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:

"DESARROLLO DE UN PROTOTIPO COMPUTACIONAL DE DIAGNÓSTICO DE AVERÍAS MEDIANTE RECOPILACIÓN DE DATOS DEL SENSOR CKP DE UN MOTOR DAEWOO GM F16D3A"

AUTORES:

JUAN PABLO LUNA ÁVILA

JOHN ANDRÉS TAPIA PALACIOS

TUTOR:

ING. RAFAEL WILMER CONTRERAS URGILÉS, MsC.

CUENCA - ECUADOR

2021

CESIÓN DE DERECHOS DE AUTOR

Nosotros, Juan Pablo Luna Ávila con documento de identificación N° 0301932893 y John Andrés Tapia Palacios con documento de identificación N° 1104720311, 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: **"DESARROLLO DE UN PROTOTIPO COMPUTACIONAL DE DIAGNÓSTICO DE AVERÍAS MEDIANTE RECOPILACIÓN DE DATOS DEL SENSOR CKP DE UN MOTOR DAEWOO GM F16D3A",** 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 la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Cuenca, julio de 2021.

Juan Pablo Luna Ávila	John Andrés Tapia Palacios
C.I. 0301932893	C.I. 1104720311

CERTIFICACIÓN

Yo, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: **"DESARROLLO DE UN PROTOTIPO COMPUTACIONAL DE DIAGNÓSTICO DE AVERÍAS MEDIANTE RECOPILACIÓN DE DATOS DEL SENSOR CKP DE UN MOTOR DAEWOO GM F16D3A"**, realizado por Juan Pablo Luna Ávila y John Andrés Tapia Palacios, obteniendo el *Proyecto Técnico*, que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana.

Cuenca, julio de 2021.

Ing. Rafael Wilmer Contreras Urgilés, MsC.

C.I. 0104463328

DECLARATORIA DE RESPONSABILIDAD

Nosotros, Juan Pablo Luna Ávila con documento de identificación N° 0301932893 y John Andrés Tapia Palacios con documento de identificación N° 1104720311, autores del trabajo de titulación: **"DESARROLLO DE UN PROTOTIPO COMPUTACIONAL DE DIAGNÓSTICO DE AVERÍAS MEDIANTE RECOPILACIÓN DE DATOS DEL SENSOR CKP DE UN MOTOR DAEWOO GM F16D3A",** certificamos que el total contenido del *Proyecto Técnico,* es de nuestra exclusiva responsabilidad y autoría.

Cuenca, julio de 2021.

Juan Pablo Luna Ávila	John Andrés Tapia Palacios
C.I. 0301932893	C.I. 1104720311

DEDICATORIA

Dedicado a todos quienes estuvieron siempre para guiarme en el proceso de aprendizaje que ha sido esta parte de mi vida. De manera especial a mi Madre, por ser el ejemplo constante de lucha y sacrificio; a mi hermano por convertirse en un Padre en la época de adversidad y finalmente a la mujer que en el camino me acompañó hasta verme triunfar.

Juan Pablo Luna

DEDICATORIA

El presente trabajo investigativo lo dedico principalmente a Dios, por ser mi fuerza y guía para poder culminar este proceso y cumplir uno de mis sueños más deseados.

A mis padres, por su aliento esfuerzo y cariño que día tras día durante todos estos años, he logrado terminar una etapa más en mi vida que sin su ayuda nada de ello sería una realidad.

A mis hermanos por su apoyo incondicional y jamás dejarme desmayar durante el trascurso de estos años y que la vida me regale más tiempo para poderlos disfrutar luego de estar por muchos años lejos de casa.

A mis abuelitos quienes son un pilar fundamental en mi vida por sus consejos y por todo su amor sin límites.

A mi compañera de vida por estar siempre junto a mi dándome su mano en los momentos más difíciles

John Andrés Tapia Palacios

AGRADECIMIENTO

Mi mayor gratitud a quien ha sido parte fundamental en mi desarrollo; a esa persona que siempre me apoyo desde el inicio, que tuvo ese coraje y perseverancia para brindarme todo lo necesario en mi anhelo de convertirme en profesional. Madre tú eres la inspiración de mi vida y el ejemplo de lo que un día quiero llegar a ser. No existen palabras para demostrarte mi eterno agradecimiento. Te amo mami.

A mis hermanos que fueron una parte indispensable en el proceso académico y creyeron en mi cada vez que lo necesitaba.

A la mujer que un día llegó para quedarse; gracias a ti por no dejarme caer y estar siempre para alentarme y motivarme. Luchaste conmigo todo este tiempo, así que también este logro es tuyo. Te amo

Al Ing. Wilmer Contreras Urgiles MSc. Tutor del trabajo de titulación, quien desde las aulas de clase supo inculcar conocimiento académico, así como calidez humana; gracias por todas las facilidades prestadas para la culminación de este proyecto y la confianza depositada en mí.

Juan Pablo Luna

AGRADECIMIENTO

Mi gratitud hacia Dios, quien con su bendición ha obrado en mí. Gracias a mis padres, por creer en mi por permitirme volar lejos por dejarme soñar siempre en grande por ser mi apoyo incondicional a lo largo de mi vida.

Gracias a mis hermanos quienes me ayudaron a lo largo de este camino, su cariño y compresión hoy se ve reflejado en mis logros. Gracias a las palabras de aliento de mis familiares y amigos quienes me ayudaron de manera desinteresada.

Gracias a la mujer que llego a mi vida, para ayudarme día tras día a sacar la mejor versión de mí.

Desde las aulas a mi tutor quien me supo guiar y compartir sus conocimientos con los valores y calidez humana.

Tapia Palacios John Andrés

RESUMEN

En este proyecto se detalla la metodología aplicada para la creación de un sistema de diagnóstico de averías supervisadas en el motor de combustión GM F16D3A acoplado a vehículo Chevrolet AVEO mediante redes neuronales artificiales.

La herramienta de diagnóstico se fundamenta en el análisis de la velocidad angular del cigüeñal en la fase de combustión del ciclo Otto, misma que es traducida como una señal de voltaje por medio del sensor CKP (Crankshaft Position Sensor).

El proceso de muestreo responde a un protocolo de adquisición de datos estrictamente definido que permite la correcta obtención y análisis de los parámetros estadísticos de la señal del sensor CKP como: área, máximo, mínimo, varianza, kustosis, raíz media cuadrada (RMS), factor de cresta, asimetría, energía, potencia mismos que se caracterizan por ser influyentes de manera significativa.

Los datos se obtienen por medio de un algoritmo de post procesamiento en el software LabVIEW que permite acondicionar las señales y generar una matriz de datos para la creación y entrenamiento de una RNA. Para la clasificación de la condición de funcionamiento del motor la RNA (Red neuronal artificial) es de tipo Newff *(feed-forward backpropagation)* con una función de transferencia "traincgb", un total de 30.000 épocas, error máximo de 10.000 ($1e^4$) y un gradiente de $1e^{-50}$.

La fase de comprobación y validación se realiza a través de un análisis estadístico por el método de ANOVA, que da como resultado una fiabilidad mayor al 95%.

Pablaras Clave: diagnóstico de fallos, velocidad angular del cigüeñal, CKP, red neuronal, ANOVA.

ABSTRACT

This project details the methodology applied for the creation of a supervised fault diagnosis system in the GM F16D3A combustion engine coupled to a Chevrolet AVEO vehicle by means of artificial neural networks.

The diagnostic tool is based on the analysis of the crankshaft angular velocity in the combustion phase of the Otto cycle, which is translated as a voltage signal by means of the CKP sensor (Crankshaft Position Sensor).

The sampling process responds to a strictly defined data acquisition protocol that allows the correct obtaining and analysis of the statistical parameters of the CKP sensor signal such as: area, maximum, minimum, variance, kustosis, root mean square (RMS), crest factor, asymmetry, energy, power, which are characterized by being significantly influential.

The data are obtained by means of a post-processing algorithm in LabVIEW software that allows conditioning the signals and generating a data matrix for the creation and training of an ANN. For the classification of the engine operating condition, the ANN (artificial neural network) is of the Newff (feed-forward backpropagation) type with a transfer function "traincgb", a total of 30,000 epochs, a maximum error of 10,000 (1e4) and a gradient of 1e-50.

The testing and validation phase is performed through a statistical analysis by the ANOVA method resulting in a reliability greater than 95%.

Key words: fault diagnosis, crankshaft angular velocity, CKP, neural network, ANOVA.

Índice

1. INTRODUCCIÓN 1
2. PROBLEMA 2
2.1 Antecedentes. 2
2.2 Importancia y alcances. 2
2.3 Delimitación. 3
3. OBJETIVOS 4
3.1 Objetivo general. 4
3.2 Objetivos específicos. 4
4. REVISIÓN DE LA LITERATURA 5
4.1 Motor de combustión interna. 5
4.1.1 Motor de ciclo Otto 4 tiempos. 5
4.2 Mecanismo biela-manivela. 6
4.2.1 Cinemática del mecanismo biela - manivela. 8
4.3 El Cigüeñal. 9
4.3.1 Esfuerzos que actúan en el cigüeñal. 11
4.3.2 Velocidad angular del cigüeñal. 12
4.3.3 Coeficiente de fluctuación de velocidad angular. 12
4.3.4 Volante de inercia y la regulación de la velocidad angular. 12
4.4 Sensores. 13
4.4.1 Sensor de posición angular del cigüeñal y velocidad de giro. 14
4.4.2 Rueda Fónica. 14
4.4.3 Sensor CKP Tipo Hall. 15
4.4.4 Sensor CKP Tipo Óptico. 16
4.4.5 Sensor CKP Tipo inductivo. 17
4.4.6 Funcionamiento del sensor inductivo. 17
4.4.7 Magnitudes Físicas del sensor CKP. 18
4.5 Métodos Estadísticos. 19
4.5.1 Estadística descriptiva. 19
4.5.2 Estadística Inferencial. 21
4.5.3 ANOVA (Análisis de Varianza). 21
4.5.4 Análisis simple de la varianza (One-Way ANOVA) 22
4.6 Redes neuronales. 23
4.6.1 Reseña histórica de las redes neuronales. 23

4.6.2 Características de una RNA. 23
4.6.3 Estructura de una RNA. 24
4.6.4 Tipos de RNA. 25
4.6.5 Funcionamiento de una RNA. 27
4.6.6 Entrenamiento. 27
4.6.7 Sobreanprendizaje. 28
4.6.8 Simulación. 28
5. ESTADO DEL ARTE DEL DIAGNOSTICO DE AVERÍAS BASADAS EN REDES NEURONALES. 30
6. MARCO METODOLÓGICO. 32
6.1 Instrumento de experimentación. 32
6.1.1 Sensor CKP para análisis. 35
6.1.2 Características del sensor CKP. 36
6.1.3 Condiciones de funcionamiento aplicadas a la unidad experimental. 37
6.1.4 Desarrollo de las averías a supervisadas en el motor Daewoo GM F16D3A. 37
6.1.5 Averías generadas en los cilindros al calibrar las bujías con una holgura de cero. 38
6.1.6 Avería generada en la presión de combustible 38
6.1.7 Avería generada al filtro de aire. 41
6.1.8 Averías en componentes electrónicos. 41
6.1.9 Avería en el Sensor IAT. 43
6.1.10 Avería en el sensor de oxígeno. 43
6.1.11 Avería en el sensor TPS 43
6.1.12 Avería en la Válvula IAC. 44
6.2 Factores no controlados del experimento. 44
6.3 Recolección de datos. 44
6.3.1 Software LabVIEW. 45
6.3.2 Hardware NI Daq USB-6212. 45
6.3.3 Conexión física de los instrumentos. 46
6.3.4 Configuración de la tarjeta. 46
6.4 Protocolo de adquisición de datos. 48
6.5 Algoritmo para la adquisición de datos. 49
6.5.1 Nomenclatura para el archivo de la muestra. 50
6.6 Algoritmo para el post procesamiento de datos. 50
6.7 Algoritmo de diagnóstico para la detección de fallas mecánicas. 59

6.7.1 Proceso para la determinación de averías. 64
6.7.2 Lectura de red neuronal en LabVIEW. 65
7. ANÁLISIS DE RESULTADOS. 69
7.1 Resultados de la red neuronal en el motor. 69
7.2 Análisis de varianzas para validación de resultados. 75
7.2.1 ANOVA para avería de bujía 2. 80
7.2.2 ANOVA para avería de presión de combustible a 10 psi. 81
7.2.3 ANOVA para avería de presión de combustible a 33 psi. 82
7.2.4 ANOVA para avería de presión de combustible a 44.5 psi. 84
7.2.5 ANOVA para la matriz general. 85
8. CONCLUSIONES 87
9. RECOMENDACIONES 88
10. BIBLIOGRAFÍA 89
11. ANEXOS. 93

Índice de Figuras

Figura 1. Fases de un motor de 4 tiempos Fuente: (Payri F, 2011). 6
Figura 2. Mecanismo Biela - Manivela. Fuente:(Payri González & Desantes Fernández, 2014) 7
Figura 3. Descentramiento del cigüeñal. Fuente:(Payri González & Desantes Fernández, 2014) 7
Figura 4. Posición, velocidad y aceleración del pistón. Fuente: Autores 9
Figura 5. Componentes del cigüeñal Fuente:(Alonso Pérez, 2009) 10
Figura 6. Fuerzas y esfuerzos actuantes en el cigüeñal. Fuente: (Burgos, B. & Freire, E, 2008). 11
Figura 8. Disposiciones de Rueda Fónica Fuente:(Rt, 2015)00 15
Figura 12. Funcionamiento del sensor CKP Fuente:(Sánchez, 2011) 18
Figura 13. Señal del sensor CKP. a) Voltaje b) Identificación del doble diente. Fuente: (SANGYONG, 2015). 18
Figura 14. Esquema básico de ANOVA Fuente: Autores. 22
Figura 16. Estructura (Biológica) de una RNA Fuente: (Asanza & Mazón, 2018). 25
Figura 17. Estructura de una RNA Fuente:(Basogain, 2019) 25
Figura 19. Simulación de la red. Fuente: Garzón & Urdiales (2017) 29
Figura 20. Sensor CKP Fuente: (GMSA Chevrolet, 2011) 36
Figura 25. Asistente de la tarjeta NI DAQ 6212 Fuente: Autores. 47
Figura 26. Daq Assist en LabVIEW Fuente: Autores. 47
Figura 27. Configuración de características para la prueba. Fuente: Autores 48
Figura 28. Algoritmo de adquisición de señales. Fuente: Autores 49
Figura 29. Señal temporal del sensor CKP en ralentí. Fuente: Autores 50

Figura 30. Filtrado de la señal. Fuente: Autores..... 51
Figura 31. Cortes de los cilindros. Fuente: Autores 51
Figura 32. Corte de los Cilindros 1,3,4 y 2 Fuente: Autores..... 52
Figura 37. Bloque de restas para distancia pico a pico. Fuente: Autores 54
Figura 38. Distancia entre picos. Fuente: Autores..... 55
Figura 39. Bloque para el array de la estadística. Fuente: Autores 56
Figura 40. Interfaz para la prueba 1. Fuente: Autores 57
Figura 41. Interfaz para la prueba 2 Fuente: Autores. 57
Figura 42. Matriz estadística de las dos pruebas Fuente: Autores..... 58
Figura 43. Matriz de datos estadísticos de las dos pruebas Fuente: Autores..... 59
Figura 44. Importación de Matriz de datos a Matlab. Fuente: Autores..... 60
Figura 45. Algoritmo para cargar la matriz de datos. Fuente: Autores 60
Figura 46. Código para obtener el valor máximo de cada uno de los datos. Fuente: Autores 61
Figura 47. Línea de código para la creación de la RNA. Fuente: Autores. 61
Figura 48. Parámetros de la RNA Fuente: Autores. 62
Figura 49. Entrenamiento de la RNA. Fuente: Autores. 62
Figura 51. Código de Matlab para la simulación de la RNA. Fuente: Autores..... 63
Figura 52. Respuesta de la RNA. Fuente: Autores..... 64
Figura 53. Proceso de diseño del algoritmo de detección de averías. Fuente: Autores.. 64
Figura 54. Procesamiento de Red neuronal en LabVIEW..... 65
Figura 55. Comparador para determinar el fallo Fuente: Autores..... 66
Figura 56. Interfaz de Diagnóstico Fuente: Autores..... 67
Figura 57. Lectura del archivo a estudiar. Fuente: Autores..... 67
Figura 58. Interfaz de diganostico Fuente: Autores. 68
Figura 59. Resultado de la red neuronal y condición del vehículo. Fuente: Autor 68
Figura 60. Resultado para avería Bujía 1 Fuente: Autores..... 69
Figura 64. Resultado de avería con presión 10 PSI. Fuente: Autores 71
Figura 65. Resultado de avería con 21.5 Psi. Fuente: Autores..... 71
Figura 66. Resultado para avería Presión 33 psi. Fuente: Autores..... 72
Figura 67. Resultado para avería presión 44.5 psi. Fuente: Autores..... 72
Figura 68. Respuesta para avería Filtro de aire tapado 75%. Fuente: Autores..... 73
Figura 69. Respuesta de filtro tapado al 50%. Fuente: Autores 73
Figura 70. Repuesta de avería desconexión del sensor IAT. Fuente: Autores 74
Figura 71. Respuesta a avería desconexión válvula IAC. Fuente: Autores..... 74
Figura 72. Respuesta a avería desconexión TPS. Fuente: Autores 75
Figura 74. Datos para analizar en Minitab. Fuente: Autores..... 76
Figura 75. ANOVA de un factor en Minitab. Fuente: Autores 77
Figura 76. Parámetros de ANOVA de un factor. Fuente: Autores..... 77
Figura 77. Opciones del ANOVA de un factor. Fuente: Autores..... 78
Figura 78. Método de Tukey. Fuente: Autores..... 78
Figura 94. ANOVA para matriz general. Fuente: Autores..... 85
Figura 95. Intervalos de confianza para matriz general. Fuente: Autores..... 86
Figura 96. Agrupación de las medias para matriz general. Fuente: Autores..... 86

Índice de Tablas

Tabla 1. Parámetros estadísticos. Fuente:(Delgado, 2018) 20
Tabla 2. Características de la red neuronal. Fuente: (Asanza & Mazón, 2018). 24
Tabla 3. Tipos de redes neuronales. Fuente:(Basogain, 2019)..... 26
Tabla 4. Especificaciones del motor Fuente:(GMSA Chevrolet, 2011)..... 32
Tabla 5. Check List de componente para motor en buen estado. Fuente: Autores 33
Tabla 6. Características del sensor CKP Fuente: (GMSA Chevrolet, 2011)..... 36
Tabla 7. Magnitudes del sensor CKP del experimento. Fuete: Autores..... 36
Tabla 8. Descripción de Fallas provocadas. Fuente: Autores 37
Tabla 9. Presiones de combustibles para cada fallo. Fuente: Autores..... 39
Tabla 10. Falla en filtro de aire. Fuente: Autores..... 41
Tabla 11. Falla de Sensores Fuente: Autores. 42
Tabla 12. Nomenclatura de archivos. Fuente: Autores 50
Tabla 13. Códigos de fallo. Fuente: Autores..... 59
Tabla 14. Pruebas de RNA. Fuente: Autores. 61

1. INTRODUCCIÓN

El mantenimiento dentro de la mecánica tiene el objetivo de conservar un equipo en perfecto estado por medio de la supervisión constante de su funcionamiento, ya sea esta una maquinaria industrial o artesanal y sobre todo de uso automotriz. Todo esto desencadena una optimización de los recursos y por consecuente un mayor porcentaje de eficiencia que permite cumplir con el objetivo para el que fue creado. (Bolaños, 2007)

El mantenimiento es cada día más exigente con el pasar de los años. Las técnicas de mantenimiento correctivo como dejar funcionar hasta que sufra un desperfecto son cada vez más inusuales, esto da paso a sistemas tecnológicos no intrusivos con base en inteligencia artificial como protagonista del nuevo esquema de mantenimiento automotriz.

La electrónica automotriz hoy en día es pilar fundamental en el desarrollo de nuevas técnicas de diagnóstico no intrusivo y por consiguiente de mantenimiento. Cada vez son más frecuentes los componentes electrónicos que intervienen en el funcionamiento de los motores, tales como sensores y actuadores, mismos que aportan información sumamente importante respecto al trabajo realizado por dichos motores. En vista a este planteamiento es coherente aprovechar estas las señales proporcionadas por los componentes electrónicos en herramientas de diagnóstico.

Implementar un algoritmo que permita detectar fallas que no son evidentes es un punto de partida para obtener herramientas eficaces de diagnóstico. Una opción son las redes neuronales, mismas que permiten identificar fallos por medio del procesamiento de patrones de cada una de las señales adquiridas del sensor CKP en sus etapas de funcionamiento.

2. PROBLEMA

2.1 Antecedentes.

En la actualidad, la reparación y diagnóstico aplicados a los vehículos automotores se basan desde esquemas artesanales hasta llegar a un alto nivel de tecnificación. El incremento diario del parque automotor demanda servicios especializados con la consiguiente reducción en los tiempos de detección y reparación de fallos; desde el año 2002 Daewoo pasó a formar parte de General Motors (Autocosmos, 2011) y, actualmente en Ecuador se comercializan vehículos ensamblados con autopartes Daewoo bajo la marca Chevrolet, misma que cuenta con la mayor presencia en el mercado, pues sus vehículos se emplean para uso tanto privado como comercial; y, es bajo este concepto que la industria automotriz incorpora tecnologías exponenciales como la inteligencia artificial, ello con la finalidad de acelerar el proceso de diagnóstico de fallas de los vehículos. Bajo este fundamento se carece de un sistema de diagnóstico que permita analizar y detectar eficientemente fallos y averías que las técnicas subjetivas comunes no permiten descubrir; además, los métodos de diagnóstico a bordo actuales como OBD I y OBD II crean códigos de fallo generales respecto de un sistema, más no indican el origen específico, debido a que ciertos daños no son evidentes hasta que el problema genera mayores complicaciones; por otra parte las investigaciones desarrolladas hasta la actualidad basan su desarrollo acorde a otros elementos de análisis como diferentes tipos de sensores, creando de esta manera la necesidad de implementar elementos de diagnóstico especializados que permitan optimizar tiempo y recursos económicos.

2.2 Importancia y alcances.

El presente proyecto de titulación va dirigido a la Carrera Ingeniería Automotriz de la Universidad Politécnica Salesiana sede Cuenca para sus fases de investigación y desarrollo, así como la aplicación práctica por medio de un sistema de diagnóstico que se fundamenta en redes neuronales y el tratamiento de pruebas reales y sincrónicas, que además pueden generar bases de datos para la continuación del desarrollo de la herramienta por parte del GIIT.

La importancia recae en el protagonismo que tiene el mantenimiento preventivo de los motores, siendo esta la razón principal por la cual se pretende crear un algoritmo de

diagnóstico a través del procesamiento de señales del sensor CKP que permita identificar las averías supervisadas del motor con el empleo de un sistema de redes neuronales y por lo tanto definir la herramienta como un método no intrusivo.

