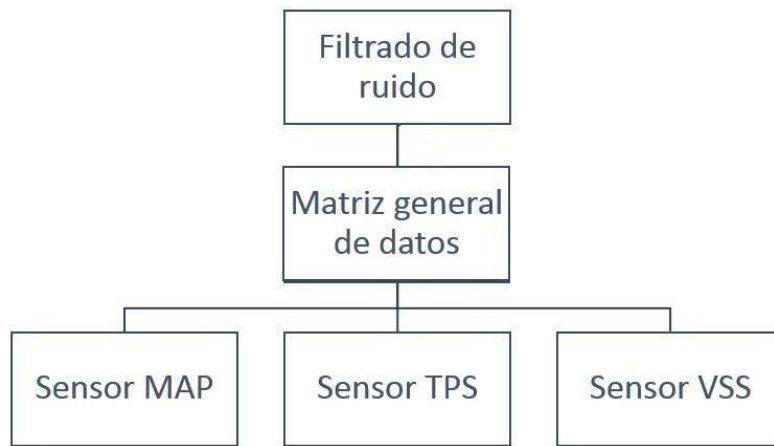


Figura 6.24. Proceso de filtrado de la señal.

Fuente: Autores.

Al obtener las señales filtradas estas son analizadas a través de Max, Min, Mean, Factor RMS, Kurtosis, Factor de cretas, Moda y desviación estándar los cuales permiten caracterizar los parámetros a analizar del vehículo, como se muestra en la figura 6.25.

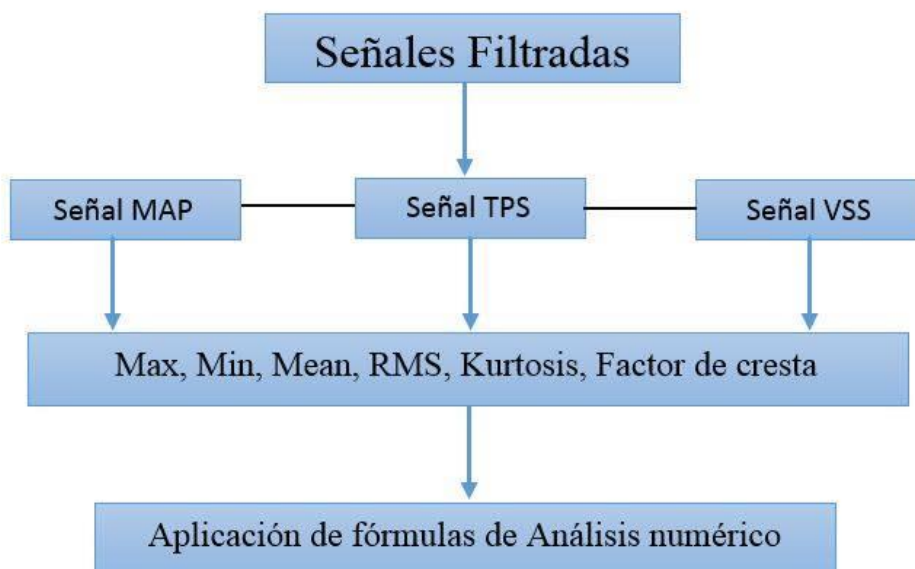


Figura 6.25. Señales de análisis de los sensores.

Fuente: Autores.

6.2.2 Valores tomados en el desarrollo

Para el experimento se tomó las señales de sensores TPS, MAP y VSS, los valores de la emisión de gases generados en el vehículo de pruebas y los valores de carga aplicados mediante el banco dinamométrico.

6.2.2.1 Ubicación de los sensores utilizados en el vehículo de pruebas

La disposición de los sensores en el vehículo Chevrolet Corsa 1.4 L, se muestran en la figura 6.26, que se muestra a continuación.




Figura 6.26. Ubicación de los sensores de muestreo en el vehículo.

Fuente: Autores.

6.2.2.2 Sensores utilizados en la experimentación

- MAP: sensor de presión de aire.
- TPS: sensor de posición de mariposa.
- VSS: sensor de velocidad del motor.

En la tabla 6.9, se describe los sensores utilizados en la experimentación, ubicación y rango de alimentación para su funcionamiento.

Tabla 6.9. Identificación de los sensores.

Fuente: Autores.

Sensores utilizados en la experimentación		
Sensores	Ubicación	Alimentación
Sensor de presión de aire (MAP)	Cuerpo de aceleración o	4.8 a 5.2 volt
Sensor de posición de mariposa	Cuerpo de aceleración	4.8 a 5.2 volt
Sensor de velocidad del motor	Transeje	3.2 volt

En la tabla 6.10, se muestra las cargas aplicadas y mediciones que se obtienen en el banco dinamométrico.

Tabla 6.10. Mediciones aplicadas en el banco dinamométrico.

Fuente: Autores.

Cargas y mediciones aplicadas en el banco dinamométrico	
Cargas	Unidad de medida
Fuerza	Newton (N)
Potencia	Kilovatio (Kw)
RPM	Revoluciones por minuto
Consumo 1	Litros por hora (L/h)
Consumo 2	Litros cada 100km (L/100km)
Velocidad	Kilómetros (Km)

En la tabla 6.11, se muestran los valores medidos por el analizador de gases.

Tabla 6.11. Valores del analizador de gases.

Fuente: Autores.

Característica	Símbolo	Rango	Sensibilidad	Unidad
Monóxido de carbono	CO	0.00 – 0.99	0.01	%
Hidrocarburos	HC	0 – 9999	1	ppm
Dióxido de carbono	CO ₂	0.0 – 20	0.10	%
Oxígeno	O ₂	0.0 – 25	0.01	%
Óxidos Nitrosos	NO _x	0 – 5000	1	ppm
Lambda	λ	0 – 2.000	0.001	–
Relación aire/combustible	AFR	0.0 – 99.0	0.1	–

Para el desarrollo del experimento se realizó la corrida experimental del motor en correcto estado de funcionamiento, y posteriormente se aplicaron 3 fallos al funcionamiento del motor. En tabla 6.12, se muestra los estados del motor durante el experimento.

Tabla 6.12. Estado de pruebas del motor.

Fuente: Autores.

Estado	Descripción
0	Estado del motor ok, motor en correcto funcionamiento.
1	Alteración en la presión de combustible, presión 60 psi.
2	Alteración en la presión de combustible, presión 40 psi.
3	Alteración en el espacio del electrodo de las bujías, espacio del electrodo 1,3 mm.

En la tabla 6.13, se presentan los efectos que se producen en el motor de combustión interna del vehículo Chevrolet Corsa Evolution 1.4 L.

Tabla 6.13. Efectos que producen en el motor de combustión interna.

Fuente: Autores.

Modos de fallo	Condición de la falla	Efectos de fallo
Menor presión de combustible	Dosado rico	El motor no enciende. Vehículo se detiene al conducir. Trabaja con mezcla pobre. Se enciende el check engine. Pérdida de potencia. Ralentí inestable. Arranque lento o sin arranque. Bomba. Inyectores en mal estado. Regulador. Sensor MAP.
		Filtro de combustible en mal estado.
Mayor presión de combustible	Dosado pobre	Incremento consumo de combustible. Excesiva emisión de CO y HC. Se enciende el Check engine. Regulador. Cañería de retorno. Filtro de combustible en mal estado.

Tabla 6.14. (Continuación) Efectos que producen en el motor de combustión interna.

Fuente: Autores.

		Desgaste bujías.
		Emisiones de HC.
		Inestable en marcha mínima.
		Falla en el motor.
		Pérdida de potencia.
Menor voltaje de encendido	Bajo voltaje de encendido	Incremento consumo de combustible.
		Vibraciones del motor.
		Vacilación del motor.
		Bujía inadecuada.
		Fallas en cables.
		Falla bobina.

6.3 Análisis mediante herramientas de aprendizaje y clasificación de la base de datos para el diagnóstico de fallas de un motor de encendido provocado

6.3.1 Tratamiento de datos

Para evitar la introducción de errores debido a las imprecisiones que se pueden tener en los resultados de las mediciones realizadas, los datos obtenidos antes de ser utilizados deben ser validados. Los modelos estadísticos que se van a desarrollar dependen entonces de las limitaciones de precisión y exactitud. A partir de las pruebas realizadas se elabora una base datos, en la que se presentan valores referentes a las variables de entrada y respuesta.

6.3.1.1 Variables de entrada

La señal de funcionamiento emitida por los sensores, es determinada para nuestro experimento como las variables de entrada.

6.3.1.2 Variables de salida

Los valores obtenidos durante las pruebas, corresponden a las variables de salida, estos valores fueron tomados de las emisiones captadas por el analizador de gases y las variables medibles en el banco de pruebas dinamo-métrico.

6.3.1.3 Base de datos utilizada en el estudio

En la tabla 6.6, se muestra un extracto de la matriz de la base de datos elaborada de la toma de datos de la señal de funcionamiento de los sensores, valores emitidos por el analizador de gases y criterios de carga y consumo medidos por el banco dinamo-métrico.

Tabla 6.15. Extracto de la base de datos utilizada en el experimento.

Fuente: Autores.