El alcance del proyecto plantea la creación de un sistema, el cual se fundamenta en un estudio que parte de la investigación del estado del arte sobre el diagnóstico de fallos del motor de combustión interna a través del análisis de datos del sensor inductivo CKP, mediante un compendio bibliográfico. Como resultado del estudio de este compendio, se plantea realizar la toma de datos del sensor inductivo CKP en etapas de funcionamiento supervisadas del motor y procesarlas mediante la aplicación de LabVIEW. Con la matriz general de datos, procesados en función a los valores estadísticos de la señal como: energía, promedio, desviación estándar, varianza, kurtosis, asimetría, máximo, mínimo y factor de cresta que son seleccionados en función al mayor aporte de información para la caracterización del experimento, se diseña una interfaz computacional para el diagnóstico de averías provenientes del motor de combustión interna. Luego de la aplicación de la propuesta del interfaz computacional basado en una red neuronal RNA, se comprueba la funcionalidad del sistema de diagnóstico en el motor Daewoo GM F16D3A, del cual se espera un error absoluto menor al 5%.

2.3 Delimitación.

El algoritmo permite identificar fallos únicamente del motor DAEWOO GM F16D3A.
Por medio de una investigación bibliográfica se seleccionan un total de 14 fallos, permitiendo establecer una clasificación de acuerdo con la relevancia que tiene cada avería dentro del funcionamiento del MCIA. Como se muestran a continuación: Fallas graves producidas por el incorrecto funcionamiento de las bujías, fallos leves los provocados por el filtro de aire, presión de combustible y fallos muy leves ocasionados por error de los sensores. Entonces el sistema se limita a las averías antes mencionadas.

3. OBJETIVOS

3.1 Objetivo general.

- Desarrollar un prototipo computacional de diagnóstico de averías mediante recopilación de datos del sensor CKP de un motor Daewoo GM F16D3A.

3.2 Objetivos específicos.

- Investigar el estado del arte sobre el diagnóstico de fallos del motor de combustión interna aplicando el análisis de datos del sensor inductivo CKP mediante un compendio bibliográfico.

- Realizar la toma de datos del sensor inductivo CKP en etapas de funcionamiento supervisadas del motor de combustión interna y procesarlas mediante la aplicación de LabVIEW.

- Diseñar una interfaz computacional para el diagnóstico de averías provenientes del motor de combustión interna en base al procesamiento y matriz de datos.

- Comprobar la funcionalidad del sistema de diagnóstico en el motor de combustión interna Daewoo GM F16D3A a través de la generación de fallos aleatorios para su validación.

4. REVISIÓN DE LA LITERATURA

4.1 Motor de combustión interna.

Un MCIA (motor de combustión interna) está definido como un conjunto mecánico en donde un suministro de mezcla aire y combustible se alimenta al interior del cilindro, en donde tiene lugar la compresión y quema. Esta reacción, desprende energía térmica que posteriormente se transforma en trabajo mecánico útil a medida que el pistón se desplaza por efecto de las altas presiones de gas generadas.

Los motores de combustión interna actuales tienen ya más de un siglo de historia. Si hubiera que escoger una fecha del nacimiento de los motores modernos (tal como los conocemos actualmente), esa sería el año 1876.(Payri González & Desantes Fernández, 2014)

4.1.1 Motor de ciclo Otto 4 tiempos.

El motor de ciclo Otto o de encendido provocado presenta la particularidad de requerir de una adición de energía a su ciclo termodinámico, que para la práctica se traduce al uso de una bujía generadora de chispa. La mezcla aire-combustible se realiza fuera del cilindro en la fase de admisión o incluso existe la posibilidad de insertar aire en la admisión y el carburante en la etapa de compresión como los motores modernos con tecnología GDI.

Como se puede apreciar en la Figura 1 el proceso de combustión tiene efecto gracias al avance del frente de llama que se presenta en la cámara de combustión, teniendo a la bujía como el inicio de esta etapa. Los gases quemados resultantes de la etapa anterior generan un incremento de volumen que corresponde al ciclo de salida de gases de escape.(Payri González & Desantes Fernández, 2014)

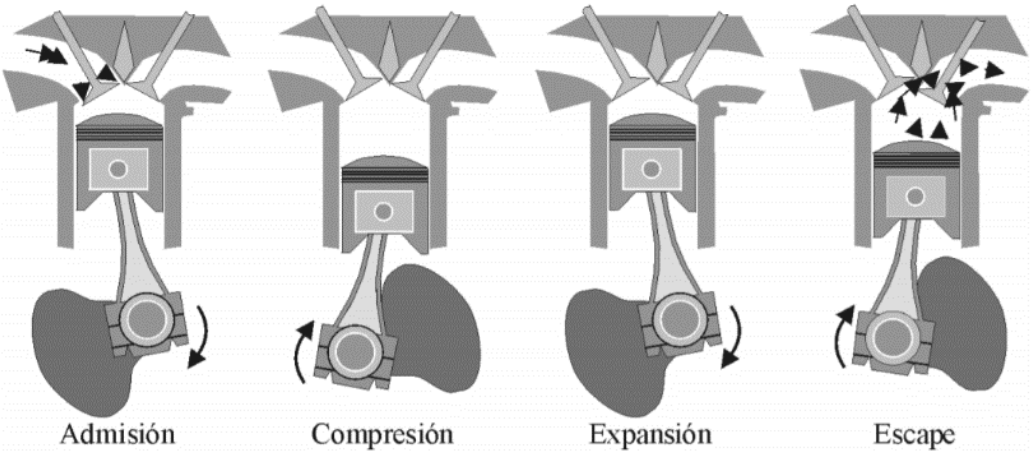

Figura 1.Fases de un motor de 4 tiempos Fuente: (Payri F, 2011).

La combustión del pistón a través de la fuerza generada en el brazo de biela se ve afectada en el movimiento circular del cigüeñal. En este movimiento se evidencia las cuatro etapas de funcionamiento del motor.

4.2 Mecanismo biela-manivela.

El mecanismo biela - manivela es un conjunto mecánico constituido por un brazo y un elemento giratorio que permite transformar el movimiento lineal del pistón en rotación del cigüeñal.

En la Figura 2 se observa la manivela (O_2A) que une el brazo del cigüeñal con los muñones de apoyo (O_2) y las muñequillas (A). La biela tiene una articulación con el pistón en el punto B y con la muñequilla en el punto A. El ángulo del giro de la manivela es ωt (antihorario), Φ representa el ángulo de la biela (horario) con respecto al eje del cilindro O_2B.(Payri González & Desantes Fernández, 2014)

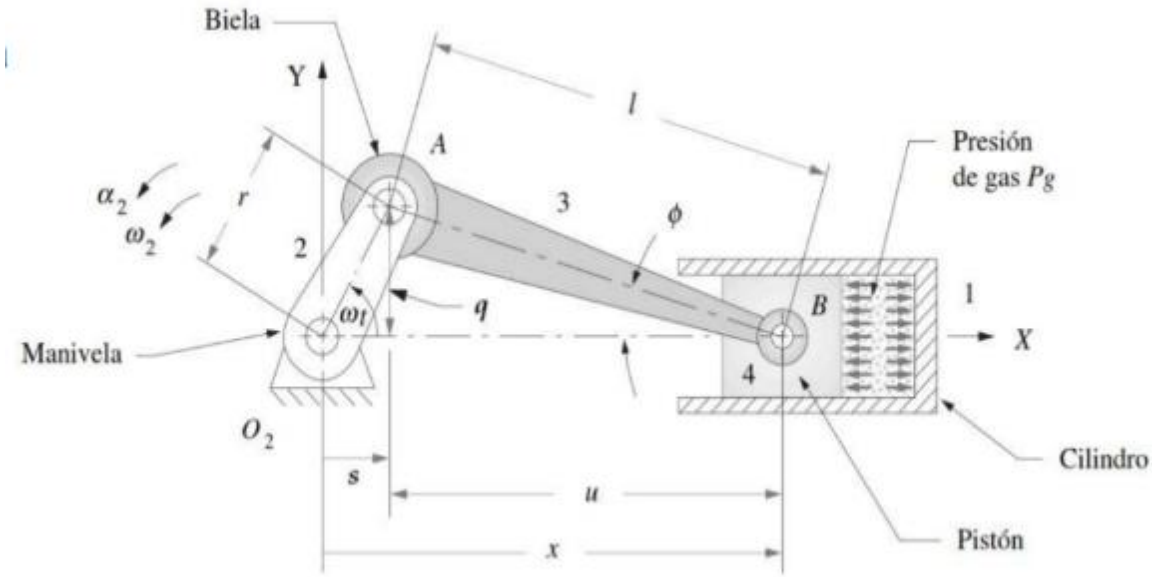

Figura 2. Mecanismo Biela - Manivela. Fuente: (Norton, (Payri González & Desantes Fernández, 2014)

El mecanismo biela manivela, generalmente se encuentra descentrado de tal forma que el eje del cigüeñal este desplazado hacia otro plano (Figura 3). El valor del descentramiento es mínimo y está por el orden centesimal, por esta razón se descarta en el cálculo de los parámetros cinemáticos.

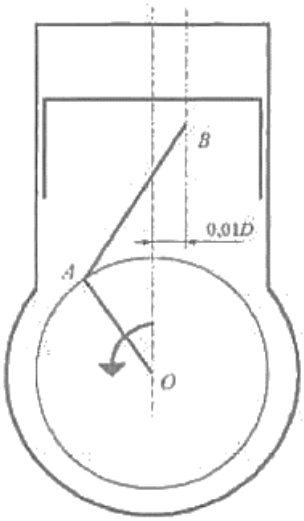

Figura 3. Descentramiento del cigüeñal. Fuente:(Payri González & Desantes Fernández, 2014)

Analizar el comportamiento del mecanismo biela - manivela permite determinar la velocidad, aceleración y posición de los diferentes puntos del mecanismo.

4.2.1 Cinemática del mecanismo biela - manivela.

En el mecanismo biela – manivela se puede establecer la ecuación que rige el movimiento angular de la biela. Todas las ecuaciones con respecto a la Figura 2.

$r\ sen\ \omega t\ = l\ sen\ \varphi$	*(1)*

De donde se deduce que:

$\cos\ \varphi = \sqrt{1 - \left(\frac{r}{l}\right)^2\ sen^2\omega t}$	*(2)*

Como el ángulo φ no se aleja de cero grados se puede decir que su coseno es positivo siempre, por lo que se obtiene la segunda derivada de la ecuación (1).

$r\left(\frac{d^2\omega t}{dt^2}\right)\cos\omega t - r\left(\frac{d\omega t}{dt}\right)^2\ sen\omega t = l\left(\frac{d^2\varphi}{dt^2}\right)\cos\varphi - l\left(\frac{d\varphi}{dt}\right)^2\ sen\varphi$	*(3)*

Sustituyendo la velocidad angular del cigüeñal (se asume constante) en la ecuación 3 se obtiene la posición angular de la biela:

$x = r\cos\omega t + l\sqrt{1 - \left(\frac{r}{l}\ sen\ \omega t\right)^2}$	*(4)*

La muñequilla, se desplaza sobre el centro O_2 y radio r, entonces la velocidad resulta de la primera derivada de la ecuación (4):

$\dot{x} = r\omega t^2\left[sen\ \omega t\ + \frac{r}{2l}\frac{sen\ 2\omega t}{\sqrt{1 - \left(\frac{r}{l}\ sen\ \omega t\right)^2}}\right]$	*(5)*

La aceleración angular se define como:

$\dot{x} = r\omega t^2\left\{\cos\omega t - \frac{r[l^2(1 - 2cos^2\omega t\,) - r^2 sen^4\omega t]}{[l^2(r\ sen\ \omega t\,)^2]^{3/2}}\right\}$	*(6)*

En la Figura 4 se observan las gráficas de posición, velocidad y aceleración del mecanismo biela manivela, descritas por las ecuaciones (4), (5) y (6).

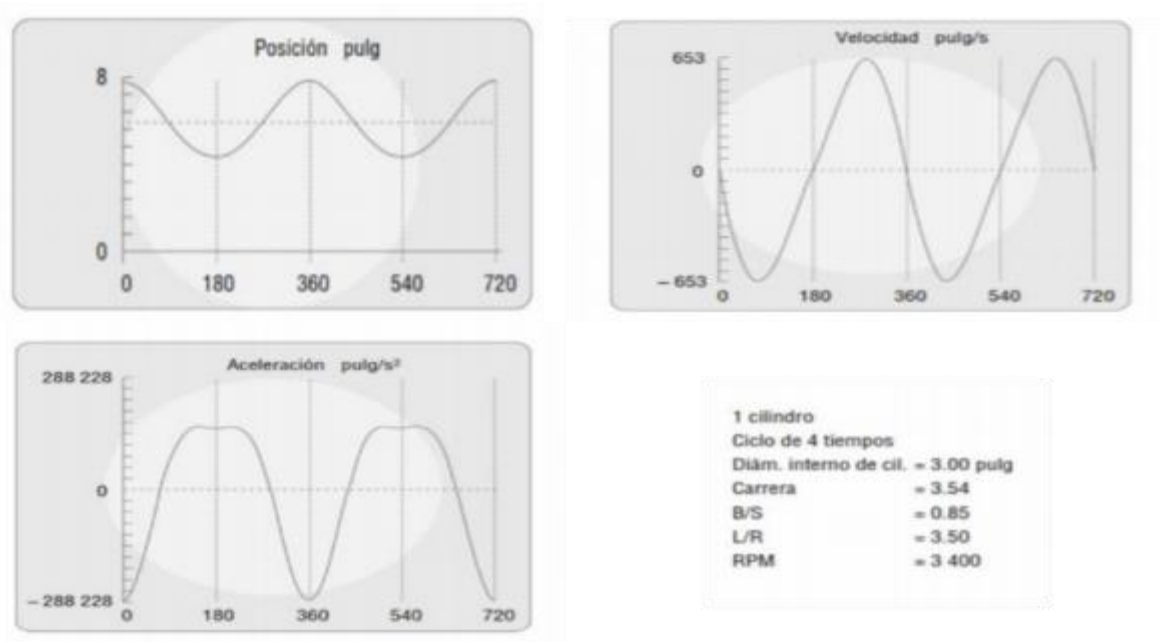

Figura 4. Posición, velocidad y aceleración del pistón. Fuente: (Norton, (Payri González & Desantes Fernández, 2014)

4.3 El Cigüeñal.

El cigüeñal es impulsado por la etapa de combustión producida en cada cilindro, lo que se convierte en giro del volante motor, y a su vez, permite el giro del cigüeñal en las etapas de escape, admisión y compresión (Figura 1). A través del cigüeñal obtienen impulso por medio de sistemas de distribución los elementos auxiliares del motor; absorbiendo parte de la energía y por ende se presenta una disminución en la potencia real del motor. (Gómez, 2018)

En la Figura 5 se observa un cigüeñal en donde se aprecian los apoyos de bancada A, que acoplan el cigüeñal a la misma a través de sombreretes, con la interposición de casquillos de antifricción. Las cabezas de biela se juntan a los codos o muñequillas B y opuestos se encuentran los contrapesos H, cuyo peso es aproximadamente el de la muñequilla. El plato C acopla el volante de inercia a través de tornillos en los taladros D. En E se evidencia un casquillo de bronce que sirve de apoyo para el eje primario de la caja de cambios sobre el que se instala el disco de embrague. En el extremo opuesto F se dispone

de un piñón anclado por una chaveta, del que se obtiene el movimiento para la distribución. (Alonso Pérez, 2000)

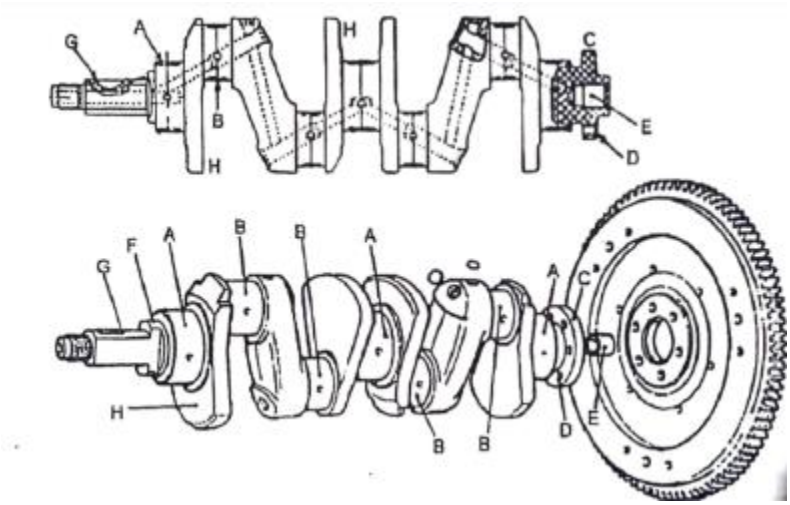

Figura 5. Componentes del cigüeñal Fuente:(Alonso Pérez, 2009)

El cigüeñal está sometido a varias cargas durante cada etapa del ciclo Otto. En la fase de explosión el pistón transmite el movimiento lineal que se ha se transformar en rotación del cigüeñal para así aprovechar el embrague como elemento de transferencia de movimiento con los demás elementos del tren motriz.

Los esfuerzos mecánicos de torsión y flexión presentes durante el trabajo del cigüeñal exigen características muy altas y precisas. Por esta razón su construcción principalmente está basada en acero tratado por cementación, estampación y templado, con aleaciones de níquel y cromo o silicio. Además se emplean tratamientos para mejorar las características mecánicas, entre los más usuales están la nitruración que se muestra como el temple superficial y cementado de las muñequillas y apoyos de bancada.(Alonso Pérez, 2009)

Algunos vehículos montan cigüeñales huecos que permiten reducir el peso y por ende se obtiene una menor inercia. Debido a que la potencia es proporcional a los esfuerzos generados, se puede disminuir el número de cojinetes, sin embargo, la rigidez del cigüeñal debe ser mayor. Con mayor potencia el cigüeñal genera más trabajo y por ende más energía que se transforma en calor, creando así la necesidad de implementar un sistema de lubricación por medio de taladros ubicados en la misma dirección de los apoyos o cojinetes. Los contrapesos ayudan a equilibrar dicho componente puesto que elimina la

energía centrífuga resultante del giro violento del cigüeñal generado por el impulso del mecanismo biela-pistón en la etapa de combustión. (Gómez, 2018).

4.3.1 Esfuerzos que actúan en el cigüeñal.

El equilibrio estático y dinámico es necesario para el correcto funcionamiento del cigüeñal en vista de que al mantener altas revoluciones existen variaciones en las que podría sufrir algún desperfecto e incluso llegar a la ruptura. Para solucionar este inconveniente los fabricantes optimizan el diseño al usar más puntos de apoyo o cojinetes, que a su vez elimina las vibraciones existentes. Las fuerzas involucradas en el funcionamiento son la compresión en las bancadas además de un par de torsión ubicado en la salida del motor.(Burgos & Freire, 2008)

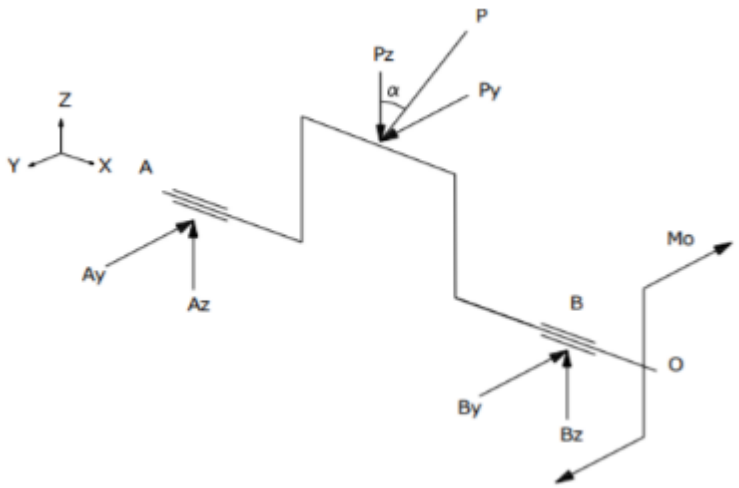

Figura 6. Fuerzas y esfuerzos actuantes en el cigüeñal. Fuente: (Burgos, B. & Freire, E, 2008).

Como se muestra en la Figura 6, existe un par de torsión (Mo) generado en la salida del cigüeñal junto al acople del volante de inercia, Se muestra además la descomposición de las fuerzas que actúan en las muñequillas (A y B). Por otra parte, en la etapa de combustión, el pistón es impulsado hacia el PMI (*punto muerto inferior*) y de esta manera desplaza una fuerza al cigüeñal (P) por mediación de la biela. La magnitud de la fuerza

que actúa sobre la cabeza del pistón está ligada al tipo del motor en el que se estudie (Gómez, 2018).

4.3.2 Velocidad angular del cigüeñal.

El motor de combustión interna alternativo por naturaleza es una maquina cíclica y por ende realiza trabajo únicamente en las etapas de combustión, de esta manera se obtiene un torque variable a la salida. La velocidad angular de giro del cigüeñal máxima se presenta cuando el motor ejerce su par máximo, en este régimen se evidencian los mayores esfuerzos sobre el cigüeñal. Cuando se llegue a este punto el par motor inicia el descenso paulatino con fluctuaciones en la salida, lo que se traduce en cambios en la velocidad de giro del cigüeñal que el volante motor debe corregir. (Figura 7)

4.3.3 Coeficiente de fluctuación de velocidad angular.

Este coeficiente determina el grado de variación de la velocidad angular del motor y es útil en la medición a régimen constante del equilibrio del motor. Según Higuera, este coeficiente debe obtener un valor aceptable en un rango de 0.02 a 0.03, a través de la ecuación 8.

$$c_f = \frac{\omega_{\max} - \omega_{\min}}{\omega_m}$$	*(7)*

Para esta ecuación se tiene: c_f coeficiente de fluctuación, $\omega_{\max}$ velocidad máxima del cigüeñal (rad/s), $\omega_{\min}$ Velocidad mínima del cigüeñal (rad/s) y $\omega_m$velocidad media del cigüeñal (rad/s).(Hurtado et al., 2014)

4.3.4 Volante de inercia y la regulación de la velocidad angular.

El volante motor o volante de inercia almacena energía mecánica al aumentar las revoluciones y por ende la velocidad angular que da como resultado la disminución de dicha velocidad y a su vez es empleado en los MCIA, en los cuales el par del motor y el par requerido son variables. (Hurtado et al., 2014)

El equilibrio dinámico del volante de inercia esta dado por la ecuación 9.

$$M = T_{in} - T_{out} - I_{\propto} = 0$$	*(8)*

Donde:

M = Torque (Nm)

T_{in}= Torque de entrada (Nm)

T_{out} = Torque de salida (Nm)

$I_{\propto}$= Inercia (Nm)

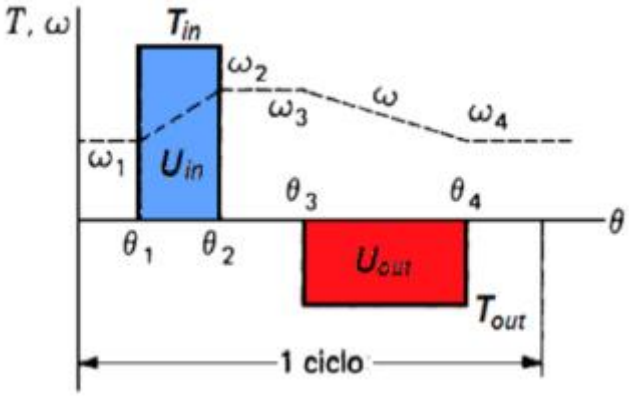

Figura 7. Torque vs Velocidad angular. Fuente:(Hurtado et al., 2014)

4.4 Sensores.

Un sensor es un dispositivo capaz de percibir una magnitud física y transformarla en una salida eléctrica, que puede ser de tipo generador o no generador. En la gestión del motor, estos componentes juegan un papel muy importante, puesto que obtienen respuesta a las condiciones de carga, temperatura, presión, régimen de giro y velocidad. (Hurtado et al., 2014)

4.4.1 Sensor de posición angular del cigüeñal y velocidad de giro.

El sensor de posición del cigüeñal *(CKP)* se encuentra ubicado a lo largo del cigüeñal o incluso en el volante motor , y de esta manera permite determinar la posición y velocidad de giro mediante el número de secuencias de la rueda fónica.(Moreno, 2015)

4.4.2 Rueda Fónica.

La rueda fónica es una pieza fundamental para la determinación de la posición del cigüeñal y por ende ayuda a la gestión electrónica del motor. Es una polea cuyo número de dientes depende del motor en el que se encuentre acoplada. La rueda dentada puede tener varios tipos de diseños: 60 menos 2, 36 menos 1, dos dientes, tres dientes, cuatro dientes, ocho dientes, 12 dientes .(Gualán & Ordoñez, 2012).

El modelo más empleado es la rueda (60 - 2), emplean este tipo de rueda las marcas Chevrolet, Volkswagen, Fiat, Renault, entre otros. La rueda con patrón 36-1 se puede encontrar en los vehículos Ford mientras que las ruedas de 2, 3, 4 dientes incorporan los vehículos de la marcha Mitsubishi y siempre están dispuestas junto al árbol de levas pues precisan trabajar con el CMP para el funcionamiento del motor. Las ruedas de 2 dientes funcionan para motores de cuatro cilindros, los de 3 dientes para motores de seis cilindros y los de 4 dientes en motores de ocho cilindros. (FuelTech, 2015)

Las ruedas de 8 y 12 dientes se emplean en motores de altas revoluciones como los acoplados a motocicletas.

El ángulo OFFSET detallado en la Figura 8 se puede calcular al contar la cantidad de dientes que transitan por el sensor posterior al paso del diente faltante hasta que el cilindro llegue a PMS *(Punto muerto superior)* y a su vez multiplicar la cantidad de dientes por 10º en ruedas de 36 - 1 o 6 º en ruedas de 60-2.(Rt, 2015)

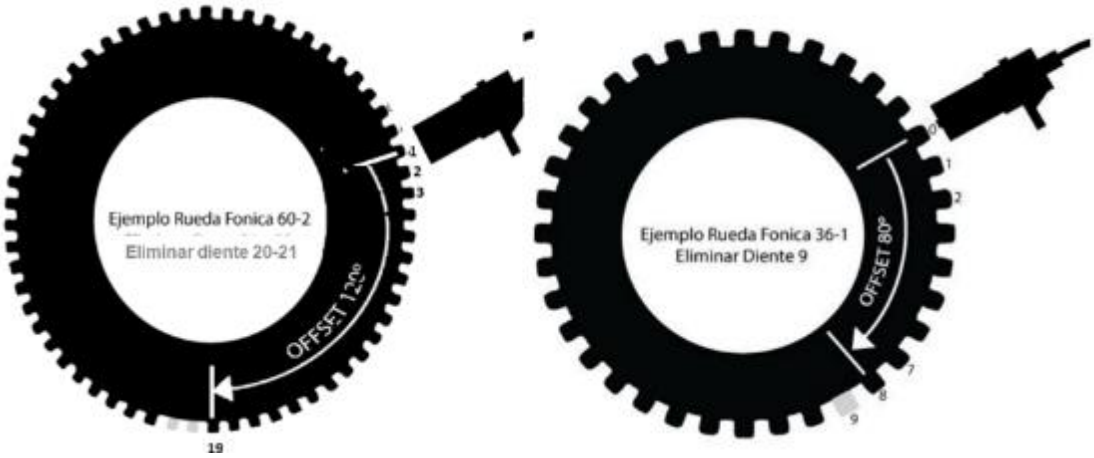

Figura 8. Disposiciones de Rueda Fónica Fuente:(Rt, 2015)00

La señal generada por el sensor se involucra directamente en el comportamiento del motor, puesto que ayuda a sincronizar la activación de varios sistemas como; las bobinas de encendido, el sistema de inyección de combustible. (Moreno, 2015). Se pueden distinguir tres tipos de sensores: Efecto Hall, Óptico y Captador inductivo.

4.4.3 Sensor CKP Tipo Hall.

Como se aprecia en la Figura 9, el efecto Hall se genera por medio de una placa metálica delgada a la que se aplica una tensión de alimentación (UA). Cuando esta placa se somete a un campo magnético B, una parte de la corriente de suministro se desvía, lo que resulta en voltaje Hall (UH). (Exxotest, 2018).

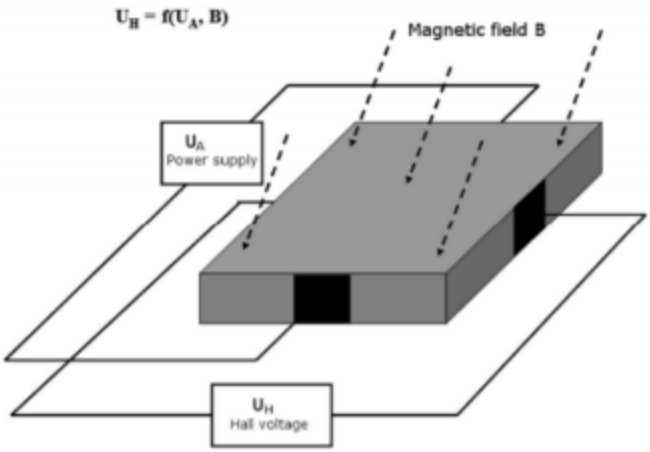

Figura 9. Efecto Hall. Fuente: (Exxotest, 2018).

Este tipo de sensor (no generador) requiere de una alimentación de voltaje además de una señal de referencia para sincronizarse y emitir una respuesta en forma de pulsos (Figura 10) hacia unidad de control electrónico del motor. Por ende, este sensor genera una salida de tipo digital.

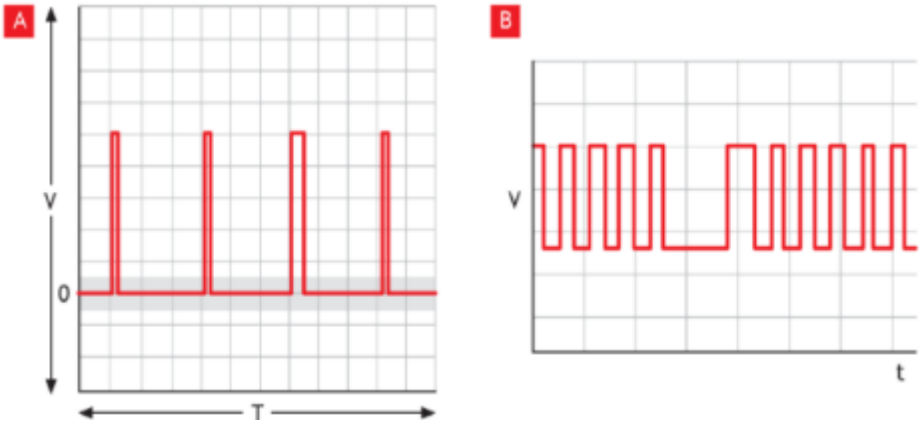

Figura 10. Señales de un sensor Tipo Hall Fuente:(Sánchez, 2011)

La Figura 10A muestra la señal cuando un diente de la rueda fónica tiene mayor tamaño, mientras que la Figura 10B señala el comportamiento del sensor cuando la rueda fónica tiene un espacio vacío en su perímetro. Este tipo de sensores se aplican en gran parte de los vehículos modernos como el Hyundai Santa Fe, Hyundai Tucson, etc.

4.4.4 Sensor CKP Tipo Óptico.

La señal de este sensor es similar a la de un sensor de efecto Hall visto en la sección anterior, su constitución está dada por una foto diodo y un led, estos generan señal cada vez que la rueda fónica deja pasar la luz hacia el foto diodo (Figura 11) y de esta manera se crea la señal de tipo digital. (Moreira, M. & Suquillo, W.& Meza, M, 2017).

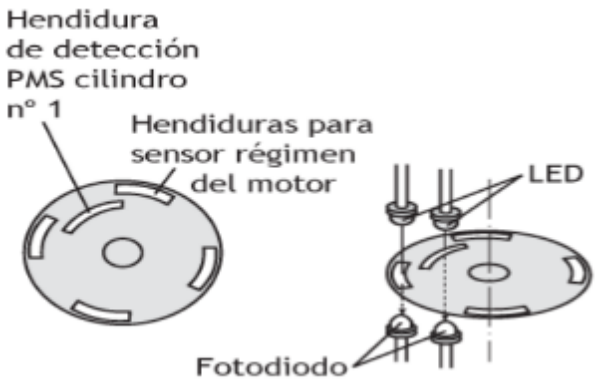

Figura 11. Sensor óptico Fuente:(Sánchez, 2011)

4.4.5 Sensor CKP Tipo inductivo.

Se hace énfasis en este tipo se sensor, en vista de que es el elemento empleado para el desarrollo de esta investigación

El sensor inductivo se utiliza para determinar la velocidad del motor y la posición del punto muerto superior (PMS). Esta información se transmite a la ECU del motor con el fin de determinar el avance de la chispa, la carga de la bobina y la tasa y cantidad de gasolina para inyectar y para controlar el ralentí. (Exxotest, 2018).

4.4.6 Funcionamiento del sensor CKP inductivo.

Este sensor es de tipo generador puesto que no depende de la fuente de alimentación. Su funcionamiento se basa en el principio de inducción electromagnética. Consta de un imán permanente, un pin de poste de hierro dulce y una bobina inductiva con dos conexiones.

El principio físico relacionado con la creación de una variación del campo magnético cuando una corona ferromagnética gira frente al sensor (Figura 12). Esta variación induce una corriente alterna (señal de onda sinusoidal) en el devanado. La frecuencia y amplitud de esta señal son proporcionales a la velocidad de rotación del cigüeñal.

Cuando las posiciones libres de la rueda fónica se colocan frente al sensor, el voltaje varia de forma descendente, hasta que el siguiente diente se alinea con el sensor y

entonces el voltaje aumenta nuevamente. De esta manera se crea la oscilación de la onda de voltaje generada por el sensor.

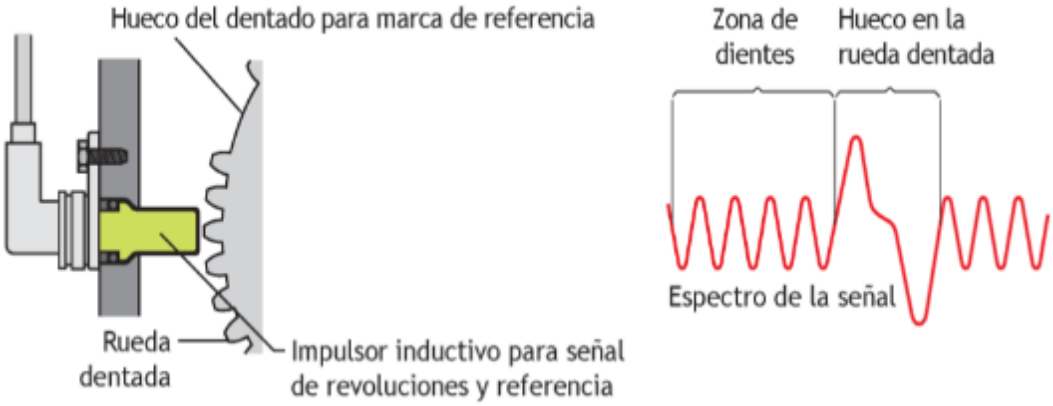

Figura 12. Funcionamiento del sensor CKP Fuente:(Sánchez, 2011)

4.4.7 Magnitudes Físicas del sensor CKP.

Los valores de resistencia del devanado del sensor por lo general oscilan en el rango de 1.050-1400 Ω, (SANGYONG, 2015). El voltaje de operación es de 5V. Además, en la Figura 13 se puede verificar la onda sinusoidal generada por el sensor. (Exxotest, 2015). En el apartado Marco metodológico se presentan las magnitudes para el sensor empleado en el proyecto.

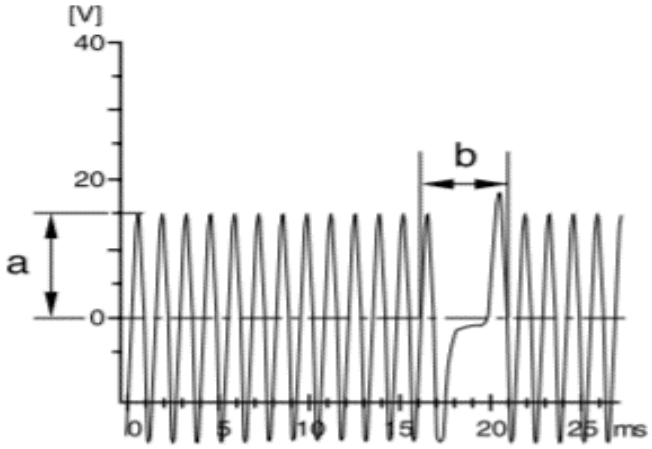

Figura 13. Señal del sensor CKP. a) Voltaje b) Identificación del doble diente. Fuente: (SANGYONG, 2015).

4.5 Métodos Estadísticos.

Los métodos estadísticos se emplean para recopilar, ordenar y procesar información con el fin de obtener diversas conclusiones que pueden ayudar a resolver problemas en la toma de decisiones y el diseño de experimentos.(Gutierrez & Vladimirovna, 2016). Para este proyecto se aplica la estadística descriptiva e inferencial.

4.5.1 Estadística descriptiva.

La estadística descriptiva se define como la rama de las matemáticas que recopila, almacena ordena y presenta un grupo de datos con el objetivo de describir de forma apropiada las características o patrones de ese conjunto de datos.

La estadística descriptiva en este proyecto trata sobre la evaluación de los parámetros: máximo, mínimo, desviación estándar, kurtosis, media, media recortada, RMS, varianza, asimetría, energía, potencia y área bajo la curva (Tabla 1); mismos que servirán para la caracterización de atributos de la señal de muestra.

Para cada ecuación en la Tabla 1 :

$N_2 - N_1$: Representa el rango de medición.

X_n : Valor de la muestra.

L_i: Límite inferior de la mediana.

$\frac{N}{2}$: Semisuma de las frecuencias absolutas.

$F_i - 1$: Frecuencia acumulada.

a_i: Amplitud de la clase.

f_i= Frecuencia absoluta de la clase modal.

f_{i-1} : Frecuencia inferior de a clase modal.

n : Número de muestras de la serie temporal.

Tabla 1 Parámetros estadísticos. Fuente:(Delgado, 2018)

Parámetro	**Ecuación**	
Área bajo la curva	$\int_a^b f(x)dx = \frac{h}{2}\left[f(a) + 2\sum_{k=1}^{n-1} f(x_n) + f(b)\right]$	*(9)*
Energía	$E = \sum_{n=N_1}^{N_2} \lvert x(n)\rvert^2$	*(10)*
Potencia	$P = \frac{1}{N_2 - N_1 + 1}\sum_{i=N_1}^{N_2} {X_n}^2$	*(11)*
Máximo	*Valor Min*	*(12)*
Factor de cresta	$FC = \frac{V_{max}}{\sqrt{\frac{{X_1}^2 + {X_2}^2 + \cdots + {X_N}^2}{n}}}$	*(13)*
RMS	$RMS = \sqrt{\frac{{X_1}^2 + {X_2}^2 + \cdots + {X_N}^2}{n}}$	*(14)*
Mínimo	*Valor Min*	*(15)*
Media	$\bar{x} = \frac{\int_a^b f(x)dx}{X_n}$	*(16)*
Desviación estándar	$\sigma = \sqrt{\sum \frac{X_n - \bar{X}}{n-1}}$	*(17)*
Varianza	$\sigma^2 = \sum \frac{(X_n - \bar{X})^2}{n-1}$	*(18)*
Asimetría	$As = \frac{\bar{x} - Mo}{\sigma}$	*(19)*
Kurtosis	$\propto^4 = \frac{\frac{1}{\pi}\sum(X_n - \bar{X})^4}{\left(\sqrt{\sum \frac{(X_n - \bar{X})^2}{n-1}}\right)^4}$	*(20)*
Mediana	$Me = L_i + \frac{\frac{N}{2} - F_i - 1_i}{f_i} * a_i$	*(21)*
Moda	$Mo = L_i + \frac{f_i - f_{i-1}}{(f_i - f_{i-1}) + (f_i - f_{i+1})} * a_i$	*(22)*

4.5.2 Estadística Inferencial.

La estadística inferencial es un conjunto de métodos que a través de una muestra puede determinar el comportamiento de un conjunto de datos. De esta manera puede determinar las conclusiones sobre un fenómeno y el grado de fiabilidad de la muestra procesada.

Dentro de la estadística inferencia se cuenta con una herramienta muy útil que permite comparar las medias de los datos obtenidos. Este método se conoce como ANOVA.

4.5.3 ANOVA (Análisis de Varianza).

El análisis de la varianza (ANOVA), es una herramienta estadística de gran utilidad para el control de procesos como el análisis de datos y el control de métodos analíticos. Los ANOVA evalúan la trascendencia de uno o más factores al contrastar las medias de la variable de respuesta en los diferentes niveles de los factores. Este método maneja dos hipótesis para el desarrollo del estudio: la hipótesis nula determina que las medias de la población en su totalidad (medias de los niveles de los factores) son iguales, de otro modo si al menos una de las medias es diferentes se maneja una hipótesis alternativa. (Minitab, 2019)

Los campos de aplicación son múltiples, pudiéndose agrupar en dos puntos principalmente: la comparación de múltiples columnas de datos y la estimación de los componentes de variación de un proceso.

En la Figura 14 se puede apreciar ellos tipos y clasificaciones del método de ANOVA.

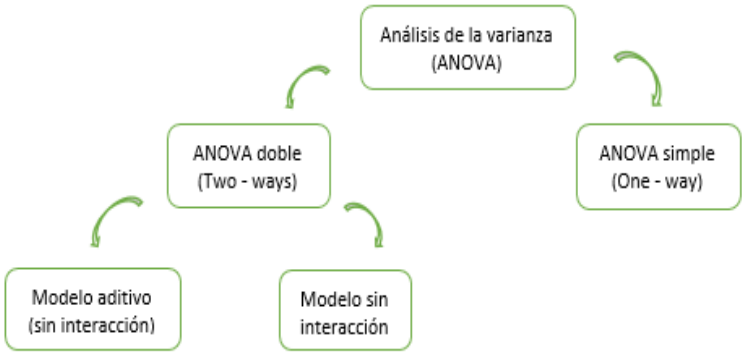

Figura 14. Esquema básico de ANOVA Fuente: Autores.

4.5.4 Análisis simple de la varianza (One-Way ANOVA).

El funcionamiento del ANOVA recae en determinar el efecto sobre alguna variable dependiente (Y), que tienen los distintos niveles de algún factor (X), Esencialmente, el diseño para el análisis simple de la varianza consiste en obtener muestras aleatorias e independientes del valor de (Y) asociado a cada uno de los distintos niveles del factor (X1, X2, Xn...). y comparar una medida de la variación entre los niveles (MS-factor) con una medida de la variación dentro de cada nivel (MS-error). Si el MS-factor es significativamente mayor que el MS-error, se concluye que las medias asociadas a diferentes niveles del factor son distintas. Esto significa que el factor influye de manera significativa sobre la variable dependiente (Y). Si, por el contrario, el MS-factor no es significativamente mayor que el MS-error, no se rechaza la hipótesis nula de que todas las medias, asociadas a diferentes niveles del factor, coinciden. (Buqué, R & Maroto, A, 1997).

En la Figura 15 se presenta un ejemplo de resultados donde la Mezcla 2 se caracteriza por tener la media de menor valor, por lo tanto, la Mezcla 4 tiene la media mayor. De esta manera se puede determinar que ninguna de las mezclas tiene similitud con respecto al factor de análisis. (Minitab, 2019)

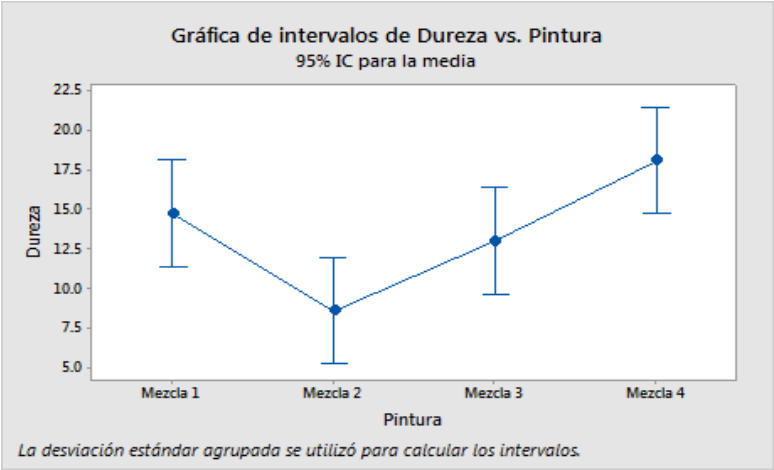

Figura 15 Ejemplo de ANOVA Fuente:(Minitab, 2019)

4.6 Redes neuronales.

Las Redes Neuronales Artificiales son estructuras de redes que interactúan con objetos o datos de experimentación real (Delgado, 2018). Denominadas de esta forma por su objetivo de imitar el procesamiento de información como lo hace el cerebro humano a través de su sistema nervioso. (Asanza & Mazón, 2018)

4.6.1 Reseña histórica de las redes neuronales.

Las redes neuronales nacen en 1936 de la mano de Alan Turing como un estudio de investigación con el fin de encontrar la manera de crear una similitud entre el ser humano y la computación. Sin embargo, no es hasta 1956 cuando Minsky, McCarthy, Rochester y Shannon, hacían la primera toma de contacto con las RNA. Al pasar de los años se ha evolucionado cada vez más hacia el desarrollo de los sistemas interconectados. Actualmente son innumerables los proyectos que se deben a las Redes Neuronales puesto que su empleo facilita el aprendizaje de nuevos eventos que ocurren en la vida real. (Asanza & Mazón, 2018).

4.6.2 Características de una RNA.

Según (Hilera González & Martínez Hernando, 1995) Las redes neuronales son entendidas como una representación informática de un sistema nervioso y es esta la característica más importante. (Tabla 2)

Tabla 2 Características de la red neuronal. Fuente: (Asanza & Mazón, 2018).

Topología de la Red	Determina la capacidad de representar la distribución de un conjunto de neuronas entre sí y en capas. La topología de la red se basa en el problema que se pretende resolver.
Regla de Aprendizaje	Una red neuronal es un sistema que tiene la capacidad de aprender a través de un entrenamiento previo.
Tipo de entrenamiento	Existen dos tipos de adiestramiento de una RNA, en la fase de aprendizaje la red se prepara para que los pesos se adecuen a la red. Y por último la red ya pasa a ser funcional con valores reales.

4.6.3 Estructura de una RNA.

La estructura de una red neuronal está inspirada en la biología, pues imita el procesamiento del cerebro humano a través de las neuronas.