Falla	Estado	MAP	TPS	RPM	VSS	Consumo L/100km	Consumo L/h	Fuerza	Potencia	CO	HC	CO2	O2	λ	AFR
0	0	3.538	3.426	3542	60	17.82	10.69	1390	23.2	0.59	130	14.1	0.64	1.006	14.98
0	0	3.539	3.439	3542	60	17.82	10.69	1390	23.2	0.59	130	14.1	0.64	1.006	14.98
0	0	3.539	3.437	3542	60	17.82	10.69	1390	23.2	0.59	130	14.1	0.64	1.006	14.98
0	0	3.539	3.436	3542	60	17.82	10.69	1390	23.2	0.59	130	14.1	0.64	1.006	14.98
0	0	3.539	3.435	3542	60	17.82	10.69	1390	23.2	0.59	130	14.1	0.64	1.006	14.98
0	0	3.54	3.438	3542	60	17.82	10.69	1390	23.2	0.59	130	14.1	0.64	1.006	14.98
0	0	3.54	3.438	3542	60	17.82	10.69	1390	23.2	0.59	130	14.1	0.64	1.006	14.98
0	0	3.539	3.441	3542	60	17.82	10.69	1390	23.2	0.59	130	14.1	0.64	1.006	14.98
0	0	3.539	3.441	3542	60	17.82	10.69	1390	23.2	0.59	130	14.1	0.64	1.006	14.98
0	0	3.54	3.44	3542	60	17.82	10.69	1390	23.2	0.59	130	14.1	0.64	1.006	14.98
0	0	3.922	3.12	2811	60	16.02	9.61	1112	18.5	5.42	173	12.1	0.28	0.864	12.7
0	0	3.922	3.045	2811	60	16.02	9.61	1112	18.5	5.42	173	12.1	0.28	0.864	12.7
0	0	3.922	2.971	2811	60	16.02	9.61	1112	18.5	5.42	173	12.1	0.28	0.864	12.7
0	0	3.923	2.815	2811	60	16.02	9.61	1112	18.5	5.42	173	12.1	0.28	0.864	12.7
0	0	3.922	2.846	2811	60	16.02	9.61	1112	18.5	5.42	173	12.1	0.28	0.864	12.7
0	0	3.923	2.836	2811	60	16.02	9.61	1112	18.5	5.42	173	12.1	0.28	0.864	12.7
0	0	3.922	2.934	2811	60	16.02	9.61	1112	18.5	5.42	173	12.1	0.28	0.864	12.7
0	0	3.922	2.887	2811	60	16.02	9.61	1112	18.5	5.42	173	12.1	0.28	0.864	12.7
0	0	3.922	2.883	2811	60	16.02	9.61	1112	18.5	5.42	173	12.1	0.28	0.864	12.7
0	0	3.923	2.814	2811	60	16.02	9.61	1112	18.5	5.42	173	12.1	0.28	0.864	12.7
0	0	1.396	1.752	4715	80	21.67	17.34	1214	27	0.53	123	14.2	0.91	1.021	15
0	0	1.395	1.825	4715	80	21.67	17.34	1214	27	0.53	123	14.2	0.91	1.021	15
0	0	1.393	1.8	4715	80	21.67	17.34	1214	27	0.53	123	14.2	0.91	1.021	15
0	0	1.395	2.112	4715	80	21.67	17.34	1214	27	0.53	123	14.2	0.91	1.021	15
0	0	1.393	2.187	4715	80	21.67	17.34	1214	27	0.53	123	14.2	0.91	1.021	15
0	0	1.396	1.965	4715	80	21.67	17.34	1214	27	0.53	123	14.2	0.91	1.021	15

6.3.2 Análisis de la base de datos mediante herramientas de aprendizaje y clasificación

Para desarrollar el análisis mediante herramientas de aprendizaje y clasificación, se establece y selecciona las variables de predicción y las de respuesta que se desea obtener, como variables de entrada se establece la señal de funcionamiento de los sensores MAP, TPS y VSS, y como respuesta se obtendrá la predicción antes mencionada de las variables Consumo, Fuerza, Potencia y gases contaminantes generados por el vehículo, en la figura 6.27, se muestra la plataforma de selección de las variables de predicción y la respuesta que se desea obtener.

Select predictors and response.			
Name	Type	Range	Import as
FALLA	double	0 .. 3	Do not import
ESTADO	double	0 .. 1	Do not import
MAP	double	1.388 .. 3.923	Predictor
TPS	double	1.318 .. 3.446	Predictor
RPM	double	742 .. 4715	Predictor
VSS	double	0 .. 100	Predictor
ConsumoL100km	double	0.1 .. 22.42	Response
ConsumoLh	double	0.57 .. 19.36	Do not import
Tamb	double	22.1 .. 25.4	Do not import
Fuerza	double	0 .. 1469	Do not import
Potencia	double	0 .. 29.4	Do not import
TAceite	double	94 .. 108	Do not import
CO	double	0.53 .. 9.66	Do not import
HC	double	123 .. 279	Do not import
CO2	double	9.6 .. 14.2	Do not import
O2	double	0.21 .. 3.45	Do not import
LAMBDA	double	0.762 .. 1.144	Do not import
AFR	double	11.2 .. 16.8	Do not import
Severidad	double	1 .. 9	Do not import
Ocurrencia	double	1 .. 8	Do not import
Deteccin	double	3 .. 10	Do not import
NPR	double	9 .. 324	Do not import

Figura 6.27. Plataforma de selección de variables predictoras y de respuesta.

Fuente: Autores.

6.3.2.1 Análisis del consumo de combustible en L/100km

En la figura 6.28, se muestra la ventana de diagrama de dispersión que crea círculos en las ubicaciones especificadas por los vectores x, y. El diagrama de dispersión representa los pares de datos numéricos, cada valor de una variable determina la posición del eje horizontal y el valor de la otra variable determina la posición en el eje vertical. Si las variables están correlacionadas, los puntos caerán a lo largo de una línea o una curva. Cuanto mejor sea la correlación, más estrechos serán los puntos que abrazarán la línea.

La herramienta de aprendizaje y clasificación permite distinguir en clases las fallas y diferenciar que el motor de combustión interna se encuentra “OK” o “CON DEFECTO”. Cada punto que se muestra en la gráfica representa las variables obtenidas por los sensores MAP y TPS y como respuesta el consumo L/100km. Para este caso, las clases no son linealmente separables con un solo hiperplano, si no con 16 dimensiones, ya que cada círculo rojo, azul y verde no pueden ser separados con un solo plano.

La fiabilidad en este caso es del 95.8% en SVM, la gráfica que tienen círculos de colores son valores acertados por la herramientas de aprendizaje y clasificación, en caso contrario cuando se marca con una x son errores que surgió al momento de entrenar las herramientas de aprendizaje y clasificación, dichos errores son valores que provocan distorsión pero poca importancia.




Figura 6.28. Diagrama de dispersión del consumo de combustible en L/100km.

Fuente Autores.

6.3.2.1.1 Matriz de confusión para el consumo de combustible en L/100km

En la figura 6.29, se muestra el gráfico de matriz de confusión para la predicción de consumo de combustible en L/100km, las filas corresponden a la clase predicha (Predicted Class), y las columnas muestran la clase verdadera (True Class). Las celdas diagonales conocidas como diagonal significativa muestran cuántos y qué porcentaje de los ejemplos de la red entrenada son calculados correctamente. Es decir, muestra que porcentaje de las clases verdaderas y predichas coinciden. Las celdas fuera de la diagonal muestran dónde el clasificador ha cometido errores. La columna en el extremo derecho de la gráfica muestra la precisión de cada clase predicha, mientras que la fila en la parte inferior de la gráfica muestra la precisión de cada clase verdadera.

En la figura 6.29, que se muestra, el clasificador a cometido varios errores, ya que se encuentran varias muestras fuera de la diagonal significativa, como por ejemplo la clase predicha es de 21.92 y la clase verdadera es de 18 que tiene un error de 17.89%. del clasificador.

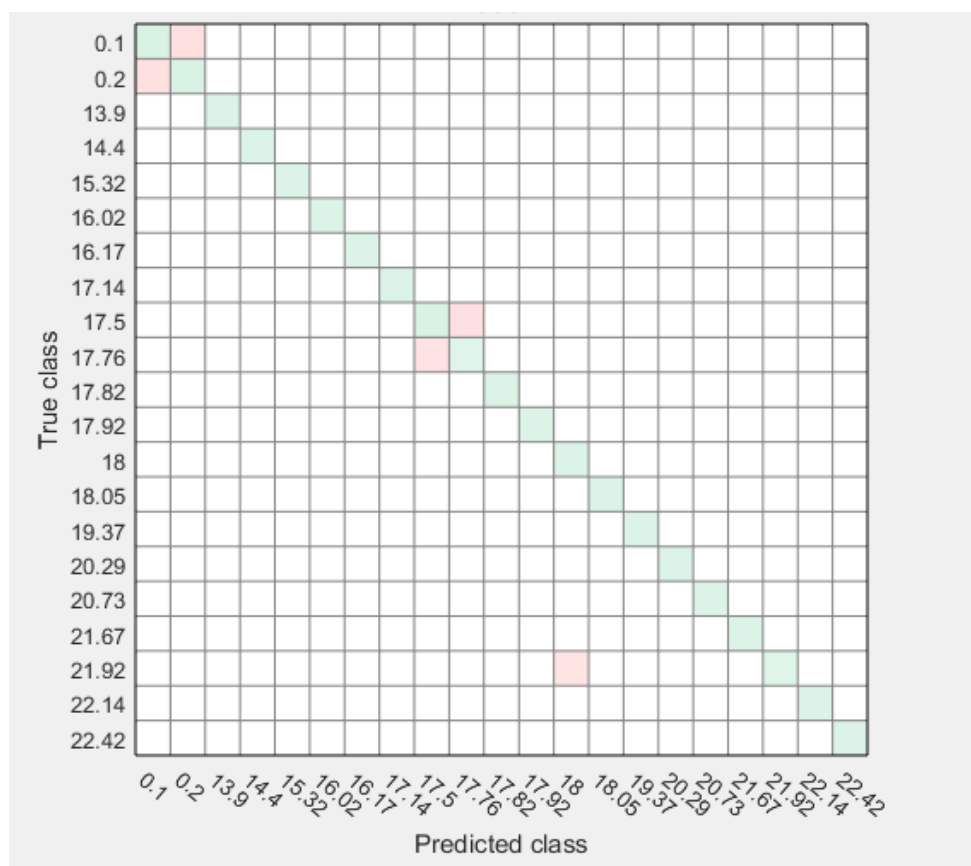


Figura 6.29. Matriz de confusión de consumo de combustible en L/100km.

Fuente Autores.

6.3.2.1.2 Diagrama de coordenadas paralelas para el consumo de combustible en L/100km

En la figura 6.30, se aprecia una herramienta para visualizar datos de alta dimensión, donde cada observación está representada por la secuencia de sus valores de coordenadas trazados en función de sus índices de coordenadas.

En un diagrama de coordenadas paralelas, cada variable recibe su propio eje y todos los ejes se colocan en paralelo entre sí. Como se observa en la figura el eje vertical se representa la desviación estándar, los valores por encima de “mean” representan la media y valores debajo de “mean” representan las desviaciones estándar.

El diagrama contiene 4 variables de entrada de los sensores MAP, TPS, VSS y las RPM que nos dará información de las falla del motor de combustión interna. Cada variable se representa con colores y las variables más significativas son los valores de los sensores MAP y TPS mientras las variables de las RPM y velocidad son valores menos significativos, los valores marcados con x son errores no significativos de las variables de entrada al momento de predecir con las herramientas de aprendizaje y clasificación.




Figura 6.30. Diagrama de coordenadas paralelas de consumo de combustible en L/100km.

Fuentes: Autores.

6.3.2.1.3 Curva operática del receptor para el consumo de combustible en L/100km

La curva de características operativas del receptor, o curva ROC de consumo de combustible en L/100km, muestra la relación de las tasas de verdaderos positivos (true positive rate) y falsos positivos (false positive rate), es decir la probabilidad de clasificación correcta de cada dato en cada clase. Como se observa en la figura 6.31, la clasificación actual tiene las coordenadas (0.03, 0.70), lo cual demuestra que los verdaderos positivos o correctamente clasificados se encuentran en el punto más alto (la unidad), y los falsos positivos o incorrectamente clasificados se encuentran en el punto más bajo (cero) de la curva ROC. Con esto el área bajo la curva (AUC) es igual a la unidad y demuestra la correcta clasificación de los datos.




Figura 6.31. Curva operativa de receptor para consumo de combustible en L/100km.

Fuentes: Autores.

6.3.2.2 Análisis del consumo de combustible en L/h

En la figura 6.32, se muestra la ventana de diagrama de dispersión con respecto al consumo de combustible en L/h, que crea círculos en las ubicaciones especificadas por los vectores x , y .

Cada punto que se muestra en la gráfica representa las variables obtenidas por las RPM del motor y el sensor TPS y como respuesta el consumo de combustible en litros/h. Para este caso, las clases no son linealmente separables con un solo hiperplano, si no con 16 dimensiones, ya que cada círculo rojo, azul y verde no pueden ser separados con un solo plano.

La fiabilidad en este caso es de 100%, generado por las herramientas de aprendizaje y clasificación (árboles de decisión), la gráfica que tienen círculos de colores son valores acertados por las herramientas de aprendizaje y clasificación, en este caso no cuentas con errores que surgirían al momento de entrenar las herramientas de aprendizaje y clasificación.




Figura 6.32. Diagrama de dispersión del consumo de combustible en L/h.

Fuentes: Autores.

6.3.2.2.1 Matriz de confusión para el consumo de combustible en L/h

La matriz que muestra en la figura 6.33, en la diagonal principal el número de datos correctamente clasificados, no existen elementos ubicados fuera de la diagonal significativa, es decir no existen errores de asignación al momento de predecir con las herramientas de aprendizaje y clasificación.




Figura 6.33. Matriz de confusión para el consumo de combustible en litros/h.

Fuentes: Autores.

6.3.2.2.2 Curva de características operáticas del receptor para el consumo de combustible en L/h

La curva de características operativas del receptor o curva ROC, como se muestra en la figura 6.34, nos permite visualizar la clasificación actual que tiene las coordenadas (0,1), lo cual demuestra que los verdaderos positivos o correctamente clasificados se encuentran en el punto más alto (la unidad), y los falsos positivos o incorrectamente clasificados se encuentran en el punto más bajo (cero) de la curva ROC. Con esto el área bajo la curva (AUC) es igual a la unidad y demuestra la correcta clasificación de los datos para el consumo de combustible en litros/hora.




Figura 6.34. Curva operativa de receptor para el consumo de combustible en L/h.

Fuentes: Autores.

6.3.2.2.3 Diagrama de coordenadas paralelas para el consumo de combustible en L/h

En la figura 6.35, se muestra un diagrama de coordenadas paralelas, cada variable recibe su propio eje y todos los ejes se colocan en paralelo entre sí. Como se observa en la figura el eje vertical se representa la desviación estándar, los valores por encima de “mean” representan la media y valores debajo de “mean” representan las desviaciones estándar.

El diagrama contiene 4 variables de entrada de los sensores MAP, TPS, VSS y las RPM que nos dará información de las falla del motor de combustión interna. Cada variable se representa con colores y las variables más significativas son los valores de los sensores MAP, TPS, VSS y RPM del motor.




Figura 6.35. Diagrama de coordenadas paralelas del consumo de combustible en L/h.

Fuentes: Autores.

6.3.2.3 Análisis de la fuerza tractora

En la figura 6.36, se muestra la ventana de diagrama de dispersión que representa las variables obtenidas por las RPM del motor y el sensor TPS y como respuesta la fuerza tractora del vehículo. Para este caso, las clases no son linealmente separables con un solo hiperplano, si no con 16 dimensiones, ya que cada círculo rojo, azul y verde no pueden ser separados con un solo plano.

La fiabilidad en este caso es del 98.3% producidas por las herramientas de aprendizaje y clasificación (máquinas de soporte vectorial), la gráfica que tienen círculos de colores son valores acertados por la herramientas de aprendizaje y clasificación, en este caso existen errores que surgen al momento de entrenar las herramientas, como se aprecia en la figura con x son errores no significativos al momento de tener un régimen de 5000 RPM y con un voltaje del sensor TPS de 2.3 V.




Figura 6.36. Diagrama de dispersión de la fuerza tractora.

Fuente: Autores.

6.3.2.3.1 Matriz de confusión para la fuerza tractora

La matriz de confusión que se muestra en la figura 6.37, tiene como predicción la fuerza tractora del vehículo en la que indica que el clasificador ha cometido errores, ya que se encuentran muestras fuera de la diagonal significativa, como por ejemplo la clase predicha es de 922 y la clase verdadera es 1214 que tiene un error de 24,06%. el clasificador.




Figura 6.37. Matriz de confusión de la fuerza tractora.

Fuente: Autores.

6.3.2.3.2 Curva de características operativas del receptor para la fuerza tractora

La curva de características operativas del receptor o curva ROC, como se muestra en la figura 6.38, la clasificación actual tiene las coordenadas (0,1), lo cual demuestra que los verdaderos positivos o correctamente clasificados se encuentran en el punto más alto (la unidad), y los falsos positivos o incorrectamente clasificados se encuentran en el punto más bajo (cero) de la curva ROC. Con esto el área bajo la curva (AUC) es igual a la unidad y demuestra la correcta clasificación de los datos para la fuerza tractoras.




Figura 6.38. Cuerva ROC de la fuerza tractora.

Fuente: Autores.

6.3.2.3.3 Diagrama de coordenadas paralelas para la fuerza tractora

En la figura 6.39, se muestra un diagrama de coordenadas paralelas, cada variable recibe su propio eje y todos los ejes se colocan en paralelo entre sí. Como se observa en la figura el eje vertical se representa la desviación estándar, los valores por encima de “mean” representan la media y valores debajo de “mean” representan las desviaciones estándar.

El diagrama contiene 4 variables de entrada de los sensores MAP, TPS, VSS y como menos significativa RPM, estas variables nos dará información de las falla del motor de combustión interna. Cada variable se representa con colores y las variables más significativas son los valores de los sensores MAP, TPS, VSS y RPM del motor.