Una neurona artificial (Figura 16) es un procesador con entradas variables (X_n) que se unen dentro del sistema neuronal por medio de una suma simple para su posterior cambio de acuerdo con la función de transferencia requerida y que finalmente envía a la salida (Y_n) del procesador. La salida puede crear una conexión ponderada con otras neuronas dependiendo de la sinapsis de la conexión. (Basogain, 2019)

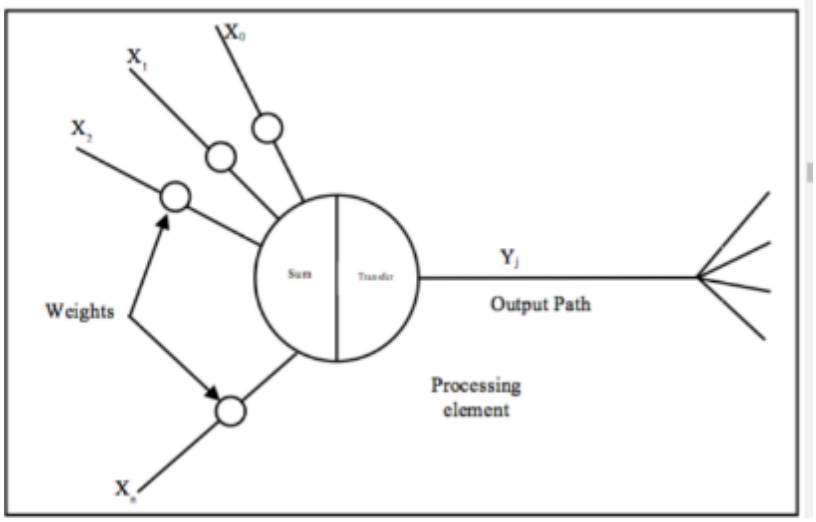

Figura 16. Estructura (Biológica) de una RNA Fuente: (Asanza & Mazón, 2018).

Entonces la red neuronal es un conjunto de procesadores conectados entre sí, principalmente los procesadores están ordenados por secuencias de capas adyacentes consecutivas.

Como se muestra en la Figura 17, existen dos capas de conexiones. La capa de entrada de datos (buffer) y la capa de salida, las demás capas se definen como ocultas.

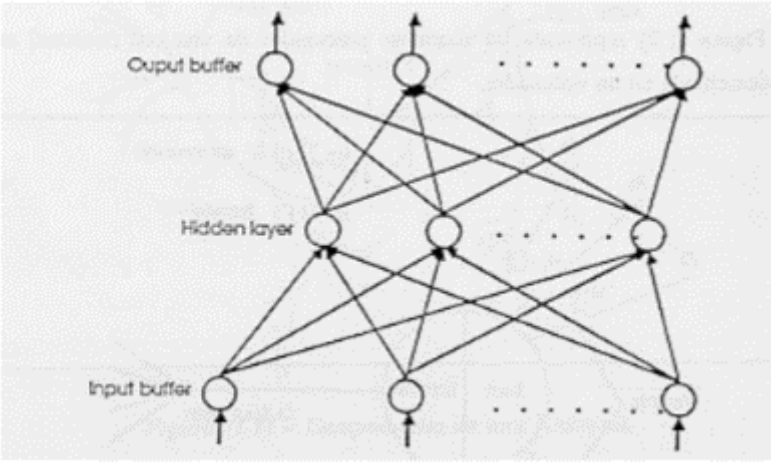

Figura 17. Estructura de una RNA Fuente:(Basogain, 2019)

4.6.4 Tipos de RNA.

Existes varios tipos de redes neuronales de acuerdo con su aplicación, que se indican en la Tabla 3:

Tabla 3 Tipos de redes neuronales. Fuente:(Basogain, 2019)

Red	**Diseñador**	**Año**	**Tipo**	**Características**
Red recurrente	McCulloch y Walter Pittsk	1943	Clasificación	Series temporales
Perceptron Networks	Rosenblatt 1950	1950	Predicción	Primer modelo de sistema Neuronal Artificial.
Adaline Y Madaline	Bernard Widrow	1960	Predicción	Técnicas de Adaptación para el reconocimiento de patrones
Directed Random Search (DRS)	Maytas y Solis	1965-81	Clasificación	Técnica de valores Random en el mecanismo de Ajuste de Pesos.
Adaptive Resonance Theory Networks (ART)	Carpenter, Grossberg	1960-86	Conceptualización	Reconocimiento de patrones y modelo del Sistema Neuronal Concepto de resonancia adaptativa.
Back-Propagation	Rumelhart y Parker	1985	Calificación	Solución a las limitaciones de su red procesadora Perceptrón
The Boltzmann Machine	Ackley, Hinton y Sejnowski	1985	Asociacion	Similitud don la red Hopfield
Bi-Directional Associative Memory (BAM)	Bart Kosko	1987	Asociacion	Inspirada en la red ART
Cascade-Correlation-Network	Fahhman y Lebiere	1990	Asociación	adición de nuevas capas ocultas

Digital Neural Network Architeture (DNNA)	Neural Semiconductor Inc.	1990	Predicción	Implementación de Hardware de la función Sigmoid.
Hopfield Networks	Hopfield	1982	Optimización	Concepto de la red en términos de energía.
Probabilistic Neural Network (PNN)	Spetcht	1988	Asociación	Clasificación de Patrones utilizando métodos estadísticos.
Recirculation Networks	Hinton y McClelland	1988	Filtrado	Alternativa a la red Backpropagation

4.6.5 Funcionamiento de una RNA.

Los valores ingresados se convierten en salida por medio de una conexión en paralelo de las neuronas. El valor de salida es resultado del análisis matemático de propagación en base a una función que realiza el producto de pesos de cada conexión y los suma a todas las variables de entrada además de un valor de vía. La segunda función para analizar es la transferencia que actúa sobe la función de propagación y pueden ser del tipo hiperbólica, lineal, radial o sigmoidea. Al final se obtiene una función que resulta de la suma de todas las entradas.

4.6.6 Entrenamiento.

El entrenamiento es el proceso de configuración de una red para que las entradas generen una respuesta de salida mediante el afianzamiento de las conexiones.

Esto se logra al definir los pesos que se conocen o al aplicar una retroalimentación para la obtención de patrones de aprendizaje adecuados.

El aprendizaje puede dividirse en: supervisado que espera una salida luego de haber obtenido una entrada específica y no supervisado mismo que busca las características estadísticas entre agrupamientos de patrones.(Ponce, 2010)

4.6.7 Sobreaprendizaje.

Este caso se presenta al tener una confusión en la etapa de procesamiento de datos, ello debido a la intrusión de elementos externos en la toma se señales tales como ruido o cortes. El sobreaprendizaje resulta en un problema puesto que una red puede adaptarse a un conjunto de datos de manera perfecta (Figura 18), pero puede presentar inconvenientes al leer nuevos valores, por esta razón se debe evitar que la red presente esta condición.

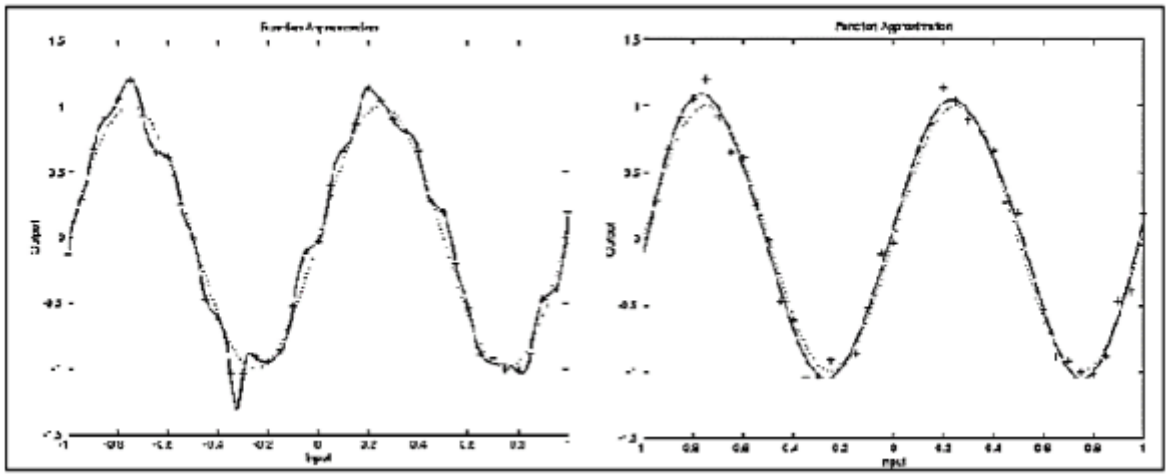

Figura 18. Función seno con sobreaprendizaje y sin sobreaprendizaje Fuente: Delgado, E. (2018).

4.6.8 Simulación.

Comparar los datos en entrada con los valores obtenidos a la salida es el proceso de simulación de una red que ya se ha entrenado previamente. Los datos para comparar pueden ser los empleados durante el entrenamiento o un conjunto nuevo. De esta manera se puede comprobar si dichos datos son parecidos, lo que permitirá una validación del estudio. Esta validación cruzada corrobora además la posible existencia de un Sobreanprendizaje de la red. Figura 19

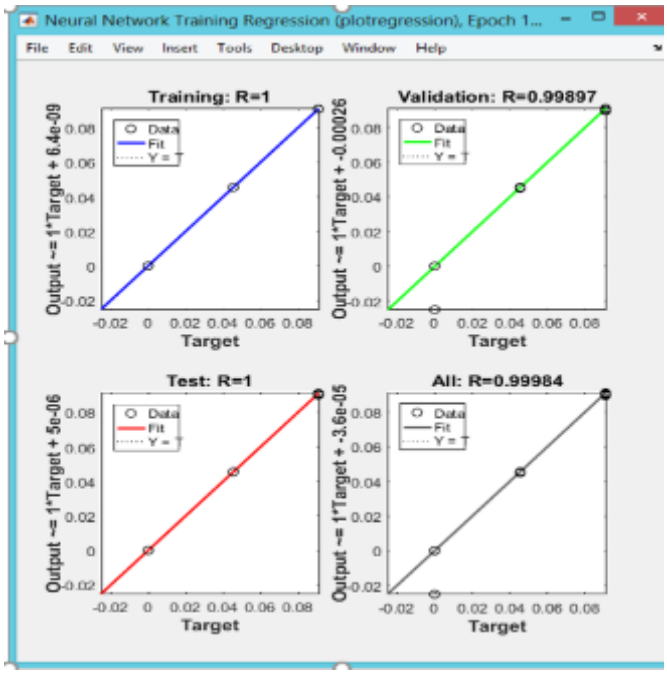

Figura 19. Simulación de la red. Fuente: Garzón & Urdiales (2017)

5. ESTADO DEL ARTE DEL DIAGNOSTICO DE AVERÍAS BASADAS EN REDES NEURONALES.

En esta sección se describe de manera sintetizada algunos de los proyectos que se han desarrollado sobre sistemas de diagnóstico mediante metodologías de adquisición de señales en motores de combustión interna.

Para el año 1995 Isermann afirma que existen métodos para la detección de fallas fundamentados en datos de las señales adquiridas y a través de modelos matemáticos de los sistemas. De estos se mencionan tres: estimación de parámetros, estimación de estados y ecuaciones de paridad.

En el año 1997 Isermann y Ballé, mencionaron que se puede emplear esquemas FDD *(Fault Detection and Diagnosis)* basado en modelos de señales cuando únicamente se cuenta con señales medidas de salida y proponen los filtros pasa bandas, análisis de la Transformada de Fourier y estimación máxima de la entropía. Por otra parte, si la sintomatología cambia drásticamente para ciertas averías, indican el análisis por distancia geométrica, métodos probabilísticos y redes neuronales artificiales son una forma de determinar el tipo de fallo.

La investigación presentada por Chandroth, Sharkey y Sharkey en 1999 muestra el diseño de un FDD basado en señales provenientes de las vibraciones del motor y la presión de los cilindros. A través del entrenamiento de dos RNA de Retropropagación *(BP)*, una para cada parámetro. La vibración es medida desde la parte superior del motor obteniendo una mayor relación con la presión del cilindro.

El trabajo desarrollado por Namburu en 1999, integró un sistema de reconocimiento de patrones a partir del agrupamiento de datos característicos por medio de una RNA. Las fallas provocadas para este experimento fueron tres en sensores y dos fallas físicas.

La experimentación de 2009 por Wu y Liu emplea señales acústicas del motor con un tratamiento pasabanda de frecuencia variable. Consecuentemente se emplea una red neuronal que analiza los datos probabilísticos de la señal para determinar el tipo de fallo.

El sensor de oxígeno bajo efecto del catalizador en condiciones supervisadas fue analizado por Hua et.al en el año 2011. El resultado fue la caracterización de la forma de

onda del sensor dependiendo del fallo mediante una RNA y así la determinación de la avería.

Jafari, Mehdigholi, y Behzad en 2014, fundamentaron su investigación en el análisis de señales acústicas del motor cuando este presenta averías en las válvulas. Se aplican métodos de extracción de patrones a través de una red neuronal del tipo BP *(retropropagación)* que analiza valores estadísticos como: RMS, orden, energía, amplitud, máximo y promedio.

En 2014 Hurtado, Morocho y Pinguil diseñaron un sistema que determina el estado porcentual del rendimiento de los cilindros, mediante el análisis de la señal de sensor de posición del cigüeñal de un motor Diesel.

Ahmed para 2015 presentó una investigación de modelos de señales a partir de los datos de vibración en el sensor de inclinación del cigüeñal, por medio de RNA. El autor comparó entre el método de BP, el método de Levenberg-Marquardt (LM), el método Quasi-Newton (QN), el filtro extendido de Kalman (EKF) y el filtro estructurado de variable suave (SVSF) y concluye que el método de clasificación por redes neuronales a partir de modos deslizantes entrega un mejor desempeño que todas las demás con las que fue comparado.

Mas tarde, León y Maldonado en el 2018 presentaron el diseño de una red neuronal que procesa los datos estadísticos obtenidos de la señal de los sensores MAP *(Manifold Air Pressure)* y CMP *(Camshat Position Sensor).* De esta manera se logró identificar los diferentes tipos de fallos ocasionales para su experimentación.

En 2020 Arias presenta un software para la detección y diagnóstico de fallas en rodamientos de equipos rotativos, a través de una Red Neuronal Convolucional sobre un Escalograma de Transformada Wavelet Continua y Árbol de Decisión, que permite determinar fallos en diferentes condiciones de operación.

6. MARCO METODOLÓGICO.

La aplicación del método experimental con técnicas no intrusivas permite realizar un proceso ordenado y lógico, con guía en una respectiva secuencia de muestreo. Los métodos empleados para el desarrollo de la investigación se listan a continuación:

- Instrumento de experimentación.
- Variables no controlables durante el experimento.
- Fallas provocadas a la unidad experimental.
- Recolección de datos.
- Crear un algoritmo para la obtención de atributos.
- Diseñar un algoritmo para el post - procesamiento de la señal.
- Implementar el algoritmo de diagnóstico para la detección de fallas mecánicas.

6.1 Instrumento de experimentación.

El instrumento empleado para el desarrollo de la investigación es un motor Daewoo GM F16D3A, acoplado al vehículo Chevrolet Aveo activo 1.6, el cual será intervenido para la adquisición de datos.

Las características del motor se detallan en laTabla 4.

Tabla 4 Especificaciones del motor Fuente:(GMSA Chevrolet, 2011)

Parámetros	**Descripción**	**Ilustración**
Tipo de motor	4CIL DOHC 16V	
Número de cilindros	4	
Alimentación	MPFI	
Cilindrada	1598 cc	
Potencia (HP @ RPM)	103 @ 6000	
Torque (libra – pie @ RPM)	14.7 @ 3600	
Compresión	9.5: 1	
Diámetro por carrera (mm)	79 x 81.5	
Transmisión	Manual	
Combustible	Gasolina	

Las condiciones de funcionamiento del motor son muy importantes para la experimentación, puesto que de ello depende la validez de las muestras obtenidas para su posterior procesamiento.

De acuerdo con el planteamiento anterior, se verifica los componentes del motor para un estado de funcionamiento correcto, listados en la Tabla 5.

Tabla 5 Check List de componente para motor en buen estado. Fuente: Autores

PARÁMETROS	**ESTADO**	**OBSERVACIÓN**	**ILUSTRACIÓN DEL COMPONENTE**
Filtro de aire.	OK	Filtro nuevo para las pruebas	
Bujía 1	OK	Holgura de 1mm	
Bujía 2			
Bujía 3			
Bujía 4			
Filtro de combustible.	OK	Filtro nuevo para las pruebas	

Bomba de combustible.	OK	Presión recomendada 55PSI	
Verificación de la temperatura del motor en ralentí.	OK	90-97 C	
Verificación de fluidos del motor.	OK		
Compresión cilindro 1.	OK	Compresión de 120 psi	
Compresión cilindro 2	OK	120 psi	

Compresión cilindro 3	OK	110 psi	
Compresión cilindro 4	OK	120 psi	
Voltaje de la batería y nivel del electrolito.	OK	Voltaje recomendado 12.7V	
Revisión electrónica mediante el Scanner Automotriz (Detección de cogidos de fallos).	OK	Sensor de detonación, airbag explosionado.	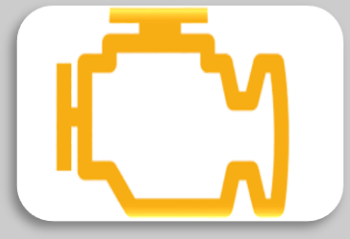

6.1.1 Sensor CKP para análisis.

Para este trabajo se emplea la señal del sensor del sensor CKP (Crankshaft Position Sensor) que se detalla en la Figura 18.

Figura 20. Sensor CKP Fuente: (GMSA Chevrolet, 2011)

6.1.2 Características del sensor CKP.

En la Tabla 6 se muestran los valores de las magnitudes físicas del sensor aplicado al motor Daewoo, además se ilustra la medición del sensor del vehículo (Tabla 7)

Tabla 6 Características del sensor CKP Fuente: (GMSA Chevrolet, 2011)

Modelo	GM 96253542
Tipo de sensor	Inductivo
Voltaje en vacío	5V
Resistencia	550ohm

Tabla 7. Magnitudes del sensor CKP del experimento. Fuete: Autores.

Voltaje en funcionamiento.	
Resistencia medida	

6.1.3 Condiciones de funcionamiento aplicadas a la unidad experimental.

En base a la literatura y modelos experimentales desarrollados en las investigaciones anteriores de (León & Maldonado, 2018) y (Delgado, 2018), se seleccionan para el análisis los fallos que han demostrado su influencia de manera importante dentro del funcionamiento del motor (Tabla 8)

Tabla 8 Descripción de Fallas provocadas. Fuente: Autores

NUMERO DE FALLA	**DESCRIPCIÓN**	**NIVEL**
1	Falla del cilindro uno	Calibración de bujía cero.
2	Falla del cilindro dos	Calibración de bujía cero.
3	Falla del cilindro tres	Calibración de bujía cero.
4	Falla del cilindro cuatro	Calibración de bujía cero.
5	Presión de combustible	10 PSI.
6	Presión de combustible	21.5 PSI.
7	Presión de combustible	33 PSI.
8	Presión de combustible	45.5 PSI
9	Falla de filtro de aire tapado	50%.
10	Falla de filtro de aire tapado	75%.
11	Falla de la válvula IAC	Desconexión
12	Falla del sensor IAT	Desconexión
13	Falla del sensor O2	Desconexión
14	Falla del sensor TP	Desconexión

6.1.4 Desarrollo de las averías a supervisadas en el motor Daewoo GM F16D3A.

Con los fallos identificados se procede a generar las condiciones pertinentes para cada una de las pruebas que permitan analizar el comportamiento del cigüeñal a través de su velocidad angular, de tal manera que los datos obtenidos se emplean para la construcción de una matriz de datos.

6.1.5 Averías generadas en los cilindros al calibrar las bujías con una holgura de cero.

Al calibrar una holgura de 0mm en cada una de las bujías se genera una falla en el encendido y por ende una carencia de combustión lo que provoca inestabilidad en el motor y genera una desaceleración del cigüeñal en la etapa de combustión del cilindro en falla. Este proceso se realiza independientemente para cada uno de los cilindros, es decir, se coloca la bujía del primer cilindro con la calibración en cero, mientras que los tres restantes mantienen la holgura recomendada de 1mm.

Este proceso se repite para cada uno de los cilindros cuya finalidad es tener siempre un cilindro en fallo. En la Figura 21 se muestra la calibración para cada bujía.

Figura 21. Calibración de bujías Fuente: Autores

6.1.6 Avería generada en la presión de combustible

Cuando se modifica la presión proveniente de la bomba (10psi, 21.5psi, 33psi. 44.5psi) los inyectores no tienen la capacidad de pulverizar el combustible correctamente, de esta manera la quema del carburante en el cilindro no será eficaz lo que se traduce en una desaceleración significativa del cigüeñal.

A través de un medidor de presión se procede a la comprobación de la presión nominal de combustible (56 psi) cuando el motor se encuentra en buenas condiciones y en ralentí. Para provocar el fallo y garantizar una medición efectiva, se emplea un manómetro que permita simular alteraciones en el sistema de alimentación (Figura 22).

Conectado dicho instrumento, se procede a liberar la presión de combustible; a continuación, se desconecta el acople de la manguera de la entrada al riel de inyección, de tal manera que la línea de combustible sea interrumpida por la herramienta de medición y que la cañería con la válvula de estrangulación se encargue de regular la presión.

Es de suma importancia colocar la cañería de desfogue del medidor hacia un depósito auxiliar con la finalidad de retener el combustible que se ha de desechar por la cañería de desfogue (León & Maldonado, 2018).

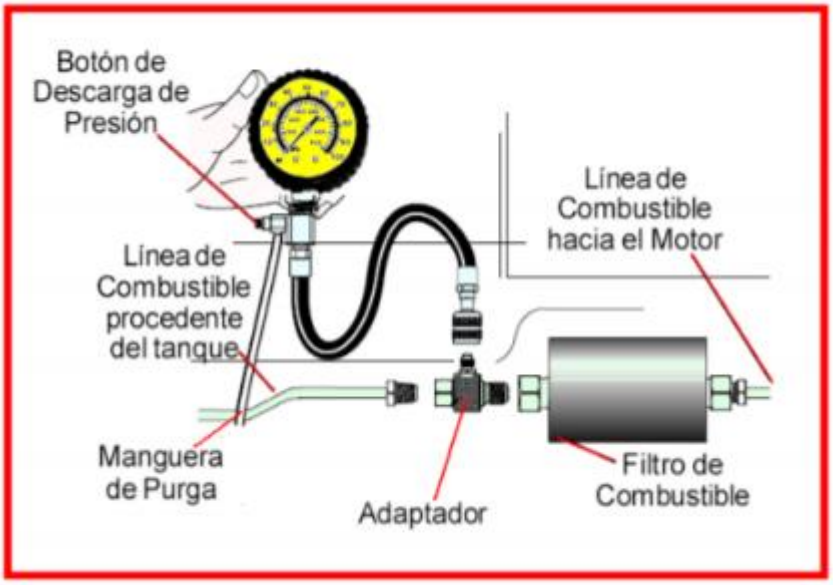

Figura 22. Diagramas del sistema de regulación de presión de combustible, Fuente: (Universida Politécnica Salesiana, 2019)

En la Tabla 9 se muestran las presiones determinadas para cada fallo.

Tabla 9 Presiones de combustibles para cada fallo. Fuente: Autores

Falla número	Valor obtenido	Ilustración
1	10 psi	

2	21.5 psi	
3	33 psi	
4	45.5 psi	
5	56 psi	

.

6.1.7 Avería generada al filtro de aire.

Al impedir el ingreso normal del flujo de aire, se modifica el valor de lambda y no se puede hablar de una mezcla estequiométrica, sin embargo, la ECU adapta el ingreso de combustible para que el motor funcione de acuerdo con las nueva condiciones. Esta avería presenta una disminución de las revoluciones del motor que afecta además a la aceleración del cigüeñal al tener una combustión no adecuada.