Figura 6.39. Diagrama de coordenadas paralelas de la fuerza tractora.

Fuentes: Autores.

6.3.2.4 Análisis de la potencia del vehículo

En la figura 6.40, se muestra la ventana de diagrama de dispersión que representa las variables obtenidas por la velocidad del motor y el sensor TPS y como respuesta la potencia del vehículo. Para este caso, las clases no son linealmente separables con un solo hiperplano, si no con 16 dimensiones, ya que cada círculo rojo, azul, verdes no pueden ser separados con un solo plano.

La fiabilidad en este caso es de 98.3% producidas por las herramientas de aprendizaje y clasificación (máquinas de soporte vectorial), la gráfica que tienen círculos de colores son valores acertados por la herramientas de aprendizaje y clasificación, en este caso existen errores que surgió al momento de entrenar las herramientas, como se aprecia en la figura con x son errores no significativos al momento de una velocidad de 80 km/h y con un voltaje de funcionamiento del sensor TPS de 2.43 V.




Figura 6.40. Diagrama de dispersión de potencia.

Fuente: Autores.

6.3.2.4.1 Matriz de confusión para la potencia

La matriz de confusión que se muestra en la figura 6.41, tiene como predicción potencia del motor en la que indica que el clasificador ha cometido error, ya que se encuentran muestras fuera de la diagonal significativa, como por ejemplo la clase predicha es de 25.6 y la clase verdadera de 27 con un error de 5.19%.




Figura 6.41. Matriz de confusión de potencia.

Fuente: Autores.

6.3.2.4.2 Curva de características operativas del receptor para la potencia

La curva de características operativas del receptor o curva ROC, como se muestra en la figura 6.42, la clasificación actual tiene las coordenadas (0,1), lo cual demuestra que los verdaderos positivos o correctamente clasificados se encuentran en el punto más alto (la unidad), y los falsos positivos o incorrectamente clasificados se encuentran en el punto más bajo (cero) de la curva ROC. Con esto el área bajo la curva (AUC) es igual a la unidad y demuestra la correcta clasificación de los datos para la fuerza tractoras.




Figura 6.42. Cuerva ROC de potencia.

Fuente: Autores.

6.3.2.4.3 Diagrama de coordenadas paralelas para la potencia

En la figura 6.43, se muestra un diagrama de coordenadas paralelas, cada variable recibe su propio eje y todos los ejes se colocan en paralelo entre sí. Como se observa en la figura el eje vertical se representa la desviación estándar, los valores por encima de “mean” representan la media y valores debajo de “mean” representan las desviaciones estándar.

El diagrama contiene 4 variables de entrada de los sensores MAP, TPS, VSS y como menos significativa RPM, estas variables nos dará información de las falla del motor de combustión interna. Cada variable se representa con colores y las variables más significativas son los valores de los sensores MAP, TPS, VSS y RPM del motor.




Figura 6.43. Diagrama de coordenadas paralelas de potencia.

Fuentes: Autores.

6.3.2.5 Análisis del monóxido de carbono (CO)

En la figura 6.44, se muestra la ventana de diagrama de dispersión que representa las variables obtenidas por las RPM del motor y el sensor TPS y como respuesta son los gases contaminantes (CO). Para este caso, las clases no son linealmente separables con un solo hiperplano, ya que existen varias predicciones de una sobre otra, en este caso las máquinas de soporte vectorial separa en 16 dimensiones y separados con su respectivo hiperplano.

La fiabilidad en este caso es de 98.3% producidas por las herramientas de aprendizaje y clasificación (máquinas de soporte vectorial), la gráfica que tienen círculos de colores son valores acertados por las herramientas de aprendizaje y clasificación, en este caso existen errores que surgen al momento de entrenar las herramientas, como se aprecia en la figura con x son errores no significativos, el error ocurre al momento al tener un voltaje de 3.42 V y 4550 RPM en el vehículo.




Figura 6.44. Diagrama de dispersión para el CO.

Fuente: Autores.

6.3.2.5.1 Matriz de confusión para el monóxido de carbono (CO)

La matriz de confusión que se muestra en la figura 6.45, tiene como predicción los gases contaminantes (CO), lo que indica que el clasificador ha cometido error, ya que se encuentran muestras fuera de la diagonal significativa, como por ejemplo el error se encuentra en la clase verdadera (1.21) y la clase predictora (9.28), con un error de 13.03% el clasificador.




Figura 6.45. Matriz de confusión para el CO.

Fuente: Autores.

6.3.2.5.2 Curva de características operativas del receptor para el monóxido de carbono (CO)

La curva de características operativas del receptor o curva ROC, como se muestra en la figura 6.46, la clasificación actual tiene las coordenadas (0,1), (0 en verdadero positivo, 1 falso positivo), lo cual demuestra que los verdaderos positivos o correctamente clasificados se encuentran en el punto más alto (la unidad), y los falsos positivos o incorrectamente clasificados se encuentran en el punto más bajo (cero) de la curva ROC. Con esto el área bajo la curva (AUC) es igual a la unidad y demuestra la correcta clasificación de los datos para la fuerza tractoras.




Figura 6.46. Curva ROC para el CO.

Fuente: Autores.

6.3.2.5.3 Diagrama de coordenadas paralelas para el monóxido de carbono (CO)

En la figura 6.47, se muestra un diagrama de coordenadas paralelas, cada variable recibe su propio eje y todos los ejes se colocan en paralelo entre sí. Como se observa en la figura el eje vertical representa la desviación estándar, los valores por encima de “mean” representan la media y valores debajo de “mean” representan las desviaciones estándar.

El diagrama contiene 4 variables de entrada de los sensores MAP, TPS, VSS y RPM del motor, estas variables nos dará información de las desviaciones estándar que encuentra

cada variable de entrada. Cada variable se representa con colores y los errores marcados con x son valores menos significativos al momento de entrenar con la herramienta de aprendizaje y clasificación.




Figura 6.47. Diagrama de coordenadas paralelas del CO.

Fuente: Autores.

6.3.2.6 Análisis de hidrocarburos no combustionados (HC)

En la figura 6.48, se muestra la ventana de diagrama de dispersión que representa las variables obtenidas por el sensor TPS y las RPM del motor como respuesta son los gases contaminantes (HC). Para este caso, las clases no son linealmente separables con un solo hiperplano, ya que existen varias predicciones, en este caso las máquinas de soporte vectorial separa en 16 dimensiones, con su respectivo hiperplano.

La fiabilidad en este caso es de 92.5% producidas por las herramientas de aprendizaje y clasificación (árboles de decisión), la gráfica que tienen círculos de colores son valores acertados por la herramientas de aprendizaje y clasificación, en contrario los errores se marcan con x el cual indica que surgió un error al momento de entrenar las herramientas, son errores no significativos, el error ocurre al momento al tener un voltaje de 3.42 V y 2700 RPM en el vehículo.




Figura 6.48. Diagrama de dispersión para HC.

Fuente: Autores.

6.3.2.6.1 Matriz de confusión para los hidrocarburos no combustionados (HC)

La matriz de confusión que se muestra en la figura 6.49, tiene como predicción los gases contaminantes (HC), lo que indica que el clasificador ha cometido error, ya que se encuentran muestras fuera de la diagonal significativa, como por ejemplo el error se encuentra en la clase verdadera (173) y la clase predictora (130), con un error del 24.86%.




Figura 6.49. Matriz de confusión de HC.

Fuente: Autores.

6.3.2.6.2 Curva de características operativas del receptor para los hidrocarburos no combustionados (HC)

La curva de características operativas del receptor o curva ROC, como se muestra en la figura 6.50, la clasificación actual tiene las coordenadas (0,1), (0 en verdadero positivo, 1 falso positivo), lo cual demuestra que los verdaderos positivos o correctamente clasificados se encuentran en el punto más alto (la unidad), y los falsos positivos o incorrectamente clasificados se encuentran en el punto más bajo (cero) de la curva ROC. Con esto el área bajo la curva (AUC) es igual a la unidad y demuestra la correcta clasificación de los datos para la fuerza tractoras.




Figura 6.50. Curva ROC de HC.

Fuente: Autores.

6.3.2.6.3 Diagrama de coordenadas paralelas para los hidrocarburos no combustionados (HC)

En la figura 6.51, se muestra un diagrama de coordenadas paralelas, cada variable recibe su propio eje y todos los ejes se colocan en paralelo entre sí. Como se observa en la figura el eje vertical se representa la desviación estándar, los valores por encima de “mean” representan la media y valores debajo de “mean” representan las desviaciones estándar.

El diagrama contiene 4 variables de entrada de los sensores MAP, TPS, VSS y RPM del motor, estas variables nos dará información de las desviaciones estándar que encuentra

cada variable de entrada. Cada variable se representa con colores y los errores marcados con x son valores menos significativos al momento de entrenar con la herramienta de aprendizaje y clasificación para los gases contaminantes (HC).




Figura 6.51. Diagrama de coordenadas paralelas de HC.

Fuente: Autores.

6.3.2.7 Análisis del dióxido de carbono (CO₂)

En la figura 6.52, se muestra la ventana de diagrama de dispersión que representa las variables obtenidas por el sensor TPS y sensor VSS como respuesta son los monóxidos de carbono (CO₂). Para este caso, las clases no son linealmente separables con un solo hiperplano, ya que existen varias predicciones, en este caso los árboles de decisión, separa en 16 dimensiones y separados con su respectivo hiperplano.

La fiabilidad en este caso es de 86.7% producidas por las herramientas de aprendizaje y clasificación (árboles de decisión), la gráfica que tienen círculos de colores son valores acertados por la herramientas de aprendizaje y clasificación, en contrario los errores se marcan con x el cual indica que surgió un error al momento de entrenar las herramientas, son errores no significativos, el error ocurre al tener un voltaje del TPS 2.41 V y una velocidad de 80 km/h.




Figura 6.52. Diagrama de dispersión para el CO₂.

Fuente: Autores.

6.3.2.7.1 Matriz de confusión para el dióxido de carbono (CO₂)

En la figura 6.53, se muestra el gráfico de matriz de confusión para la predicción dióxido carbono, las filas corresponden a la clase predicha (Predicted Class), y las columnas muestran la clase verdadera (True Class).

En la figura que se muestra el clasificador a cometido varios errores, ya que se encuentran varias muestras fuera de la diagonal significativa, como por ejemplo la clase predicha es de 10.2 y la clase verdadera es 14 con un error del 27,15%.




Figura 6.53. Matriz de confusión para el CO₂.

Fuente: Autores.

6.3.2.7.2 Curva de características operativas del receptor para el dióxido de carbono (CO₂)

La curva de características operativas del receptor o curva ROC, como se muestra en la figura 6.54, la clasificación actual tiene las coordenadas (0,1), (0 en verdadero positivo, 1 falso positivo), lo cual demuestra que los verdaderos positivos o correctamente clasificados se encuentran en el punto más alto (la unidad), y los falsos positivos o incorrectamente clasificados se encuentran en el punto más bajo (cero) de la curva ROC. Con esto el área bajo la curva (AUC) es igual a la unidad y demuestra la correcta clasificación de los datos para la fuerza tractoras.




Figura 6.54. Curva ROC para el CO₂.

Fuente: Autores.

6.3.2.7.3 Diagrama de coordenadas paralelas para el dióxido de carbono (CO₂)

En la figura 6.55, se muestra un diagrama de coordenadas paralelas, cada variable recibe su propio eje y todos los ejes se colocan en paralelo entre sí. Como se observa en la figura el eje vertical se representa la desviación estándar, los valores por encima de “mean” representan la media y valores debajo de “mean” representan las desviaciones estándar.

El diagrama contiene 4 variables de entrada de los sensores MAP, TPS, VSS y RPM del motor, estas variables nos dará información de las desviaciones estándar que encuentra

cada variable de entrada. Cada variable se representa con colores y los errores marcados con x son valores menos significativos al momento de entrenar con la herramienta de aprendizaje y clasificación para el dióxido de carbono (CO₂)




Figura 6.55. Diagrama de coordenadas paralelas de CO₂.

Fuente: Autores.

6.3.2.8 Análisis del oxígeno (O₂)

En la figura 6.56, representa las variables obtenidas por el sensor MAP y el sensor TPS y como respuesta el oxígeno. Para este caso, las clases no son linealmente separables con un solo hiperplano, si no con 16 dimensiones, ya que cada círculo rojo, azul, verdes no pueden ser separados con un solo hiperplano.

La fiabilidad en este caso es de 87.5% producidas por las herramientas de aprendizaje y clasificación (máquinas de soporte vectorial), la gráfica que tienen círculos de colores son valores acertados por la herramientas de aprendizaje y clasificación, en caso contrario se obtiene errores marcados con x, el cual dichos errores que surgen al momento de entrenar las herramientas de aprendizaje y clasificación.




Figura 6.56. Diagrama de dispersión para el O₂.

Fuente: Autores.

6.3.2.8.1 Matriz de confusión para el oxígeno (O₂)

En la figura 6.57, se muestra el gráfico de matriz de confusión para la predicción oxígeno, las filas corresponden a la clase predicha (Predicted Class), y las columnas muestran la clase verdadera (True Class).

En la figura que se muestra el clasificador a cometido varios errores, ya que se encuentran varias muestras fuera de la diagonal significativa, como por ejemplo la clase predicha es de 0.21 y la clase verdadera es 0.91 con un error del 23,07%.




Figura 6.57. Matriz de confusión para el O₂.

Fuente: Autores.

6.3.2.8.2 Curva de características operativas del receptor para el oxígeno O₂

La curva de características operativas del receptor o curva ROC, como se muestra en la figura 6.58, la clasificación actual tiene las coordenadas (0.01, 1), (0.01 en verdadero positivo, 1 falso positivo), lo cual demuestra que los verdaderos positivos o correctamente clasificados se encuentran en el punto más alto (la unidad), y los falsos positivos o incorrectamente clasificados se encuentran en el punto más bajo (cero) de la curva ROC. Con esto el área bajo la curva (AUC) es igual a la unidad y demuestra la correcta clasificación de los datos para la fuerza tractoras.




Figura 6.58. Curva ROC del O₂.

Fuente: Autores.

6.3.2.8.3 Diagrama de coordenadas paralelas para el oxígeno (O₂)

En la figura 6.59, se muestra un diagrama de coordenadas paralelas, cada variable recibe su propio eje y todos los ejes se colocan en paralelo entre sí. Como se observa en la figura el eje vertical se representa la desviación estándar, los valores por encima de “mean” representan la media y valores debajo de “mean” representan las desviaciones estándar.

El diagrama contiene 4 variables de entrada de los sensores MAP, TPS, VSS y RPM del motor, estas variables nos dará información de las desviaciones estándar que encuentra cada variable de entrada. Cada variable se representa con colores y los errores marcados

con x son valores menos significativos al momento de entrenar con la herramienta de aprendizaje y clasificación para el oxígeno (O₂)




Figura 6.59. Diagrama de coordenadas paralelas para el O₂.

Fuente: Autores.

6.3.2.9 Análisis del factor LAMBDA

En la figura 6.60, se muestra la ventana de diagrama de dispersión que representa las variables obtenidas por el sensor TPS y las RPM del motor como respuesta son LAMBDA. Para este caso, las clases no son linealmente separables con un solo hiperplano, ya que existen varias predicciones, las máquinas de soporte vectorial separa en 16 dimensiones con la finalidad de ser separados con su respectivo hiperplano.

La fiabilidad en este caso es de 100% producidas por las herramientas de aprendizaje y clasificación (máquinas de soporte vectorial), la gráfica que tienen círculos de colores son valores acertados por la herramientas de aprendizaje y clasificación, en contrario los errores se marcan con x el cual indica que surgió un error al momento de entrenar las herramientas.




Figura 6.60. Diagrama de dispersión para el factor LAMBDA.

Fuente: Autores.

6.3.2.9.1 Matriz de confusión para el factor LAMBDA

La matriz que muestra en la figura 6.61, en la diagonal principal es el número de datos correctamente clasificados, no existen elementos ubicados fuera de la diagonal significativa, es decir no existen errores de asignación al momento de predecir con las herramientas de aprendizaje y clasificación.




Figura 6.61. Matriz de confusión para el factor LAMBDA.

Fuente: Autores.

6.3.2.9.2 Curva de características operativas del receptor para el factor LAMBDA

La curva de características operativas del receptor o curva ROC, como se muestra en la figura 6.62, la clasificación actual tiene las coordenadas (0,1), (0 en verdadero positivo, 1 falso positivo), lo cual demuestra que los verdaderos positivos o correctamente clasificados se encuentran en el punto más alto (la unidad), y los falsos positivos o incorrectamente clasificados se encuentran en el punto más bajo (cero) de la curva ROC. Con esto el área bajo la curva (AUC) es igual a la unidad y demuestra la correcta clasificación de los datos para LAMBDA.




Figura 6.62. Curva de ROC para LAMBDA.

Fuente: Autores.

6.3.2.9.3 Diagrama de coordenadas paralelas para el factor LAMBDA

En la figura 6.63, se muestra un diagrama de coordenadas paralelas, cada variable recibe su propio eje y todos los ejes se colocan en paralelo entre sí. Como se observa en la figura el eje vertical se representa la desviación estándar, los valores por encima de "mean" representan la media y valores debajo de "mean" representan las desviaciones estándar.

El diagrama contiene 4 variables de entrada de los sensores MAP, TPS, VSS y las RPM que nos dará información de las desviaciones.




Figura 6.63. Diagrama de coordenadas paralelas de LAMBDA.

Fuente: Autores.

6.3.2.10 Análisis del radio aire combustible (AFR)

En la figura 6.64, representa las variables obtenidas por el sensor MAP y el sensor TPS y como respuesta el AFR. Para este caso, las clases no son linealmente separables con un solo hiperplano, si no con 16 dimensiones, ya que cada círculo rojo, azul, verdes no pueden ser separados con un solo hiperplano.

La fiabilidad en este caso es de 98.3% producidas por las herramientas de aprendizaje y clasificación (máquinas de soporte vectorial), la gráfica que tienen círculos de colores son valores acertados por la herramientas de aprendizaje y clasificación, en caso contrario se obtiene errores maracas con x, el cual dichos errores que surgen al momento de entrenar las herramientas de aprendizaje y clasificación.