El filtro de aire es el encargado de depurar las impurezas que se encuentran en el aire-ambiente con la finalidad de que el motor aspire aire limpio. La capacidad filtrante de estos elementos es de 1 a 3 micras. El tiempo útil de un motor está ligado estrictamente a la capacidad del filtro, puesto que cualquier impureza tiene propiedades abrasivas en el motor lo que puede desencadenar en una reducción importante en su estructura interna (Carrera & Paredez, 2020).

Con el objetivo de conseguir las señales del sensor CKP y analizar el comportamiento del cigüeñal se limita la capacidad del filtro al 50% y al 75% del área total. (Tabla 10)

Tabla 10. Falla en filtro de aire. Fuente: Autores.

Descripción	**Ilustración**
Filtro tapado al 50%	
Filtro tapado al 75%	

6.1.8 Averías en componentes electrónicos.

Existen tres diferentes tipos de fallas conocidas en los sensores como ruido en la señal, falla gradual y fallo total. Una falla gradual se evidencia cuando el sensor ha trabajado de manera excesiva y por ende los componentes electrónicos o mecánicos presentan

desgaste. La falla por ruido inserta una variación en la señal de salida, debido a intrusiones de señales externas o derivaciones a masa. El fallo total es el resultado de la falla gradual.

Para generar el fallo a estudiar se toma la investigación de (Vidal & Moreira, 2014), como referencia para determinar los elementos electrónicos (sensores) más importantes dentro del diagnóstico. Para esto se simuló una falla total mediante la desconexión de cada uno de los sensores mencionados en la Tabla 11.

Cuando un sensor tiene inconvenientes el motor presenta un funcionamiento inadecuado, esto debido a que la computadora compensa de cierta manera la carencia de alguna variable para cada condición. De esta manera se genera una inestabilidad que se traduce en alteración de la velocidad angular del cigüeñal. Para cada una de las averías propuestas se espera que el MCIA presente este problema.

Tabla 11 Falla de Sensores Fuente: Autores.

Sensor	**Descripción**	**Desconexión**
Avería del sensor IAT		
Avería del sensor O2		
Avería del sensor TPS		

Avería en la válvula IAC		

6.1.9 Avería en el Sensor IAT.

El sensor IAT detecta la temperatura del aire de admisión, y permite a la unidad de control del motor (ECU) manejar el tiempo de inyección por medio de la densidad del aire que ingresa a la cámara de combustión.

Cuando este sensor presenta averías, existe un aumento de emisiones de CO y HC así como un elevado consumo de combustible, arranque en frio problemático y perdida de aceleración del motor. (*SENSOR IAT | Guía 2020 | Funcionamiento y fallas*, 2019)

6.1.10 Avería en el sensor de oxígeno.

El sensor O2 determina si la mezcla aire - combustible es estequiométrica a través del análisis de la cantidad de oxígeno presente en los gases de escape. Las averías que se presentan cuando este elemento no se encuentra en buen estado son: el consumo excesivo de combustible o en otro caso la disminución de potencia por falta de carburante en la cámara de combustible. (*SENSOR IAT | Guía 2020 | Funcionamiento y fallas*, 2019)

6.1.11 Avería en el sensor TPS

El TPS identifica el ángulo de apertura de la mariposa de aceleración para calcular los requerimientos que tiene el motor en cuanto a cantidad de combustible y aire. Si este sensor se encuentra averiado, el motor puede detenerse repentinamente o funcionar con fuertes vibraciones, debido a que se generan ráfagas intermitentes de combustible hacia los inyectores. La computadora interpreta que el vehículo se desplaza y provoca un ralentí inestable.(*SENSOR TPS | Guía 2020 | Funcionamiento y fallas*, 2019)

6.1.12 Avería en la Válvula IAC.

Cuando la válvula IAC *(Intake Air Control)* tiene inconvenientes en su funcionamiento, el motor presenta una aceleración excesiva en el régimen de ralentí, puesto que el aire de ingreso a la cámara de combustión no se puede controlar. El otro caso se presenta cuando el motor pierde rápidamente revoluciones y tiende a apagarse.

6.2 Factores no controlados del experimento.

Los factores que no se pueden controlar durante el experimento, se deben principalmente a fenómenos ambientales. A continuación, se mencionan dichos parámetros.

- La variación de temperatura del motor oscila en un rango de 90ºC y 97ºC, esto debido al funcionamiento del sistema de refrigeración. Adicionalmente el electroventilador del vehículo actúa de acuerdo a intervalos, donde el consumo de combustible y las rpm del motor aumentan con el objetivo de compensar la carga del ventilador. Para la toma de datos se tomaron en cuenta aquellos intervalos en los que el electroventilador se encuentra en reposo y de esta manera se evita un error en la muestra.
- De acuerdo con la ubicación geográfica, en la ciudad de Cuenca la presión atmosférica tiene un valor de 73 o 74 atm; y la humedad relativa se encuentra en los 62.87%, lo cual constituye un factor que afecta la calidad del combustible y de manera directa influye en el rendimiento del motor. (Delgado, 2018)

6.3 Recolección de datos.

En esta etapa se emplea un sistema para la adquisición de datos. El cual se desarrolla en la plataforma National Intruments, a través de su software Labview y la tarjeta NI Daq-USB 6212.

6.3.1 Software LabVIEW.

LabVIEW es un software de ingeniería de que permite realizar sistemas para aplicaciones complejas que demandan etapas de pruebas, medidas y control a través del rápido acople de hardware e información de datos. Ofrece un entorno de programación gráfica (Figura 23) que facilita el desarrollo de algoritmos mediante la visualización cada aspecto de la aplicación, incluyendo configuración del hardware, datos de medidas y depuración. (National Instruments, 2021a)

Figura 23. Interfaz de programación de LabVIEW Fuente: Autores

6.3.2 Hardware NI Daq USB-6212.

El USB-6212 es un dispositivo DAQ multifunción con entradas analógicas, digitales, salida digital y dos contadores de 32 bits. El dispositivo proporciona un amplificador integrado diseñado para configuraciones rápidas a altas velocidades de muestreo.

Este dispositivo posee la capacidad de trabajar con registros de datos portátil, monitoreo de campo, OEM embebidas, adquisición de datos del vehículo y aplicación académica. El USB-6212 tiene una cubierta mecánica ligera y es energizado por bus para ofrecer fácil portabilidad. El controlador NI-DAQmx y la utilidad de configuración incluidos simplifican la configuración y las medidas.(National Instruments, 2021b)

Definidas las herramientas a emplear en la toma de datos la siguiente etapa es la creación de un algoritmo de adquisición de datos.

6.3.3 Conexión física de los instrumentos.

La conexión de los instrumentos se realiza como se muestra en la Figura 24. La señal del sensor CKP, por medio de una conexión en paralelo es llevada hacia la entrada analógica Ai1 de la tarjeta DAQ 6212 que a su vez se acopla a la computadora mediante un cable de datos USB estándar tipo B.

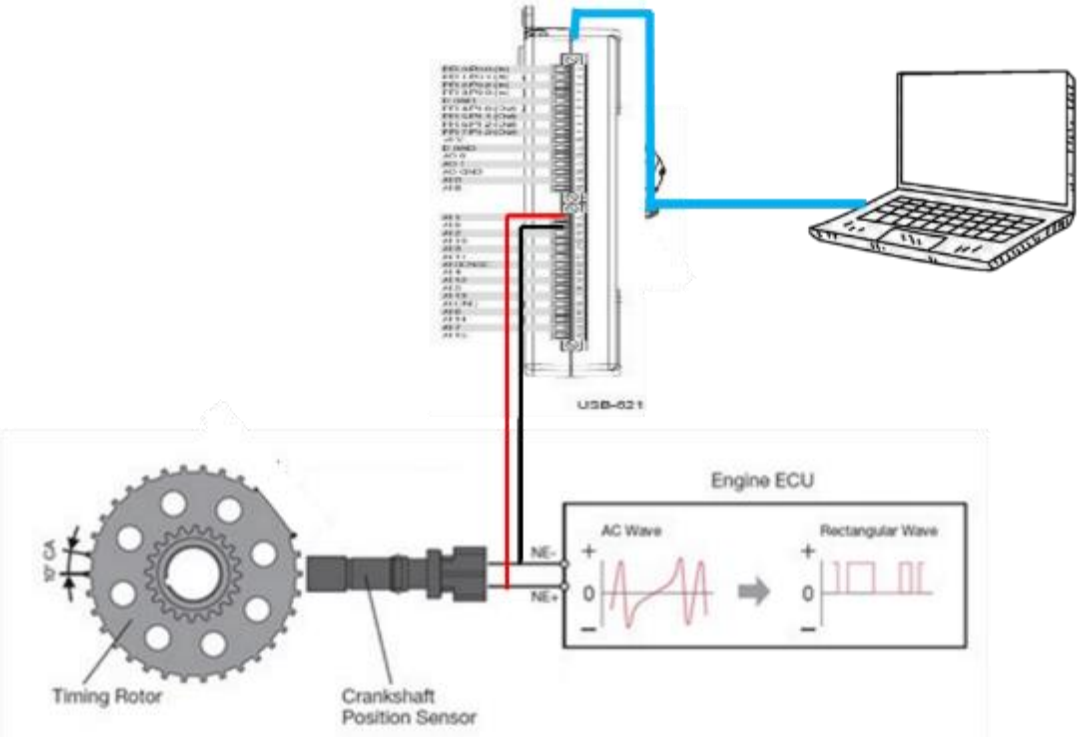

Figura 24. Conexión de los instrumentos. Fuente: Autores.

6.3.4 Configuración de la tarjeta.

La tarjeta Daq 6212 necesita de un controlador (NI DAQmx) proporcionado por el fabricante. Si la instalación ha sido correcta, se desplegará la ventana del asistente de la tarjeta como se muestra en la Figura 25.

Figura 25. Asistente de la tarjeta NI DAQ 6212 Fuente: Autores.

Cuando la tarjeta ya está sincronizada con el ordenador, se procede a calibrar los aspectos necesarios para la prueba.

Tal como se muestra en la Figura 26, dentro del entorno de programación (Block Diagram), al ingresar a la dirección: Express/ Input se encuentra el asistente de la tarjeta (DAQ Assist).

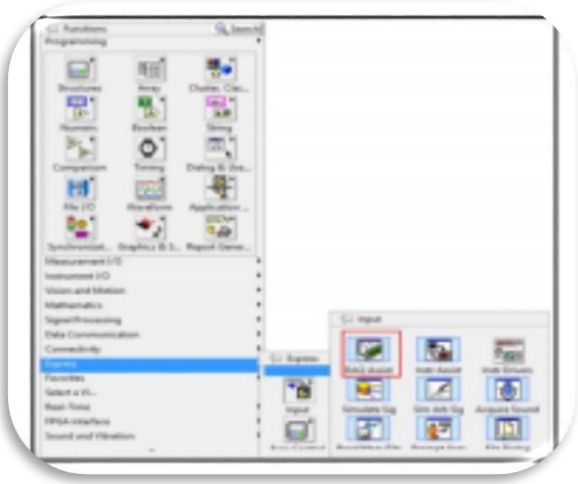

Figura 26. Daq Assist en LabVIEW Fuente: Autores.

Al tener el Daq Assist en el Block diagram, a través de un doble clic sobre el icono, se ingresa a la configuración de las características para la prueba deseada.

Para este trabajo se programa la entrada analógica AI1 como puerto de adquisición de la señal que en la configuración se ha de seleccionar como voltaje. Por último, se establece

una entrada diferencial con frecuencia de muestro de 10KH y 5K en base al criterio de Nyquist, el cual indica que la toma de datos debe realizarse al doble de la frecuencia máxima de la señal, es decir si el motor trabaja a 850 rpm en ralentí, la frecuencia de giro corresponde a 14.16 Hz, por lo tanto, la frecuencia de muestreo empleada cumple fielmente con este criterio (Figura 27).

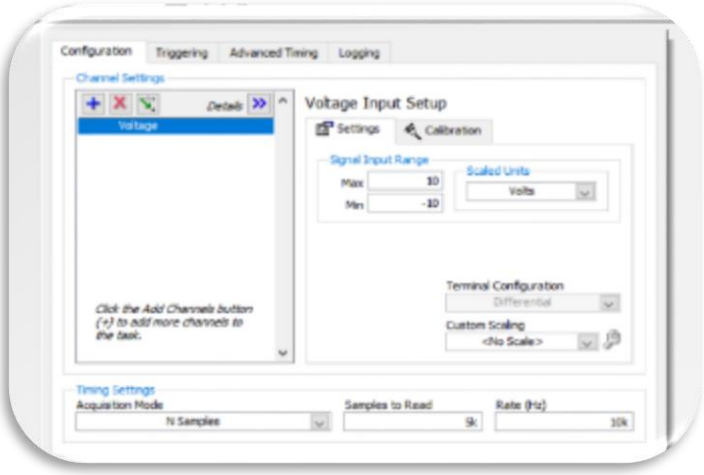

Figura 27. Configuración de características para la prueba. Fuente: Autores

6.4 Protocolo de adquisición de datos.

La toma de muestras debe ser fiable, puesto que de este aspecto dependen los resultados que se puedan obtener. El protocolo de muestreo permite corroborar que cada toma será siempre igual. Los parámetros por revisar se detallan a continuación:

- Preparar las herramientas y equipos requeridos.
- Verificar los niveles de fluidos del motor
- Instrumentar el motor.
- Corroborar el funcionamiento de los componentes eléctricos.
- Puesta en marcha del motor.
- Llevar al motor a la temperatura normal de funcionamiento.
- Obtener una muestra de prueba para determinar la perfecta instalación de los instrumentos.
- Apagar el motor.
- Evidenciar que los fluidos se encuentren su nivel.
- Provocar la avería previamente seleccionada.
- Verificar la instrumentación.

- Encender el motor.
- Estabilizar el motor a ralentí.
- Descartar las muestras si el electroventilador se encuentra activado.
- Realizar la adquisición de la señal por un intervalo de 12 segundos.
- Guardar las muestras obtenidas.
- Apagar el motor.

6.5 Algoritmo para la adquisición de datos.

La adquisición de señales es posible gracias a un algoritmo que obtiene y almacena los valores de la señal temporal.

Dicho algoritmo se muestra en la Figura 28. La señal del sensor CKP *(Crankshaft position sensor)* que corresponde por la frecuencia de muestreo alrededor de 5000 datos, es adquirida por un periodo de 12 segundos continuos, en los cuales se puede apreciar en tiempo real la onda proveniente del sensor (Figura 29). Transcurrido este tiempo los datos de la señal proveniente del sensor se almacenan en una columna del archivo de Microsoft Excel con extensión (.xls) para su posterior procesamiento.

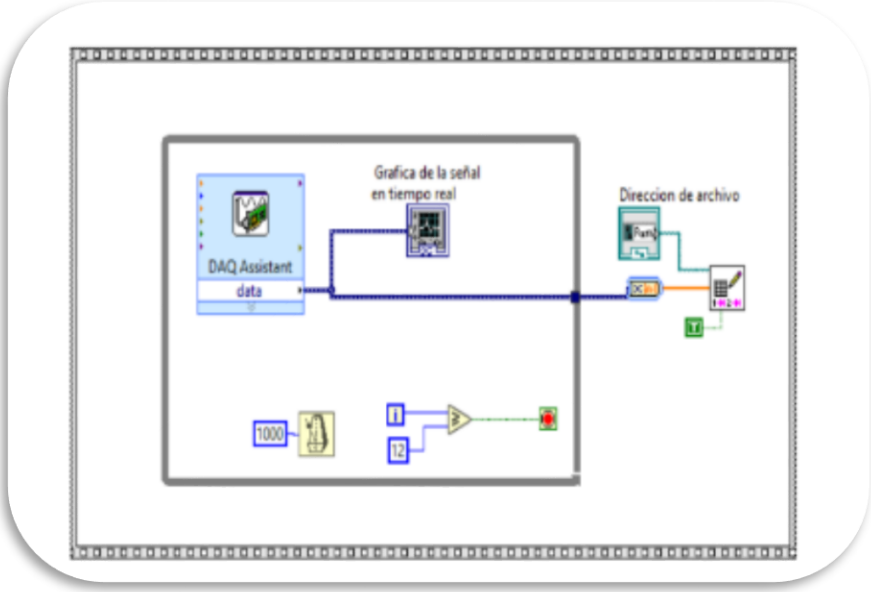

Figura 28. Algoritmo de adquisición de señales. Fuente: Autores

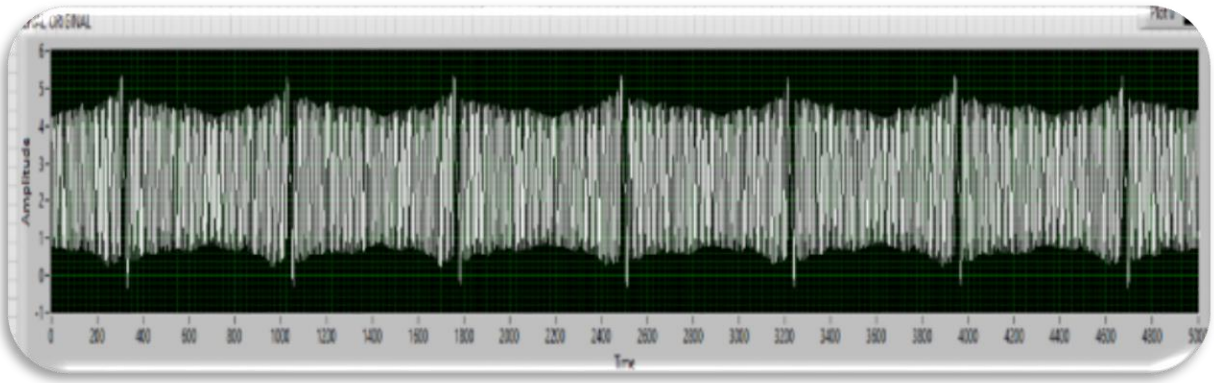

Figura 29. Señal temporal del sensor CKP en ralentí. Fuente: Autores

6.5.1 Nomenclatura para el archivo de la muestra.

La nomenclatura responde a las averías ocasionadas en el experimento, así como el número de repetición y la fecha de muestreo.

Tabla 12 Nomenclatura de archivos. Fuente: Autores

Fecha	**Condición**	**Numero de repeticiones**
02_jun_21	Motor_OK_	1
	02_jun_21_Motor_OK_1	

6.6 Algoritmo para el post procesamiento de datos.

Con la base de datos de las señales adquiridas, se procede a desarrollar el algoritmo que determine los parámetros estadísticos de cada una de las señales y por consiguiente genere de forma automática una matriz.

Como se aprecia en la Figura 30, se realiza la lectura de los archivos, para posteriormente iniciar el filtrado las señales y evitar cualquier error debido a una intromisión de ruido externo a la señal.

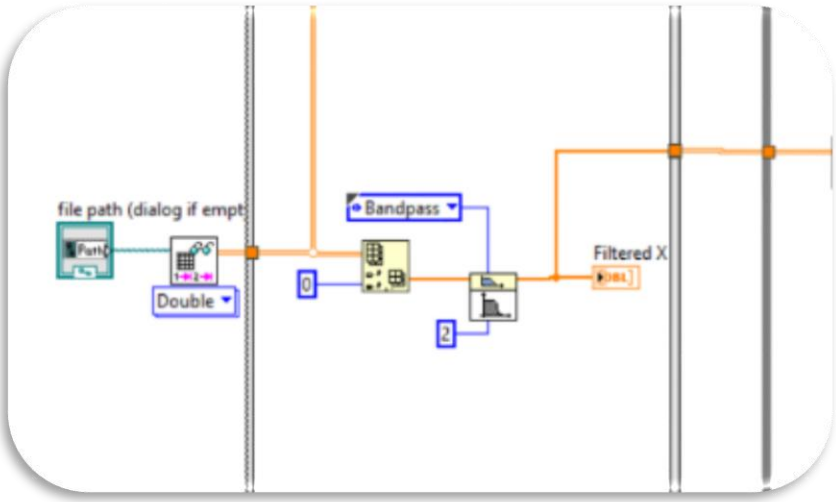

Figura 30. Filtrado de la señal. Fuente: Autores

En función a la literatura se conoce que inmediatamente después de que el doble diente de la rueda fónica pasa por el sensor CKP existen 19 picos hasta llegar a la etapa en que el cilindro uno se encuentra en el PMS (Punto muerto superior) en la fase de compresión. De esta manera se determinan los cortes a realizar en la señal temporal del sensor puesto que se conoce la disposición de la rueda fónica (60 – 2) y el orden de encendido (1-3-4-3), En consecuencia, se tiene que cada pico de la señal representa 6 grados de giro del cigüeñal, por lo tanto, si se respeta el orden de encendido se tendrá la compresión del cilindro uno, tres, cuatro y dos cada 30 picos de la señal (Figura 31).

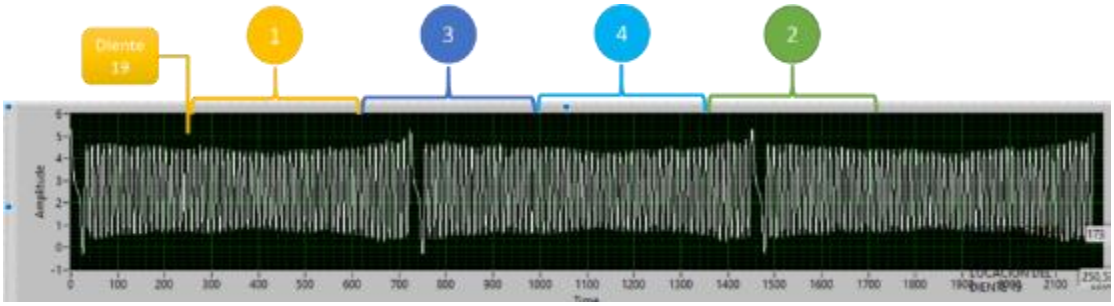

Figura 31. Cortes de los cilindros. Fuente: Autores

En la Figura 32 se muestra el algoritmo que realiza los cortes antes mencionados para determinar la aceleración del cigüeñal en cada etapa.