Figura 6.64. Diagrama de dispersión para AFR.

Fuente: Autores.

6.3.2.10.1 Matriz de confusión para el radio aire combustible (AFR)

En la figura 6.65, se muestra el gráfico de matriz de confusión para la predicción de AFR, las filas corresponden a la clase predicha (Predicted Class), y las columnas muestran la clase verdadera (True Class).

En la figura que se muestra el clasificador a cometido varios errores, ya que se encuentran varias muestras fuera de la diagonal significativa, como por ejemplo la clase predicha es de 12.7 y la clase verdadera es 11.5 que tiene un error el clasifiacor de 9.45%.




Figura 6.65. Matriz de confusión para el AFR.

Fuente: Autores.

6.3.2.10.2 Curva de características operativas del receptor para el radio aire combustible AFR

La curva de características operativas del receptor o curva ROC, como se muestra en la figura 6.66, la clasificación actual tiene las coordenadas (0,1), (0 en verdadero positivo, 1 falso positivo), lo cual demuestra que los verdaderos positivos o correctamente clasificados se encuentran en el punto más alto (la unidad), y los falsos positivos o incorrectamente clasificados se encuentran en el punto más bajo (cero) de la curva ROC. Con esto el área bajo la curva (AUC) es igual a la unidad y demuestra la correcta clasificación de los datos para la fuerza tractoras.




Figura 6.66. Curva de ROC para el AFR.

Fuente: Autores.

6.3.2.10.3 Diagrama de coordenadas paralelas para el radio aire combustible AFR

En la figura 6.67, se muestra un diagrama de coordenadas paralelas, cada variable recibe su propio eje y todos los ejes se colocan en paralelo entre sí. Como se observa en la figura el eje vertical se representa la desviación estándar, los valores por encima de “mean” representan la media y valores debajo de “mean” representan las desviaciones estándar.

El diagrama contiene 4 variables de entrada de los sensores MAP, TPS, VSS y RPM del motor, estas variables nos dará información de las desviaciones estándar que encuentra cada variable de entrada. Cada variable se representa con colores y los errores marcados

con x son valores menos significativos al momento de entrenar con la herramienta de aprendizaje y clasificación para la relación estequiometria (AFR)




Figura 6.67. Diagrama de coordenadas paralelas de AFR.

Fuente: Autores.

6.4 Presentar los resultados obtenidos mediante métodos estadísticos y experimentales para la comprobación del software desarrollado

6.4.1 Análisis de las variables de respuesta mediante métodos estadísticos

6.4.1.1 Comportamiento del consumo de combustible en L/h

En la figura 6.68, se muestra la gráfica de intervalos de consumo de combustible en Litros/hora, donde se observa que cuando no existe falla en el sistema, el consumo es normal; en cambio cuando se da alguna falla, el consumo en L/h se eleva y por ende se genera una mayor concentración de gases contaminantes. Se puede evidenciar que la falla de dosado rico es la que genera mayor consumo y las fallas de dosado pobre y bajo voltaje de encendido no son tan significativos como la falla de dosado rico.




Figura 6.68. Variación del consumo en L/h de acuerdo al fallo provocado.

Fuente: Autores.

6.4.1.1.1 Gráficas de contorno de consumo de combustible en Litros/hora con vehículo en parámetros de correcto funcionamiento

En la figura 6.69, se muestra la gráfica de contorno de consumo de combustible en Litros/hora con el vehículo en parámetros de correcto funcionamiento, donde el consumo es mayor cuando el porcentaje de la apertura de la mariposa se encuentra a un (10% a 60%) y con (4100 a 4500 RPM) del motor, el cual el mayor consumo en estas condiciones de funcionamiento es de aproximadamente de 6.5 litros/hora.




Figura 6.69. Gráfica de contorno de consumo en L/H vs RPM y TPS.

Fuente: Autores.

6.4.1.1.2 Gráfica de contorno de consumo de combustible en Litros/hora con falla de dosado Rico

La Gráfica de contorno de consumo de combustible en Litros/hora con la falla de dosado Rico es mayor con respecto al vehículo en parámetros de correcto funcionamiento, el consumo es más significativo cuando se genera dicha falla, esta se genera cuando la apertura de la mariposa se encuentra entre un (40% a 100%) y (4100 RPM a 4500 RPM), donde el consumo en estas condiciones de funcionamiento es de aproximadamente de 12.5 litros/hora, como se muestra en la gráfica 6.70.




Figura 6.70. Gráfica de contorno del consumo en L/h con respecto a la falla de dosado rico.

Fuente: Autores.

6.4.1.1.3 Gráfica de superficie de consumo de combustible en Litros/hora

En la figura 6.71, se puede apreciar las gráficas de consumo de combustible en Litros/hora cuando el vehículo se encuentra en parámetro de correcto de funcionamiento (A) y con la falla de dosado Rico (B), como se parecía la gráfica (A), el consumo de combustible mayor cuando el porcentaje de la apertura del mariposa se encuentra aproximadamente a un 50% y con la falla (B) el consumo de combustible es mayor cuando el porcentaje de la apertura del mariposa se encuentra aproximadamente a un 95%




Figura 6.71. Gráfica de superficie de consumo de combustible.

Fuente: Autores

6.4.1.1.4 Gráfica de superficie de consumo de combustible con respecto a los tipos de fallas

En la figura 6.72, se muestra la gráfica de superficie de consumo de combustible Litros/hora frente a los tipos de fallas que se generaron en el motor y el porcentaje de apertura de la mariposa (TPS).




Figura 6.72. Gráfica de superficie con respecto a los fallos generados.

Fuente: Autores.

6.4.1.2 Gráfica de intervalos de monóxido de carbono

En la figura 6.73, se muestra la gráfica de intervalos de monóxido carbono generado por el motor, donde se observa cuando no existe falla en el sistema, el valor de CO se encuentran en los límites máximos de emisiones permitidas para fuentes móviles; en cambio cuando se provoca alguna de las tres fallas, el porcentaje de CO aumenta considerablemente, así superando los límites máximos de emisiones permitidos.




Figura 6.73. Comportamiento del CO con respecto a los fallos provocados.

Fuente: Autores.

6.4.1.2.1 Gráficas de contorno de monóxido de carbono con el vehículo en parámetro de correcto funcionamiento

En la figura 6.74, se muestra la gráfica de contorno de monóxido de carbono (CO), con el vehículo en parámetro de correcto funcionamiento, donde el porcentaje del CO se encuentra en los límites permitido, el porcentaje de dicho gas contaminante se incrementa cuando el porcentaje de la apertura de la mariposa se encuentra aproximadamente entre (38% a 98%), el mayor porcentaje de CO en estas condiciones de funcionamiento es de 0.3%.




Figura 6.74. Gráfica de contorno del CO vs TPS y MAP.

Fuente: Autores.

6.4.1.2.2 Gráfica de contorno de porcentaje de monóxido de carbono con falla de dosado Rico

La gráfica de contorno de porcentaje de monóxido de carbono (CO) con falla de dosado Rico es mayor con respecto con el vehículo en parámetros de correcto funcionamiento, el porcentaje de CO es más significativo cuando se genera la dicha falla, esta se genera cuando la apertura de la mariposa se encuentra entre (55% a 100%), donde el porcentaje de CO es aproximadamente de 2.6 %, como se muestra en la gráfica 6.75.




Figura 6.75. Gráfica de contorno del CO con mezcla de dosado rico.

Fuente: Autores.

6.4.1.2.3 Gráfica de superficie del monóxido de carbono

En la figura 6.76, se puede apreciar las gráficas de porcentaje de monóxido de carbono, cuando el vehículo se encuentra en parámetro de correcto de funcionamiento (A) y con la falla de dosado Rico (B), como se parecía la gráfica (A), el CO es mayor cuando el porcentaje se genera la falla de dosado rico en el motor de combustión interna.




Figura 6.76. Gráfica de superficie del CO.

Fuente: Autores.

6.4.1.2.4 Gráfica de superficie de porcentaje de monóxido de carbono

En la figura 6.77, se muestra la gráfica de superficie del porcentaje de monóxido de carbono (CO), frente a los tipos de fallas que se generaron en el motor y el porcentaje de apertura de la mariposa (TPS).




Figura 6.77. Gráfica de superficie de porcentaje de monóxido de carbono.

Fuente: Autores.

6.4.1.3 Gráfica de intervalos de la relación estequiométrica (AFR)

La figura 6.78, se muestra una gráfica de intervalos de la relación estequiometria (AFR), donde se observa que cuando no existe falla en el motor, el AFR se encuentra en el rango adecuado; en cambio cuando se provoca alguna de las tres fallas que se explicó anteriormente, el AFR disminuye considerablemente.




Figura 6.78. Comportamiento del AFR con respecto a los fallos provocados.

Fuente: Autores.

6.4.1.3.1 Gráficas de contorno de la relación estequiometria con el vehículo en parámetros de correcto funcionamiento

En la figura 6.79, se muestra la gráfica de contorno de AFR con el vehículo en parámetros de correcto funcionamiento, donde AFR se encuentra en los valores adecuados.




Figura 6.79. Gráfica de contorno del AFR vs TPS y VSS.

Fuente: Autores.

6.4.1.3.2 Gráficas de contorno de la relación estequiometría con el vehículo en parámetros de correcto funcionamiento

En la figura 6.80, se muestra la gráfica de contorno de la relación estequiometría AFR en función de la velocidad del vehículo y el porcentaje de apertura de la mariposa, donde AFR es mayor cuando la velocidad se encuentra (50 a 85)km y la apertura de la mariposa entre (50 a 95) %.




Figura 6.80. Gráfica de contorno con respecto a la falla de dosado rico.

Fuente: Autores.

6.4.1.3.3 Gráfica de superficie de la relación estequiométrica

En la figura 6.81, se puede apreciar las gráficas de superficie de la relación estequiométrica (AFR), cuando el vehículo se encuentra en parámetro de correcto de funcionamiento (A) y con la falla de bajo voltaje de encendido (D), como se parecía la gráfica (A), el AFR es menor con respecto a la gráfica (D)




Figura 6.81. Gráfica de superficie de la relación estequiométrica.

Fuente: Autores.

6.4.1.3.4 Gráfica de superficie del porcentaje de la relación estequiométrica

En la figura 6.82, se muestra la gráfica de superficie de la relación estequiométrica (AFR), frente a los tipos de fallas que se generaron en el motor y el porcentaje de apertura de la mariposa (TPS).

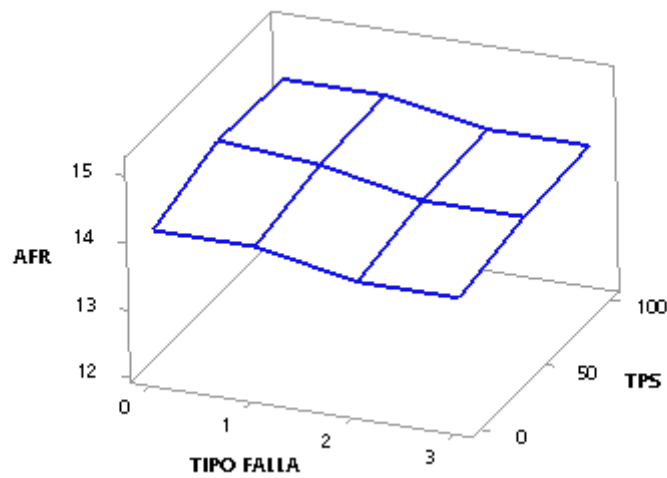


Figura 6.82. Gráfica de superficie del AFR con respecto a los fallos generados.

Fuente: Autores.

6.4.1.4 Comportamiento de la fuerza tractora con respecto a los fallos generados

En la figura 6.83, se muestra la gráfica de intervalos de la fuerza tractora del vehículo, donde se observa cuando no existe falla en el sistema, la fuerza tractora es normal; en cambio cuando se realiza la falla 1 aumenta la fuerza al tener mayor entrada de combustible, mientras con la falla 2 y 3 ocurre lo contrario la fuerza tractora disminuye.




Figura 6.83. Comportamiento de la fuerza tractora con respecto a los fallos generados.

Fuente: Autores.

6.4.1.4.1 Gráfica de contorno de la fuerza tractora con el vehículo en parámetros de correcto funcionamiento

En la figura 6.82, se muestra la gráfica de contorno de la fuerza tractora con el vehículo en parámetros de correcto funcionamiento, donde la fuerza tractora del vehículo máxima es de aproximadamente de 1200 N, cuando el porcentaje de apertura de la mariposa se encuentra entre (55 a 100) %




Figura 6.84. Gráfica de contorno de la fuerza tractora con el vehículo en perfectas condiciones.

Fuente: Autores.

6.4.1.4.2 Gráfica de contorno de fuerza tractora del vehículo con dosado rico

En la figura 6.85, se muestra la Gráfica de contorno de fuerza tractora del vehículo con la falla de dosado rico es mayor con respecto con el vehículo en parámetros de correcto funcionamiento, la fuerza tractora es de aproximadamente 1500 N, cuando la apertura de la mariposa se encuentra entre (70 a 85) %.




Figura 6.85. Gráfica de contorno con dosado rico.

Fuente: Autores.

6.4.1.4.3 Gráfica de contorno de fuerza tractora del vehículo con dosado pobre

En la figura 6.86, se muestra la gráfica de contorno de fuerza tractora del vehículo con la falla de dosado pobre es menor con respecto con el vehículo en parámetros de correcto funcionamiento y dosado rico, la fuerza tractora es de aproximadamente 1000 N, cuando la apertura de la mariposa se encuentra entre (45 a 95) %.




Figura 6.86. Gráfica de contorno de la fuerza tractora con dosado pobre.

Fuente: Autores.

6.4.1.4.4 Gráfica de superficie de fuerza tractora.

En la figura 6.87, se muestra la gráfica de superficie de la fuerza tractora, cuando el vehículo se encuentra en parámetro de correcto funcionamiento (A), dosado rico (B) y dosado pobre (C), se puede corroborar que la fuerza del motor de encendido provocado aumenta al generar la falla de dosado rico, pero al generar la falla de dosado pobre, la fuerza tractora disminuye notablemente.




Figura 6.87. Gráfica de superficie de la fuerza tractora con respecto a los fallos.

Fuente: Autores.

6.4.2 Comprobación del software desarrollado

Para la verificación del estudio planteado se desarrolla una plataforma más amplia en el software Labview en base al programa desarrollado para la recopilación de datos, mediante el entrenamiento desarrollado se predice los valores realizando nuevamente pruebas al vehículo utilizado.

En la figura 6.88, se presenta la predicción de los diferentes valores analizados en el estudio, con el vehículo en correctos parámetros de funcionamiento, de esta manera se puede observar que los valores de gases como son el CO, CO₂, O₂ y HC se encuentran en un rango moderado para las condiciones en las que se encuentra en vehículo de pruebas.




Figura 6.88. Predicción de las variables de respuesta con el vehículo en estado OK.

Fuente: Autores.

6.4.2.1 Predicción con presión de combustible de 60 psi

En la figura 6.89, se puede observar la predicción al generar un cambio en la presión de combustible, al aplicar un dosado rico se enriquece la mezcla por lo que los valores de

emisiones suben y los efectos que se presentan en la fuerza y potencia presentan un aumento notorio.




Figura 6.89. Predicción de valores al aplicar un dosado rico en la mezcla.

Fuente: Autores.

6.4.2.2 Predicción con presión de combustible de 40 psi

En la figura 6.90, se evidencia los cambios que genera una mezcla pobre en el vehículo,




Figura 6.90. Predicción de valores al aplicar un dosado pobre en la mezcla.

Fuente: Autores.

6.4.2.3 Predicción con un bajo voltaje de encendido

En la figura 6.91, se puede apreciar la predicción de los cambios en los diferentes valores de emisiones contaminantes, fuerza, potencia y consumo al aplicar un cambio en el voltaje de encendido.




Figura 6.91. Predicción con un bajo voltaje de encendido.

Fuente: Autores.

7. CONCLUSIONES

- Mediante el análisis de fallas se pretende optimizar el tiempo que se utiliza en determinar la fallas que se presentan en el funcionamiento del motor de combustión interna, en el campo mecánico se recurre a la experticia del ser humano para la corrección de fallos presentes en el motor de combustión interna. Mediante herramientas de aprendizaje y clasificación y el entrenamiento de un sistema de diagnóstico de fallos se obtiene de forma acertada la determinación del fallo ahorrando tiempo y costos de operación.
- Las herramientas de aprendizaje y clasificación permiten distinguir en clases las fallas y diferenciar si el motor de encendido provocado se encuentra en buen estado o existe presencia de algún tipo de falla. Al interferir en el correcto funcionamiento generar fallas de dosado rico, dosado pobre y bajo voltaje de encendido, en un motor de combustión interna, existen consecuencias de exceder los límites máximos permitidos de los gases contaminantes para motores de encendido provocado. el porcentaje de validez es mayor al 90 %, por lo que el sistema es aplicable en la detección de fallas en motores de combustión interna.
- Los resultados de estudio muestran que la falla de Dosado rico, es más significativa en comparación a las otras dos fallas, esta falla genera un aumento de los gases contaminantes, mientras que al generar las fallas por dosado pobre y bajo voltaje de encendido no afecta de forma significativa a los niveles de emisiones. La gráfica de intervalos y gráficas de superficie permite identificar que la falla de dosado rico es la más significativa en todos los gases contaminantes.
- El consumo de combustible, de acuerdo a la alteración en el sistema de presión es la que representa un incremento significativo en el consumo en L/H y L/100km, cuando se genera fallas, ya sea en mezcla de Dosado rico, Dosado pobre, y de igual manera al aplicarse fallas en el sistema de encendido. Con respecto a la fuerza tractora y potencia del motor de combustión interna la falla de Dosado rico aumenta la potencia y fuerza, mientras que la falla de Dosado pobre conlleva a reducir las prestaciones del vehículo mencionadas anteriormente, de igual forma al aplicarse la falla en el sistema de encendido se presenta una disminución en la variables mencionadas con anterioridad.

- Cuando se genera las fallas, los valores arrojados por las herramientas de aprendizaje y clasificación, son similares a los del programa realizado para la predicción, donde una validación de la misma es de un 97.8%.