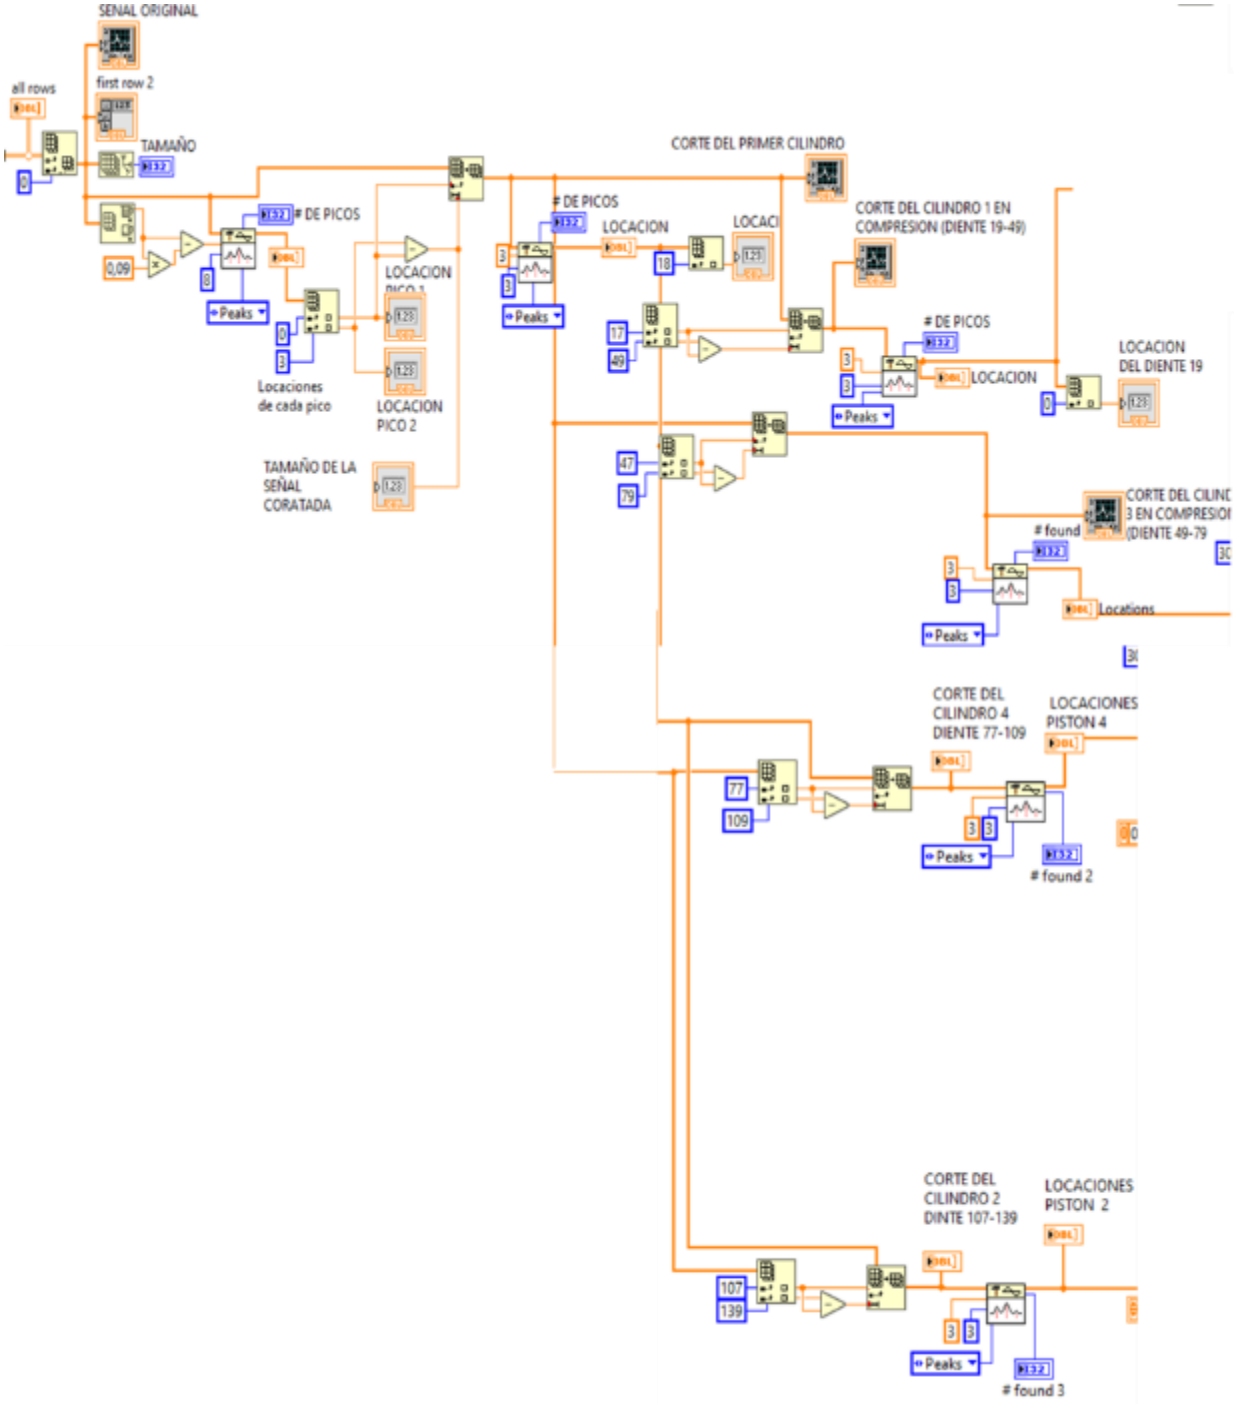

Figura 32. Corte de los Cilindros 1,3,4 y 2 Fuente: Autores

En la Figura 33 se aprecia el corte correspondiente al cilindro 1 en la etapa de explosión.

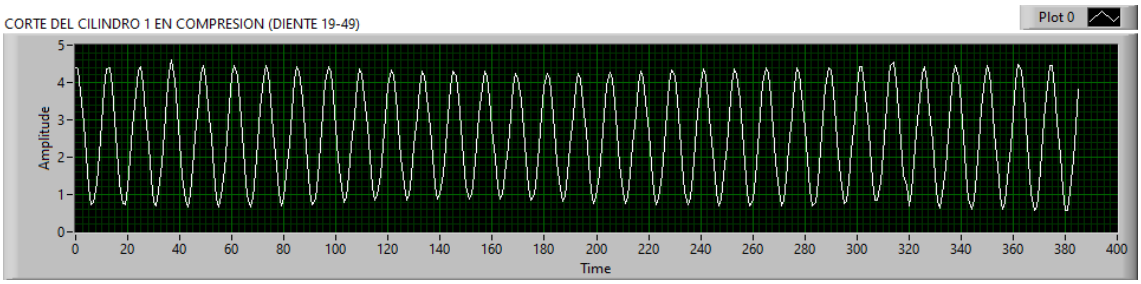

Figura 33. Corte del Cilindro 1 Fuente: Autores

En la Figura 34 se muestra el corte correspondiente al cilindro 3 en la etapa de compresión.

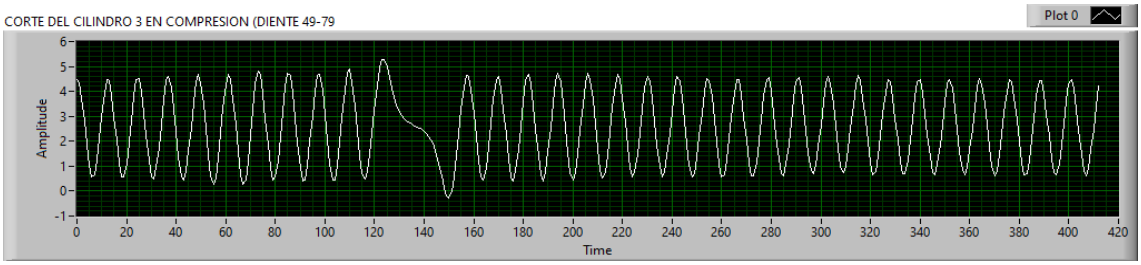

Figura 34. Corte del Cilindro 3 Fuente: Autores

En la Figura 35 se indica el corte correspondiente al cilindro 4 en la etapa de admisión.

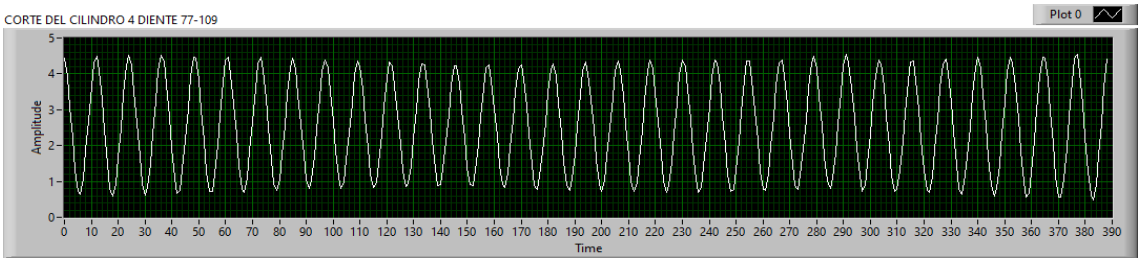

Figura 35. Corte del Cilindro 4 Fuente: Autores

En la Figura 36 se identifica el corte correspondiente al cilindro 2 en la etapa de escape.

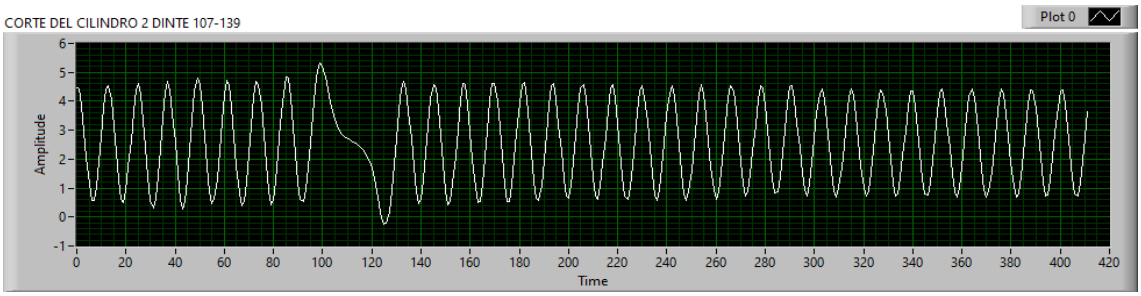

Figura 36. Corte del Cilindro 2 Fuente: Autores

Cuando ya se han obtenido los cortes de las señales del CKP que corresponden a cada uno de los cilindros, se debe realizar la resta de las distancias entre cada pico, puesto que así se obtendrán las gráficas de aceleración del cigüeñal para cada cilindro respectivamente.

En la Figura 37 se muestra el algoritmo para realizar la resta, donde se emplea una estructura FOR con 30 iteraciones de acuerdo con el número de dientes para cada cilindro, ello con el objetivo de generar una matriz que almacene cada uno de los valores para su posterior gráfica.

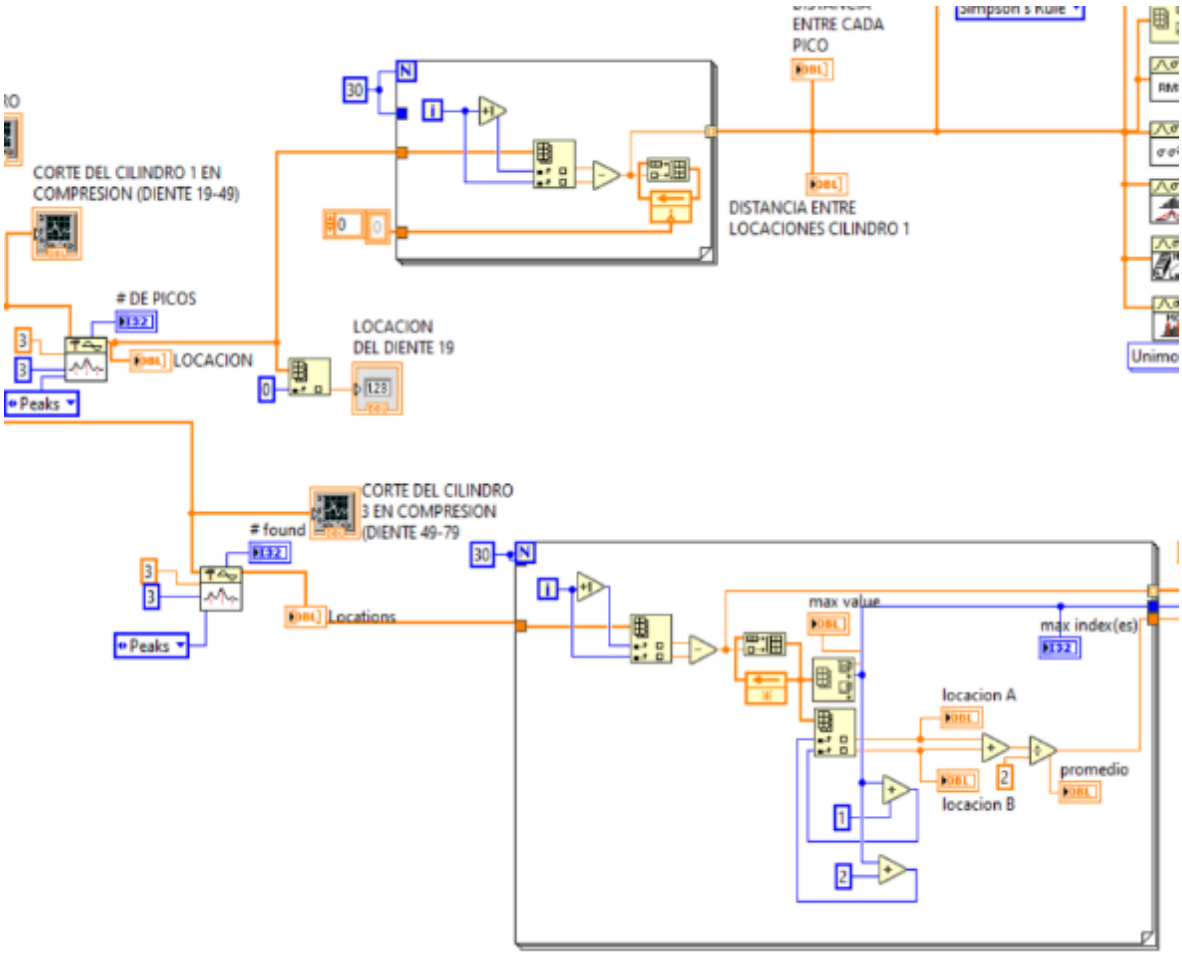

Figura 37. Bloque de restas para distancia pico a pico. Fuente: Autores

Para los cilindros 3 y 2 se reemplaza el valor del pico más alto que corresponde al nuevo diente, puesto que es un inconveniente para el cálculo estadístico. Esto se consigue al obtener el promedio de los dos puntos anteriores e insertar este valor en el Index del pico máximo.

Los valores de la distancia se grafican en función al punto en el que se encuentra cada uno de los picos, es decir la distancia (2-1) se ubica en el punto 1. Este proceso se repite para cada uno de los 120 dientes de los cuatro cilindros. (Figura 38)

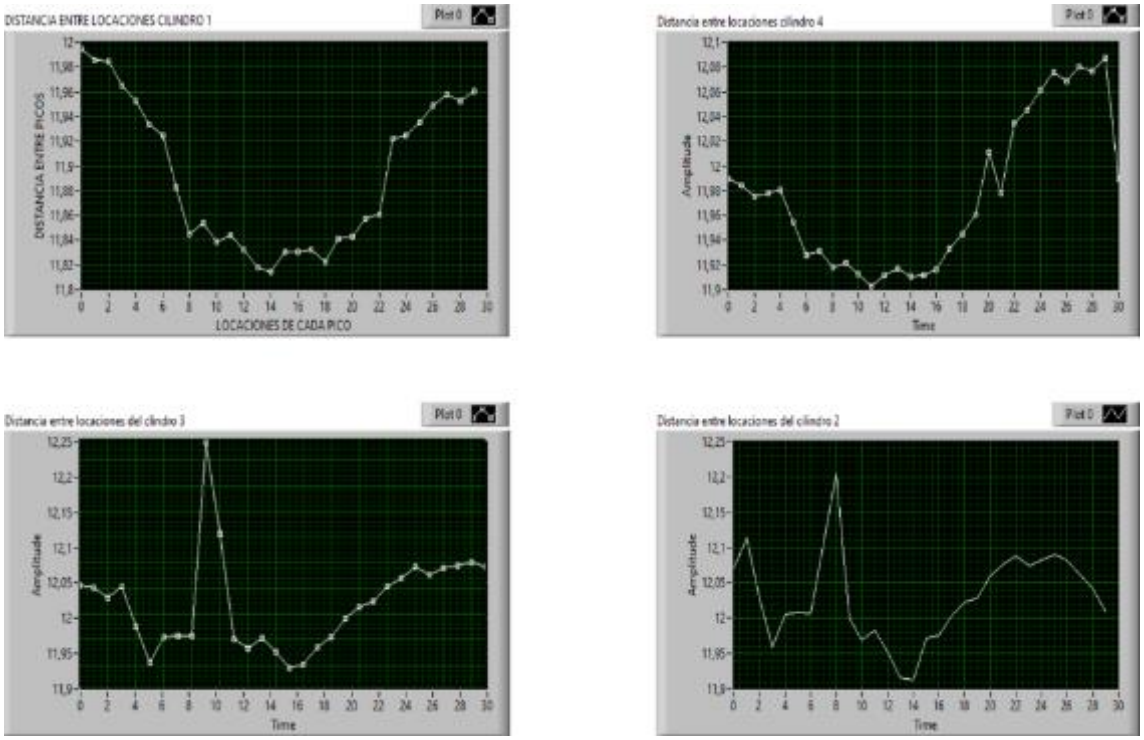

Figura 38. Distancia entre picos. Fuente: Autores.

El último paso del post procesamiento de la señal es calcular los valores estadísticos detallados en el punto 5 de este proyecto. La última etapa del algoritmo (Figura 39) consiste en calcular toda la estadística requerida, a través de los módulos que LabVIEW tiene destinados para este fin.

Al terminar este algoritmo crea una matriz con todos los valores estadísticos para cada pistón que posteriormente se anexaran a un array consolidado.

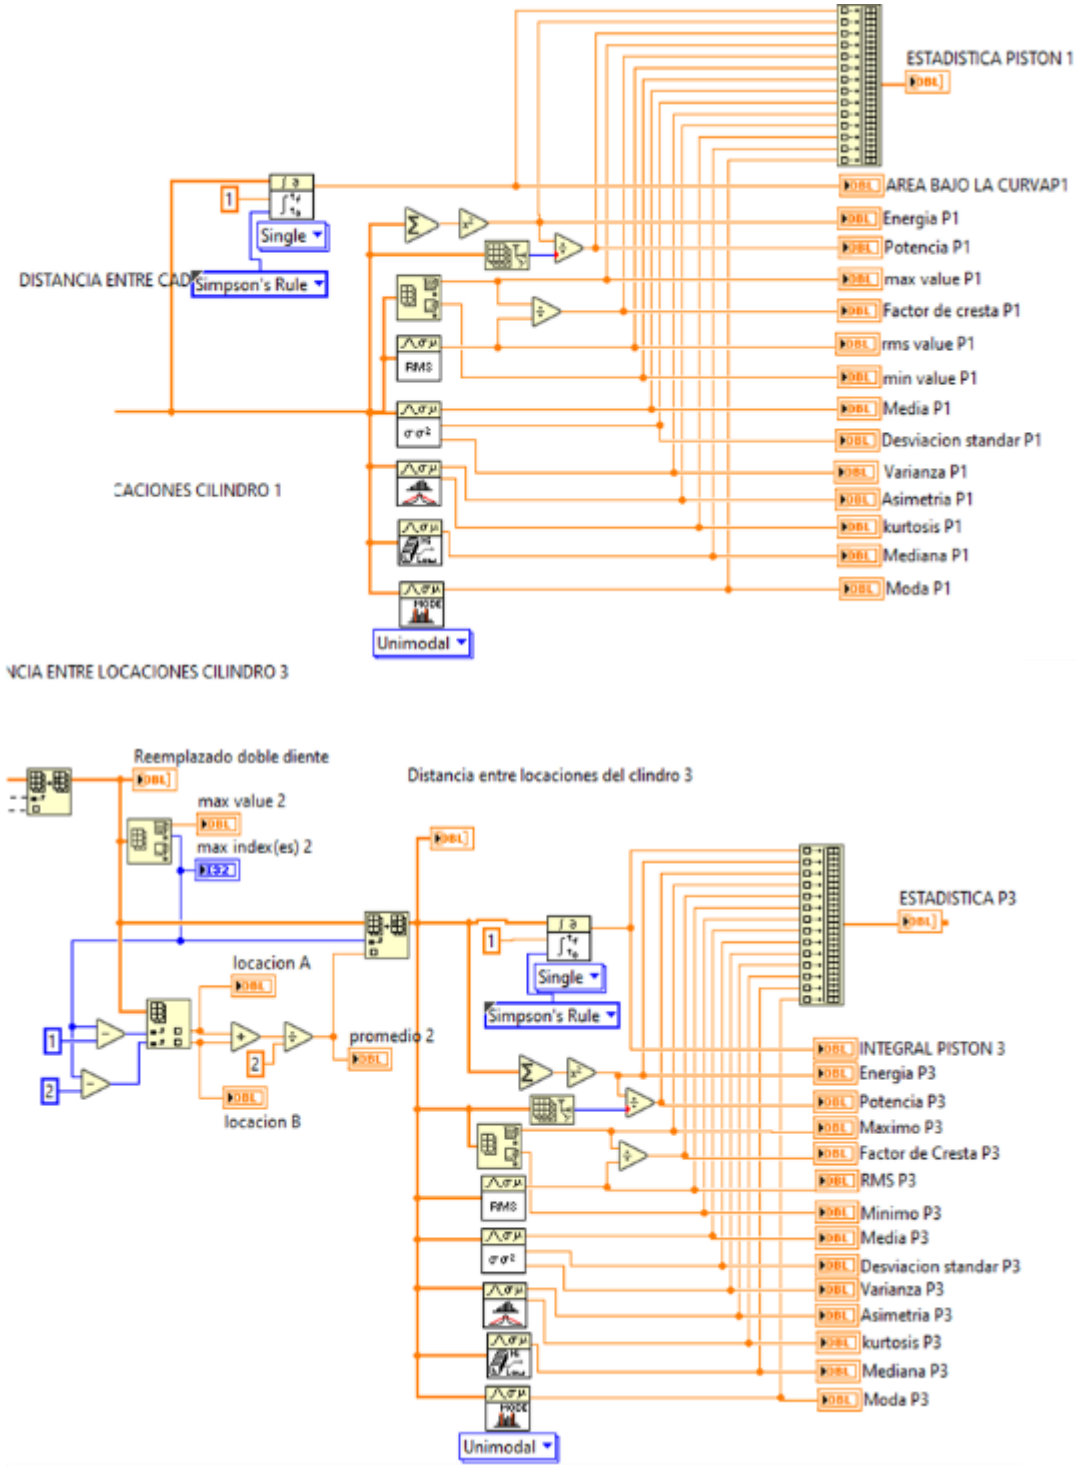

Figura 39 Bloque para el array de la estadística. Fuente: Autores

Para esta sección se requiere crear una matriz general con los datos estadísticos. En los puntos anteriores se detalla que se toman muestras de 12 segundos debido a que en cada señal se pueden obtener un total de dos ciclos del motor y realizar un segundo estudio en un mismo archivo. Paralelo al algoritmo detallado se ejecuta un SubVI que analiza la señal restante. (Figura 40,Figura 41).