8. RECOMENDACIONES

- Las diferentes pruebas realizadas en la presente investigación se enfocaron en un vehículo de uso particular, por lo que se recomienda ampliar el uso y aplicación en otros vehículos utilizados en el campo automotor.
- El proyecto desarrollado servirá para trabajos futuros enfocados en la predicción de las fallas y su gravedad en motores de combustión interna, trabajos como:
 - “ANÁLISIS DE MODOS DE FALLA, EFECTOS Y CRITICIDAD (AMFEC) DEL SISTEMA DE INYECCIÓN DE UN MOTOR DE ENCENDIDO PROVOCADO CORSA EVOLUTION 1.4L EMPLEANDO HERRAMIENTAS DE APRENDIZAJE Y CLASIFICACIÓN PARA LA PROGRAMACIÓN DEL MANTENIMIENTO”
 - “DETERMINACIÓN DE LA FIABILIDAD DE UN MOTOR CORSA EVOLUTION 1.4L A PARTIR DEL ANÁLISIS DE MODOS DE FALLAS EN LÍNEA BASADO EN LA DISTRIBUCIÓN DE WEIBULL”
 - “SISTEMA DE TOMA DE DECISIONES INTELIGENTES PARA EL MANTENIMIENTO PREDICTIVO Y PREVENTIVO DEL SISTEMA DE INYECCIÓN DE UN MOTOR DE COMBUSTIÓN INTERNA DE CICLO OTTO”

10. BIBLIOGRAFÍA

- González, M. (2012). Diagnóstico de fallas en un motor.
- Acosta, J. A., & Nieto, J. P. (2014). Detección y diagnóstico de fallas para la dinámica lateral de un automóvil. México: Corporación Mexicana de Investigación en Materiales, S.A. de C.V. (COMIMSA).
- Amaury B. Andre, E. B. (s.f.). A combination of support vector machine and K-nearest neighbors for machine fault detection. Applied.
- Andre, A. B., Beltrame, E., & Wainer, J. (s.f.). A combination of support vector machine and K-nearest neighbors for machine fault detection. Applied.
- Automecanico. (11 de 07 de 2017). Obtenido de Automecanico: <http://automecanico.com/auto2027/bbooster06.pdf>
- Automecanico. (12 de 07 de 2017). Obtenido de Automecanico: <http://automecanico.com/auto2027A/chevr1222.html>
- Automecanico. (11 de 07 de 2017). automecanico. Obtenido de automecanico: <http://automecanico.com/auto2027/bbooster05.pdf>
- Baoling Liu, D. H. (2013). An improved PSO-SVM model for online recognition. 367-385.
- Basseville, M. y. (Noviembre de 1998). Detection of Abrupt Changes - Theory and Application. Obtenido de <http://www.irisa.fr/sigma2/kniga/>
- Bo, & Qin. (2010). Fault Diagnosis Method of Automobile Engine Based on Least Squares Support. International Conference on Signal Processing Systems.
- Bo, Q. (2010). Fault Diagnosis Method of Automobile Engine Based on Least Squares Support. International Conference on Signal Processing Systems.
- Burges. (2012). A Tutorial on Support Vector Machines for Pattern Recognition. Boston.
- Burges, C. (2012). A Tutorial on Support Vector Machines for Pattern Recognition. Boston.
- Burges, C. (2012). A Tutorial on Support Vector Machines for Pattern Recognition. Boston.

- Carrasco, R. A. (Agosto de 2007). Detección y diagnóstico de fallas en robots móviles cooperativos. Santiago de Chile, Chile: Pontificia Universidad Católica de Chile .
- Ejíque, & Valásquez, J. (2011). Aplicación de la inteligencia artificial.
- Ejíque, J. V. (2011). Aplicación de la inteligencia artificial.
- González, D. (2015). Motores Termicos y sus sistemas auxiliares . Madrid: Paraninfo .
- Granda, & Herrera, I. D. (11 de 07 de 2017). repositorio.ute.edu.ec. Obtenido de repositorio.ute.edu.ec:
repositorio.ute.edu.ec/bitstream/123456789/4827/1/48108_1.pdf
- Hernandez, & Cardona, P. A. (2015). Aplicación de árboles de decisión en modelos.
- Hernandez, P. A. (2015). Aplicación de árboles de decisión en modelos.
- Jesús Alejandro Navarro Acosta, J. P. (2014). Detección y diagnóstico de fallas para la dinámica lateral de un automóvil. México: Corporación Mexicana de Investigación en Materiales, S.A. de C.V. (COMIMSA).
- Liu, B., Hou , D., Pingjie , H., Banteng , L., & Huayi, T. (2013). An improved PSO-SVM model for online recognition. 367-385.
- Luini Leonardo Hurtado-Cortés, E. V.-L.-L. (2016). Fault detection and diagnosis through artificial intelligence. DYNA.
- Mahmood, Y. S. (2014). Fault Diagnosis in Internal Combustion Engines Using Extension Neural Network.
- Maldonado, & Guevara, C. B. (2012). Reconocimiento de patrones para árbol de desición.
- MALDONADO, C. B. (2012). RECONOCIMIENTO DE PATRONES PARA.
- Maldonado, C. B. (2012). Reconocimiento de patrones para árbol de desición.
- Manuel González. (2012). Diagnóstico de fallas en un motor.
- McDermoott, & Charniak. (1985). Fundamentos de inteligencia artificial.
- McDermoott, C. (1985). Fundamentos de inteligencia artificial.
- National Instruments. (11 de 07 de 2017). sine.ni.com. Obtenido de sine.ni.com:
<http://sine.ni.com/nips/cds/view/p/lang/es/nid/201986>

- Ngoc-Tu Nguyen, J.-M. K.-H. (2007). A Study on Machine Fault Diagnosis using Decision Tree . Journal of Electrical Engineering & Technology.
- Riobó , V., & Ortega. (2012). Reconocimiento de localizaciones mediante máquinas de soporte vectorial. Madrid, España.
- Riobó Otero, V. (2012). Reconocimiento de localizaciones mediante máquinas de soporte vectorial. Madrid, España.
- Rivera, D., & Chica, F. (09 de 2015). bibdigital.epn.edu.ec. Obtenido de bibdigital.epn.edu.ec: bibdigital.epn.edu.ec/bitstream/15000/12459/1/CD-6643.pdf
- Rolf Isermann. (2007). Diagnóstico y detección de falla.
- Setamer. (11 de 07 de 2017). equiposautomotriz. Obtenido de equiposautomotriz: <http://equiposautomotriz.com/wp-content/uploads/2013/12/gasanálisisngga6000.jpg>
- Takeyas, & López, B. (2017). Introducción a la inteligencia artificial. México.
- Takeyas, B. L. (2017). Introducción a la inteligencia artificial. México.
- Targera.daq. (07 de 2015). Obtenido de www.ni.com: <http://www.ni.com/pdf/manuals/371303n.pdf>
- www.ni.com. (2017). Obtenido de www.ni.com: <http://www.ni.com/data-acquisition/what-is/esa/>

11. ANEXOS

11.1 Comportamiento del monóxido de carbono




Figura A 1. Gráfica de contorno de contorno del monóxido de carbono.

Fuente: Autores.




Figura A 2. Gráfica de contorno con respecto a la falla de dosado rico.

Fuente: Autores.




Figura A 3. Gráfica de superficie del monóxido de carbono con respecto al dosado pobre.

Fuente: Autores.




Figura A 4. Gráfica de superficie del monóxido de carbono con respecto a un bajo voltaje de encendido.

Fuente: Autores.

11.2 Comportamiento del consumo de combustible en L/100Km con respecto a los fallos generados




Figura A 5. Gráfica de contorno del consumo de combustible en L/100Km con respecto a un dosado pobre.

Fuente: Autores.




Figura A 6. Gráfica de contorno del consumo de combustible en L/100Km con respecto a un bajo voltaje de encendido.

Fuente: Autores.




Figura A 7. Gráfica de superficie con respecto a un voltaje bajo de encendido.

Fuente: Autores.




Figura A 8. Gráfica de superficie con respecto a un dosado pobre.

Fuente: Autores.

11.3 Comportamiento de la relación estequiométrica con respecto a los fallos generados




Figura A 9. Gráfica de contorno de AFR con respecto a un dosado pobre.

Fuente: Autores.




Figura A 10. Gráfica de contorno de AFR con respecto a un bajo voltaje de encendido.

Fuente: Autores.




Figura A 11. Gráfica de superficie de AFR con respecto a un dosado pobre.

Fuente: Autores.

Gráfica de superficie de AFR vs. TPS. VSS




Figura A 12. Gráfica de superficie de AFR con respecto a un dosado rico.

Fuente: Autores.

11.4 Comportamiento de la fuerza con respecto a las fallas provocadas




Figura A 13. Gráfica de superficie de fuerza con respecto a un bajo voltaje de encendido.

Fuente: Autores.




Figura A 14. Gráfica de contorno de fuerza con respecto a un bajo voltaje de encendido.

Fuente: Autores.




Figura A 15. Software para la adquisición de datos.

Fuente: Autores.




Figura A 16. Software para la predicción de valores.

Fuente: Autores.