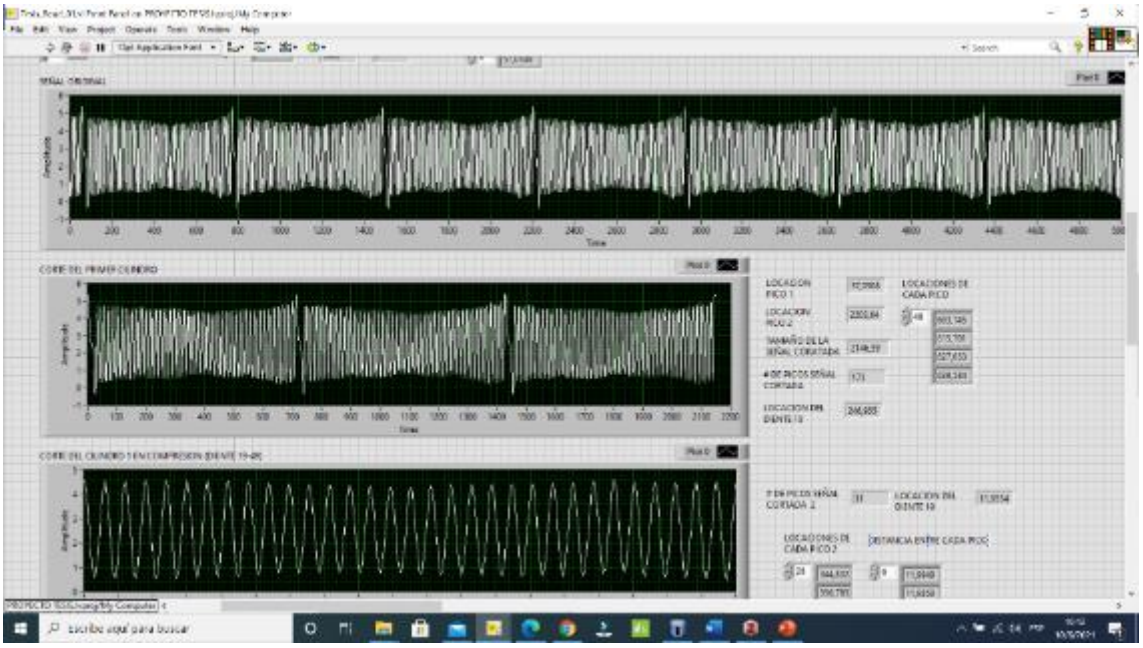

Figura 40. Interfaz para la prueba 1. Fuente: Autores

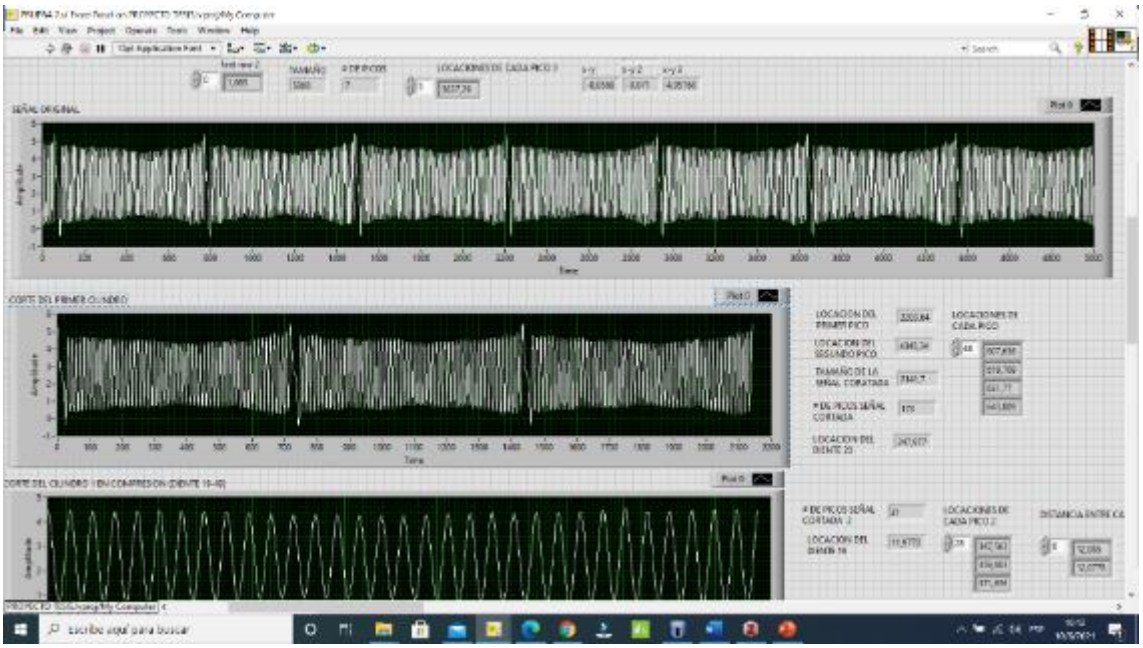

Figura 41. Interfaz para la prueba 2 Fuente: Autores.

Entonces la matriz de datos se crea en un SubVI que concatena los valores de las dos pruebas como se muestra en la Figura 42.

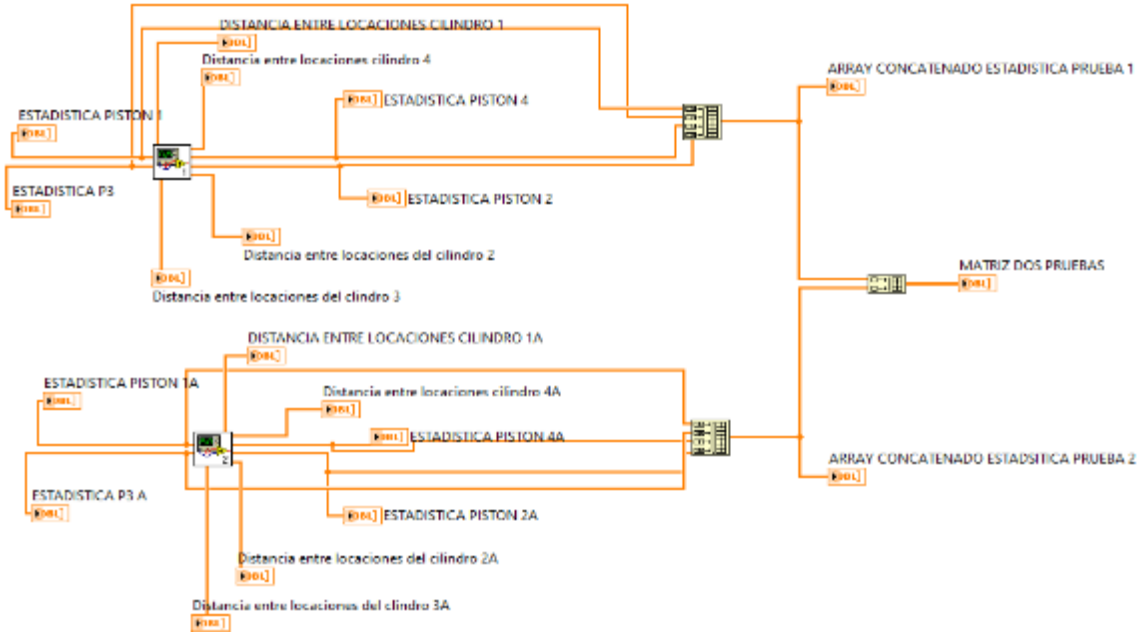

Figura 42. Matriz estadística de las dos pruebas Fuente: Autores

En la Figura 43 se puede observar el Front panel con la matriz de datos estadísticos consolidados. En la primera fila se observa el array de la prueba 1, que resulta de concatenar cada uno de los parámetros estadísticos resultantes del análisis de los cortes realizados a la señal original. En la siguiente fila para el array de la prueba 2 se realiza el proceso antes mencionado.

El array final de las dos pruebas resulta de juntar las matrices transpuestas de la prueba 1 y 2 respectivamente.

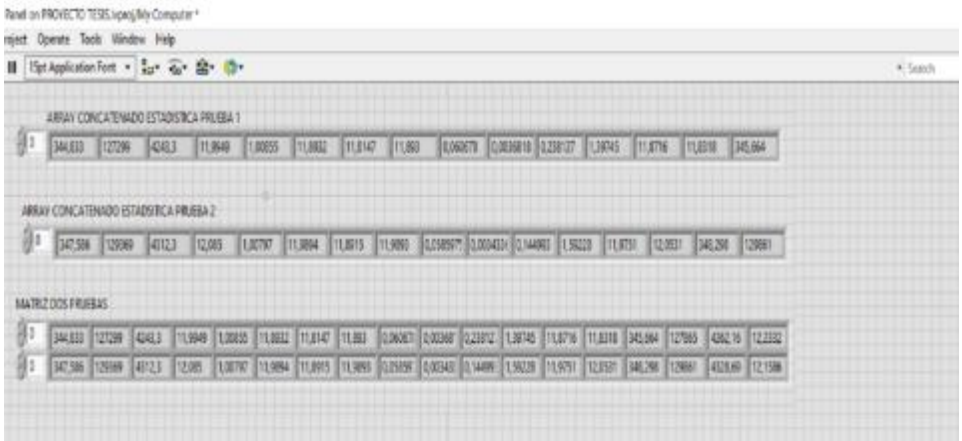

Figura 43. Matriz de datos estadísticos de las dos pruebas Fuente: Autores.

6.7 Algoritmo de diagnóstico para la detección de fallas mecánicas.

Previo al desarrollo del algoritmo es necesario determinar las condiciones del motor mediante un código de falla que defina cada una de las averías. Los códigos se toman con fundamento a las investigaciones realizadas por (Delgado, 2018) y (León & Maldonado, 2018) tal como se muestra en la tabla 13.

Tabla 13. Códigos de Avería. Fuente: Autores.

NÚMERO	**DESCRIPCIÓN**	**NIVEL**	**CÓDIGO DE AVERÍA**
	Motor en buen funcionamiento	OK	0
1	Avería del cilindro uno	Calibración de bujía cero.	100
2	Avería del cilindro dos	Calibración de bujía cero.	200
3	Avería del cilindro tres	Calibración de bujía cero.	300
4	Avería del cilindro cuatro	Calibración de bujía cero.	400
5	Presión de combustible	10 PSI.	500
6	Presión de combustible	21.5 PSI.	600
7	Presión de combustible	33 PSI.	700
8	Presión de combustible	45.5 PSI	800
9	Avería de filtro de aire tapado	50%.	900
10	Avería de filtro de aire tapado	75%.	1000
11	Avería de la válvula IAC	Desconexión	1100
12	Avería del sensor IAT	Desconexión	1200
13	Avería del sensor O2	Desconexión	1300
14	Avería del sensor TP	Desconexión	1400

El punto de partida es insertar la matriz general de datos dentro del software Matlab (Figura 44), pues es de esta matriz de donde se extraen los futuros patrones de comportamiento.

El tamaño de la matriz “datosckp” es de 57 de los cuales 56 son datos estadísticos, 14 por cada cilindro y una columna final que contiene el código de avería.

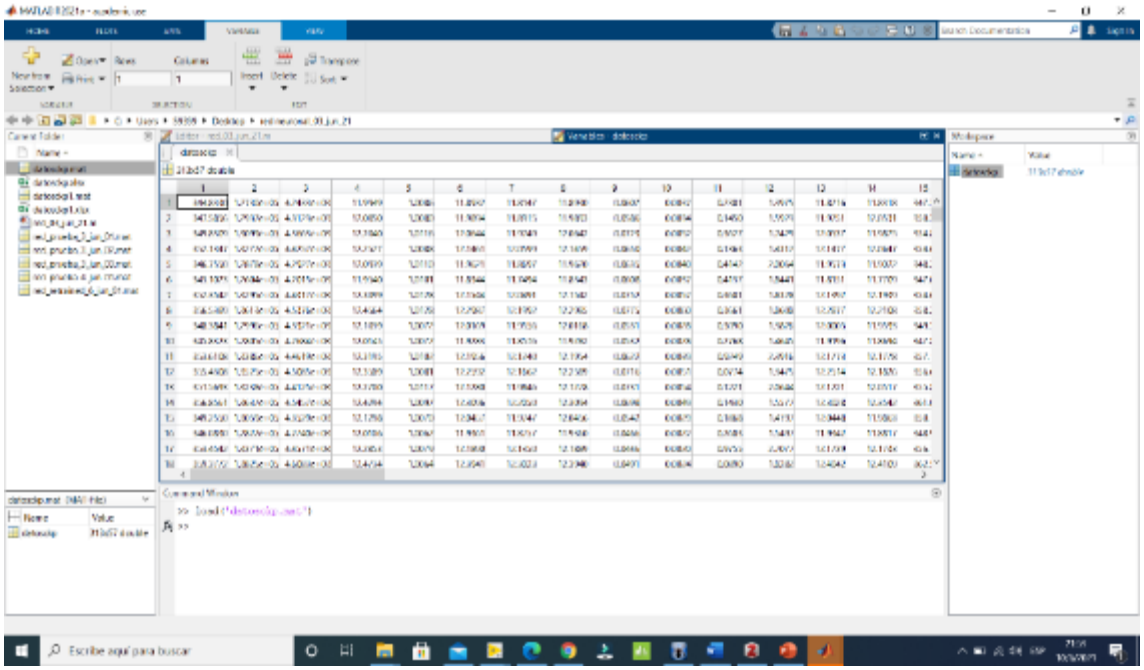

Figura 44. Importación de Matriz de datos a Matlab. Fuente: Autores

La red neuronal se programa de forma que se obtienen los valores máximos de cada factor estadístico de la matriz con el objetivo de que el entrenamiento tenga mayor eficacia al trabajar con dígitos de 0 a 1.

El código de Matlab para la creación de la red neuronal se presenta a continuación:

Se inicia con la lectura de la matriz de datos estadísticos general como se muestra en la Figura 45.

```
clc
clear all
close all
load datosckp
```

Figura 45. Algoritmo para cargar la matriz de datos. Fuente: Autores

Luego se obtienen los valores máximos de todos los valores de la matriz con la finalidad de normalizar todos los datos para un mejor entrenamiento de la RNA (Figura 46).

```
maxt=max(datosckp);
A=[datosckp(:,1)/maxt(1,1) datosckp(:,2)/maxt(1,2)
datosckp(:,3)/maxt(1,3)......
```

Figura 46. Código para obtener el valor máximo de cada uno de los datos. Fuente: Autores

La aplicación de redes neuronales se establece como el método a desarrollar para este algoritmo. Con la matriz de datos normalizada se inicia con la creación de la red neuronal (Figura 47), en donde se determinan los parámetros como: tipo de RNA, Número de capas ocultas y neuronas y funciones de transferencia.

```
red=newff(P,y,[160,320,480],{'elliotsig','elliotsig','elliotsig','tansig'});
```

Figura 47. Línea de código para la creación de la RNA. Fuente: Autores.

Luego de realizar pruebas con diferentes tipos de red (Tabla 14), se selecciona la red newff (feed-forward) debido a su eficacia en el procesamiento de datos obtenidos del sensor CKP. La etapa de entrenamiento se realiza mediante la función "traincgb" con 160, 320 y 480 neuronas en las capas ocultas.

Tabla 14. Pruebas de RNA. Fuente: Autores.

N°	Nombre	Red	Capa 1	Capa 2	Capa 3	Función de transferencia 1	Función de transferencia 2	Función de transferencia 3	Función de transferencia 4	Función de transferencia salida	error
1	red_02jun_p4.mat	Newelm	40	80	120	radbas	elliotsig	elliotsig	purelin	trainscg	11.7562
2	red_02jun_p5.mat	Newelm	80	160	240	radbas	elliotsig	elliotsig	purelin	trainscg	45.1818
3	red_02jun_p6.mat	Newff	80	160	240	radbas	elliotsig	elliotsig	purelin	trainscg	3.885
4	red_02jun_p7.mat	Newff	80	160	240	elliotsig	elliotsig	elliotsig	purelin	traingdx	62.742
5	red_02jun_p8.	Newff	80	160	240	elliotsig	elliotsig	elliotsig	purelin	traingdm	50.62
6	red_02jun_p9.mat	Newff	80	160	240	elliotsig	radbas	radbas	radbas	traingdm	26.68
7	red_02jun_p10.mat	Newff	80	160	240	elliotsig	elliotsig	elliotsig	purelin	traingda	31.17
8	red_02jun_p11.mat	Newff	80	160	240	elliotsig	elliotsig	elliotsig	elliotsig	traincgf	13.24
9	red_02jun_p12.mat	Newff	80	160	240	tansig	elliotsig	elliotsig	purelin	traincgp	20.64
10	red_02jun_p13.mat	Newff	60	320	480	tansig	tansig	tansig	tansig	trainscg	2.6804
11	red_03jun_p1.mat	Newff	40	80	120	elliotsig	elliotsig	elliotsig	elliotsig	traincgb	23.48
12	ed_prueba_3_jun_02.ma	Newff	160	320	480	elliotsig	elliotsig	elliotsig	elliotsig	trainccgb	14.4492
13	ed_prueba_3_jun_03.ma	Newff	160	320	480	tansig	tansig	tansig	tansig	trainccgb	6.35
14	ed_prueba_3_jun_03.ma	Newff	160	320	480	tansig	tansig	tansig	elliotsig	trainccgb	0.68

Como se observa en la Figura 48 los parámetros designados se cargan en la red neuronal para el posterior entrenamiento.

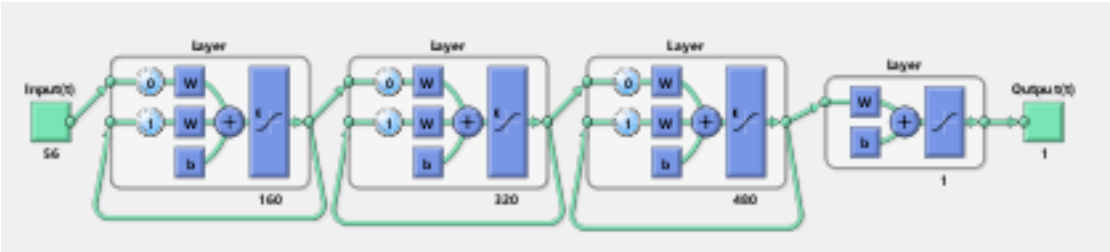

Figura 48. Parámetros de la RNA Fuente: Autores.

La siguiente línea de código realiza el entrenamiento de la red cuyos requerimientos como tipo de entrenamiento, numero de épocas y error máximo se detallan en este apartado (Figura 49).

```
[trainInd,valInd,testInd]=dividerand(P,0.7,0.15,0.15);
red.trainFcn='traincgb';
red.trainParam.goal=1e-50;
red.trainParam.epochs=3e4;
red.trainParam.max_fail=1e4;
red.trainParam.min_grad=1e-50;
red=train(red,P,y);
```

Figura 49. Entrenamiento de la RNA. Fuente: Autores.

El entrenamiento se realiza con un total de 30.000 épocas que se muestran en la Figura 49 en la tercera línea de código, en la misma figura se puede apreciar la codificación para el error máximo, el cual tiene un valor de 10.000 ($1e^{4}$) y un gradiente de $1e^{-50}$. Estos parámetros se evidencian de mejor manera en la Figura 50.

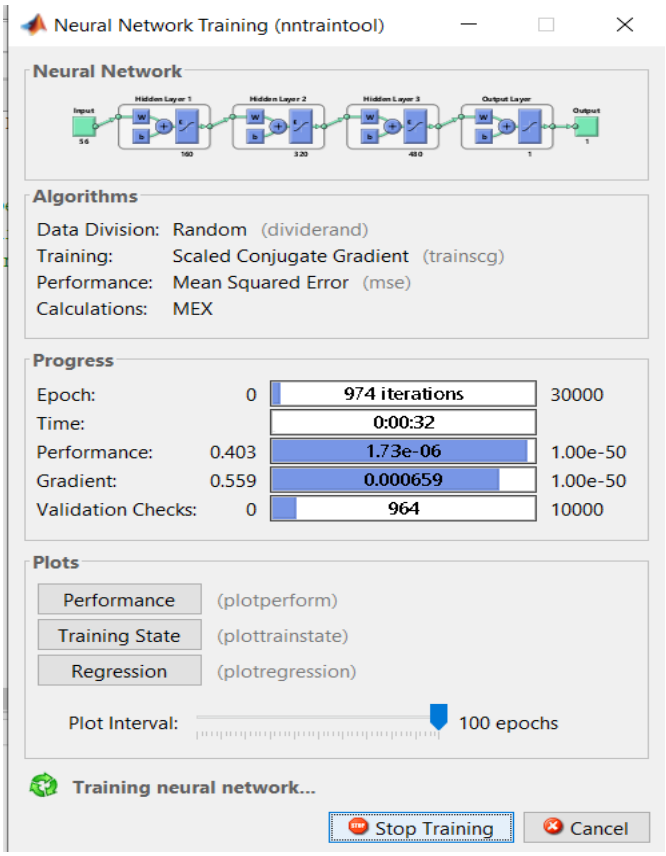

Figura 50. Entrenamiento de la red Fuente: Autores

Finalmente se simula la red a través del código" sim" que se presenta en la Figura 51. Posterior a esto se grafica la respuesta de la red.

```
    out=sim(red,P).*maxt(1,57);
    C1=C.*maxt(1,57);
    out1=out';
    figure(1)
    hold on, grid on
    plot(out1,'ko')
    plot(C1,'g')
error=abs(mean(C1-out1))
```

Figura 51. Código de Matlab para la simulación de la RNA. Fuente: Autores

En la Figura 52 se muestra los resultados de la red neuronal respecto a la matriz de datos procesada que corresponde a cada una de las averías.

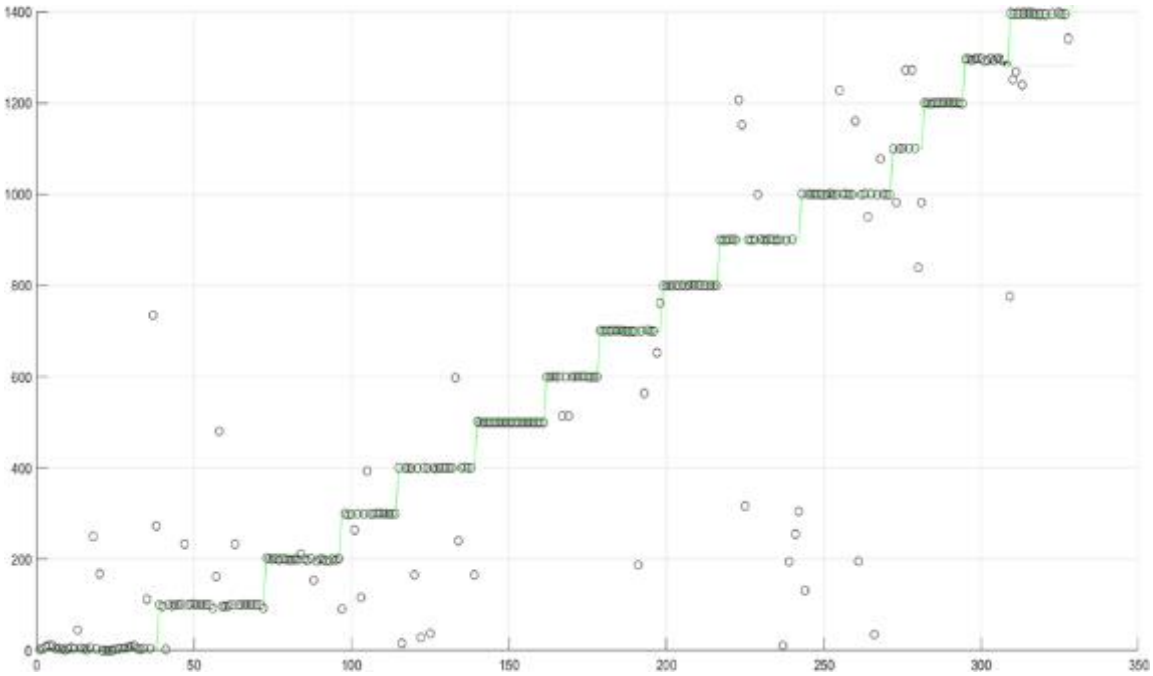

Figura 52. Respuesta de la RNA. Fuente: Autores

6.7.1 Proceso para la determinación de averías.

El proceso de diseño del algoritmo para la detección de fallas se muestra la Figura 53 , en donde se puede evidenciar cada una de las etapas antes mencionadas. El esquema muestra un proceso lógico y continuo que permite de esta forma obtener resultados óptimos en el diagnóstico de las averías.

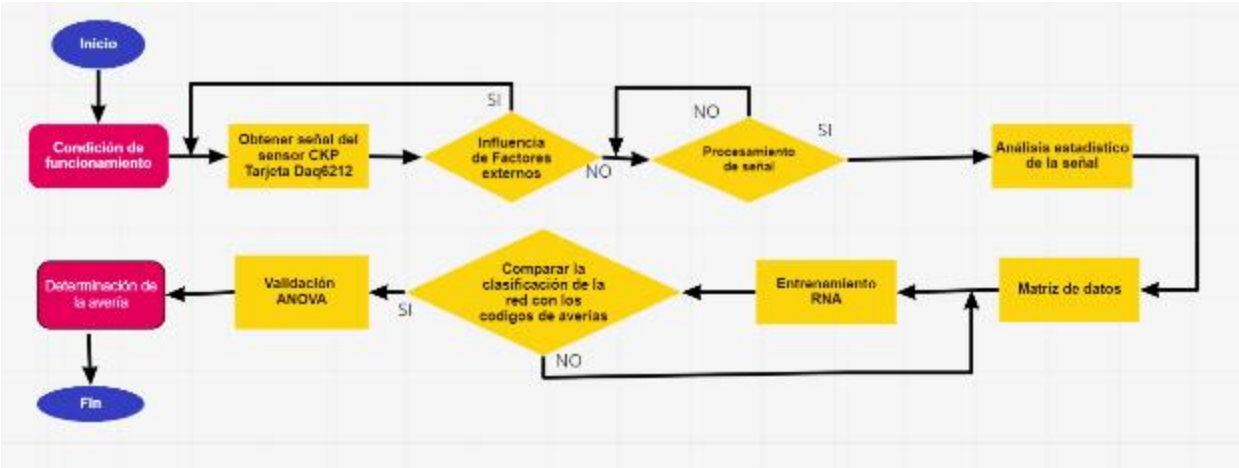

Figura 53. Proceso de diseño del algoritmo de detección de averías. Fuente: Autores

6.7.2 Lectura de red neuronal en LabVIEW.

En la Figura 54 la red neuronal creada en el software Matlab puede ser procesada en LabVIEW gracias a los comandos y módulos existentes entre ambas plataformas. El uso de la estructura Matlab Script permite mediante codificación cargar y correr la red neuronal directamente en LabVIEW para el procesamiento de datos; estos datos provienen de los arrays estadísticos de cada uno de los cilindros.

Dentro de Matlab Script es necesario precisar la ubicación de la red neuronal y de esta forma cargarla mediante la función “load”. El valor de salida de la red se obtiene mediante un “output” que contiene los valores que indican la condición de funcionamiento del motor.

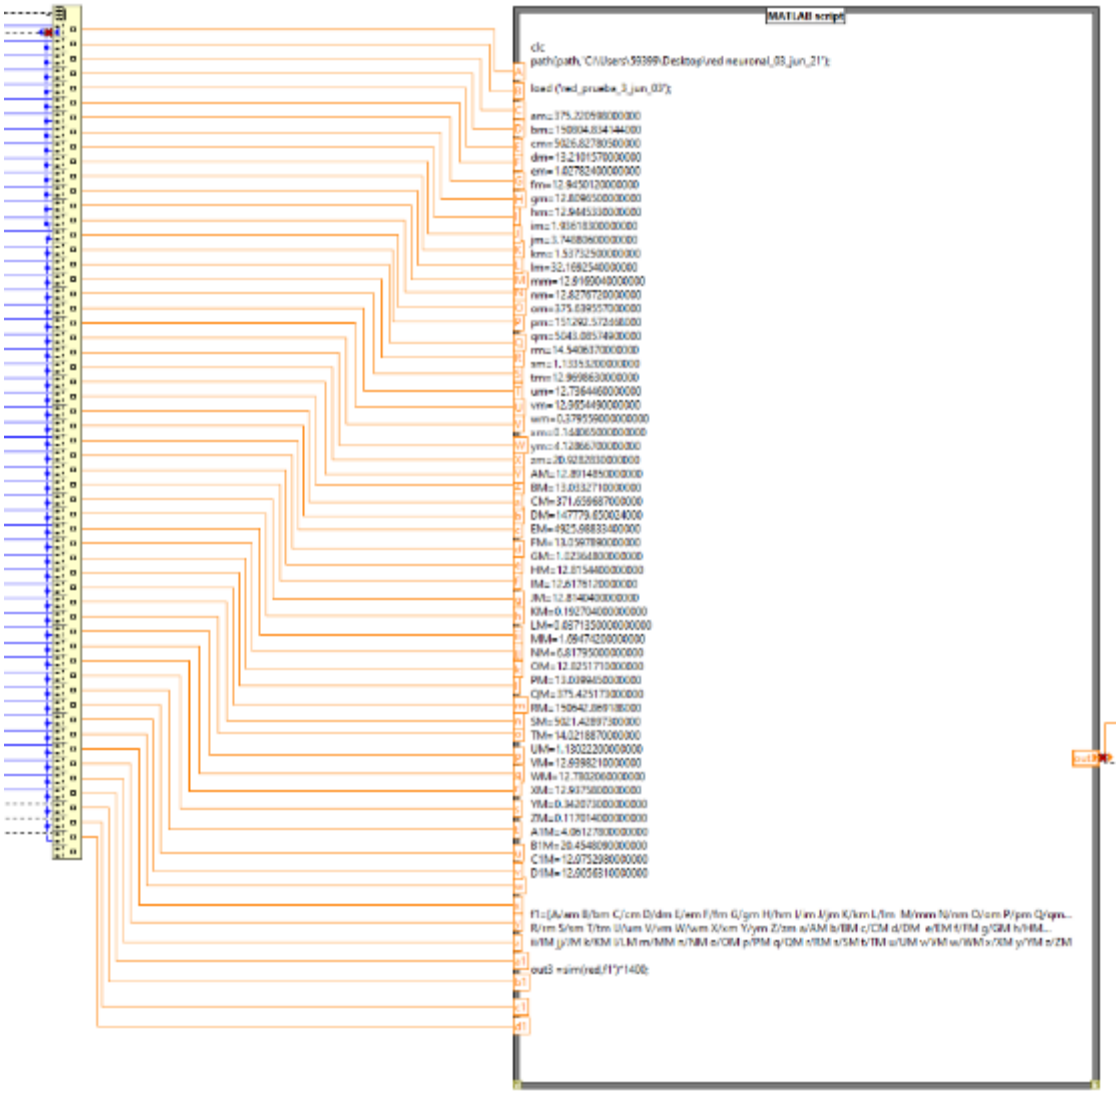

Figura 54. Procesamiento de Red neuronal en LabVIEW

Posterior a la lectura de la red neuronal en LabVIEW se debe implementar un comparador que determine si el valor obtenido por la RNA corresponde a un dato de fallo (Figura 55) y de esta manera permita definir la condición del motor de acuerdo con el código asignado a cada avería en la Tabla 13.

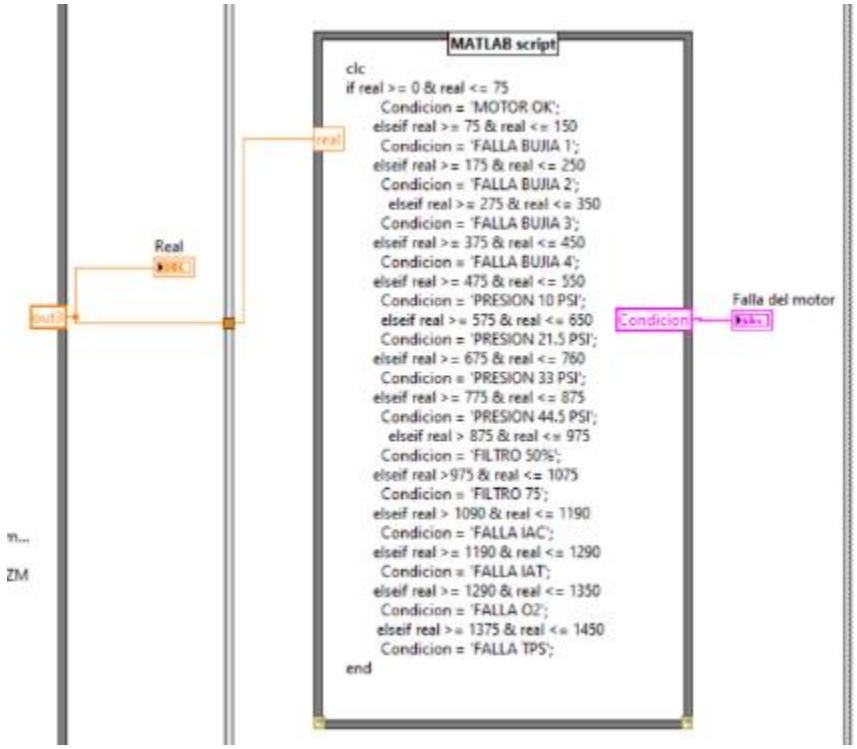

Figura 55 Comparador para determinar el fallo Fuente: Autores

Finalmente se puede corroborar el funcionamiento del sistema a través de una prueba con los datos antes ya obtenidos. La Figura 56 muestra la interfaz que presenta la condición del motor respecto a los códigos asignados.

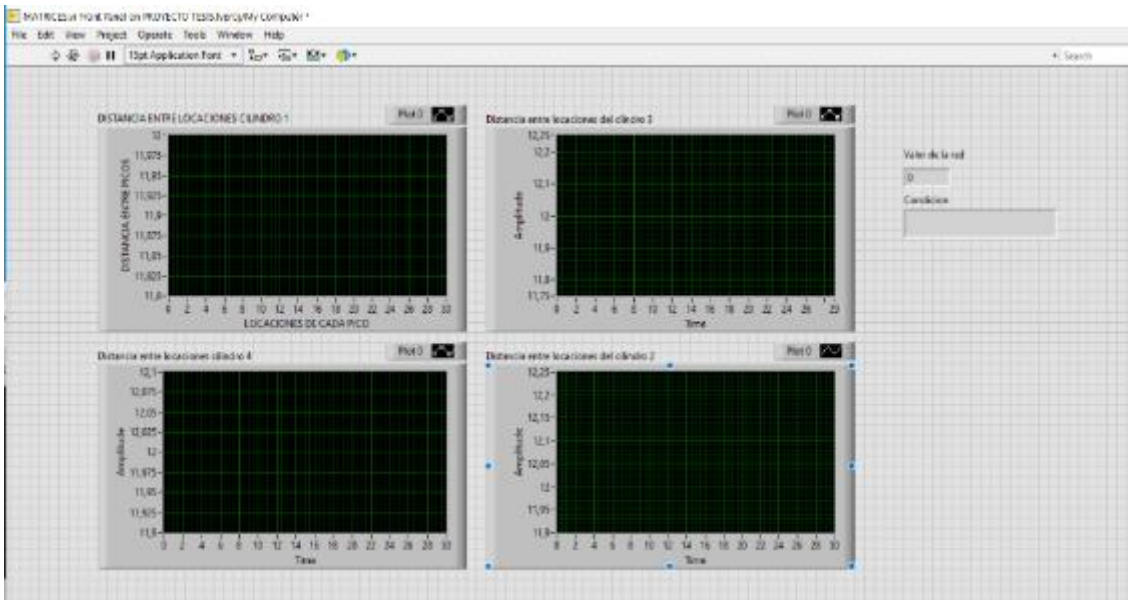

Figura 56. Interfaz de Diagnóstico Fuente: Autores

Al ejecutar el programa, se requiere el archivo de análisis, tal como se indica en la Figura 57.

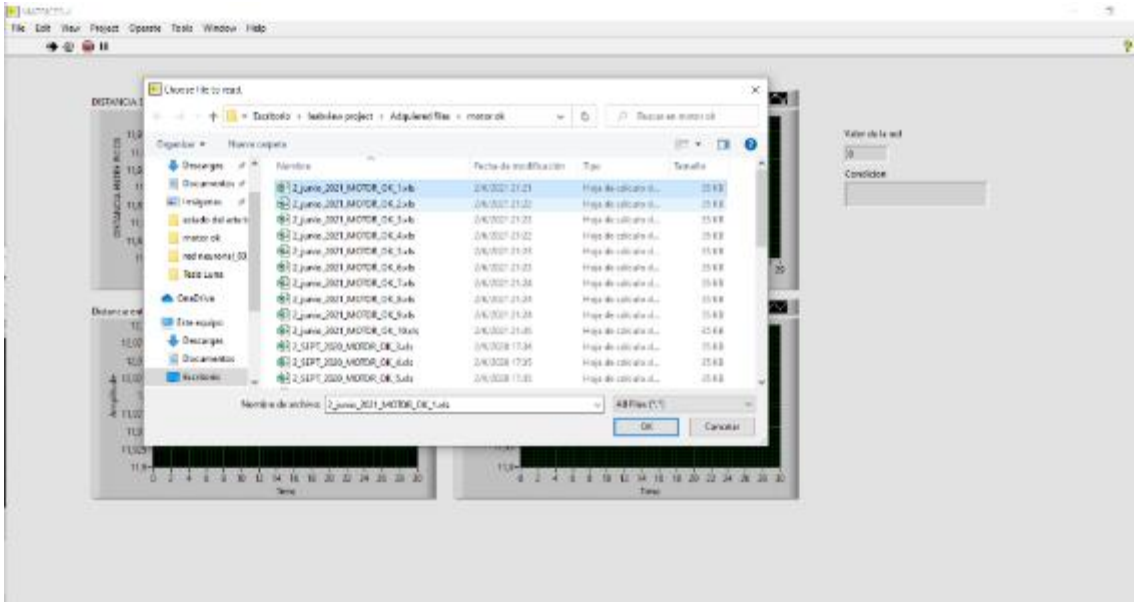

Figura 57 .Lectura del archivo a estudiar. Fuente: Autores

En la Figura 58, el algoritmo indica las gráficas de aceleración del cigüeñal correspondientes a cada cilindro, así como la condición del motor.

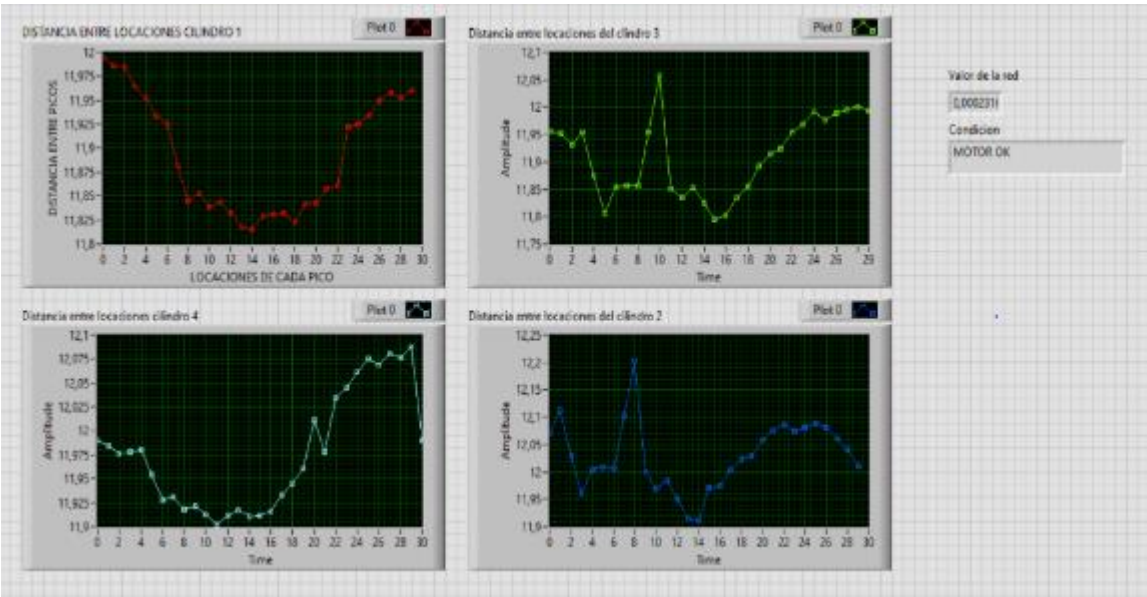

Figura 58. Interfaz de diganostico Fuente: Autores.

De acuerdo con el resultado de la red neuronal, se evidencia la condición del motor y estado de funcionamiento. Tal como se explica en la Figura 59.

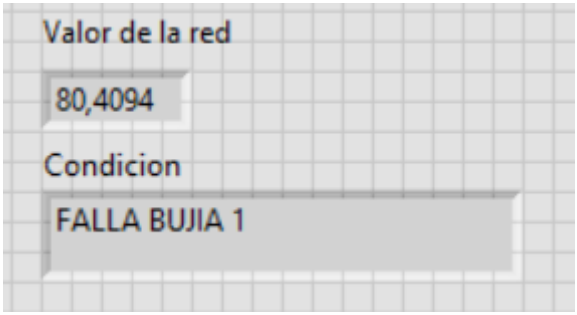

Figura 59 Resultado de la red neuronal y condición del vehículo. Fuente: Autor

7. Análisis de resultados.

7.1 Resultados de la red neuronal en el motor.

Las nuevas muestras se tomaron con el protocolo mencionado en el apartado 6.4 de esta memoria. Con una total de 12 corridas para cada fallo y de esta manera insertar los datos en el software de detección de averías.

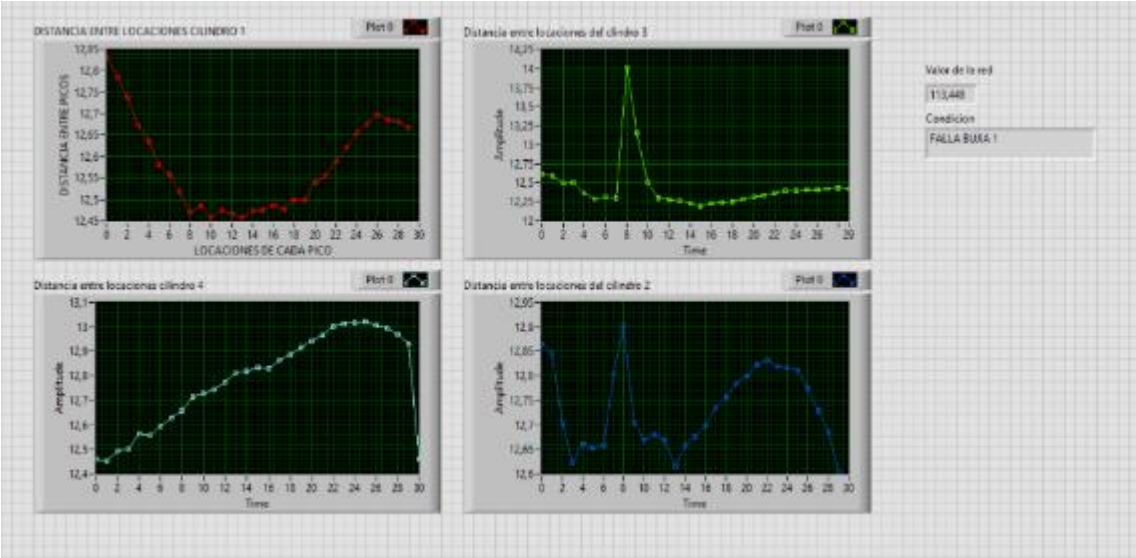

Figura 60. Resultado para avería Bujía 1 Fuente: Autores

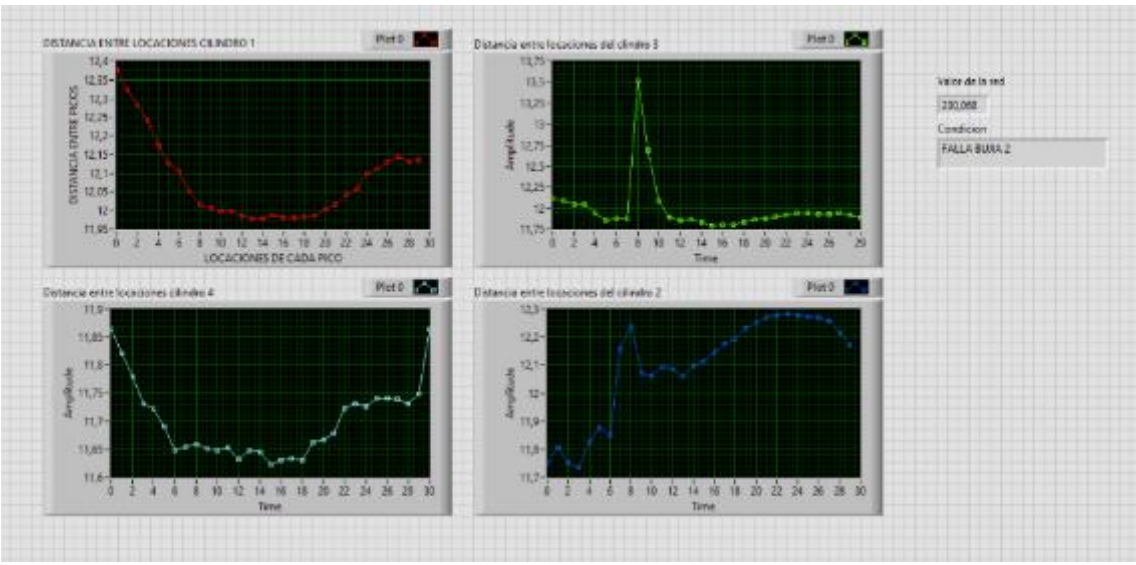

Figura 61. Resultado para avería Bujía 2. Fuente: Autores

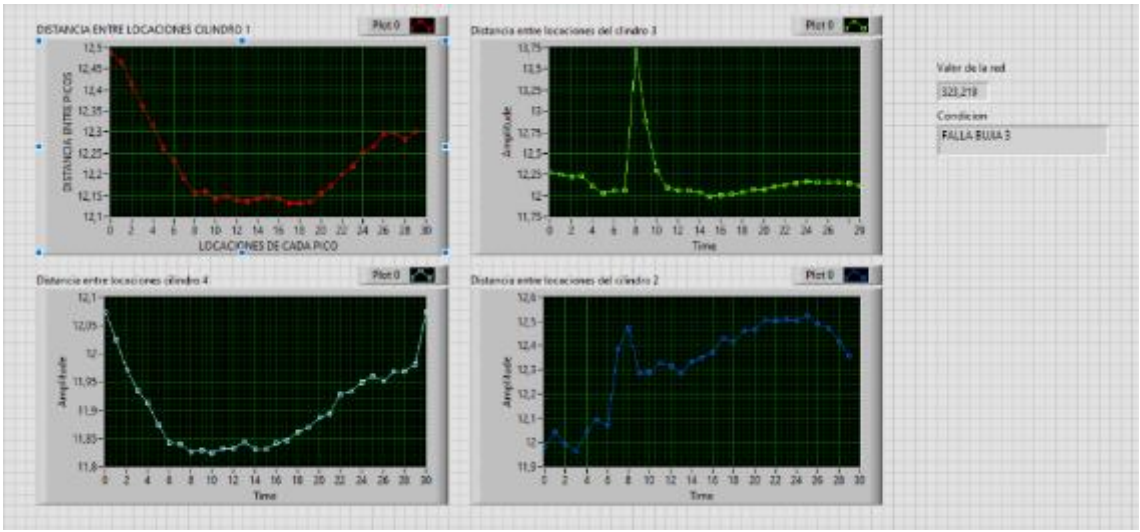

Figura 62 Resultado para avería Bujía 3. Fuente: Autores

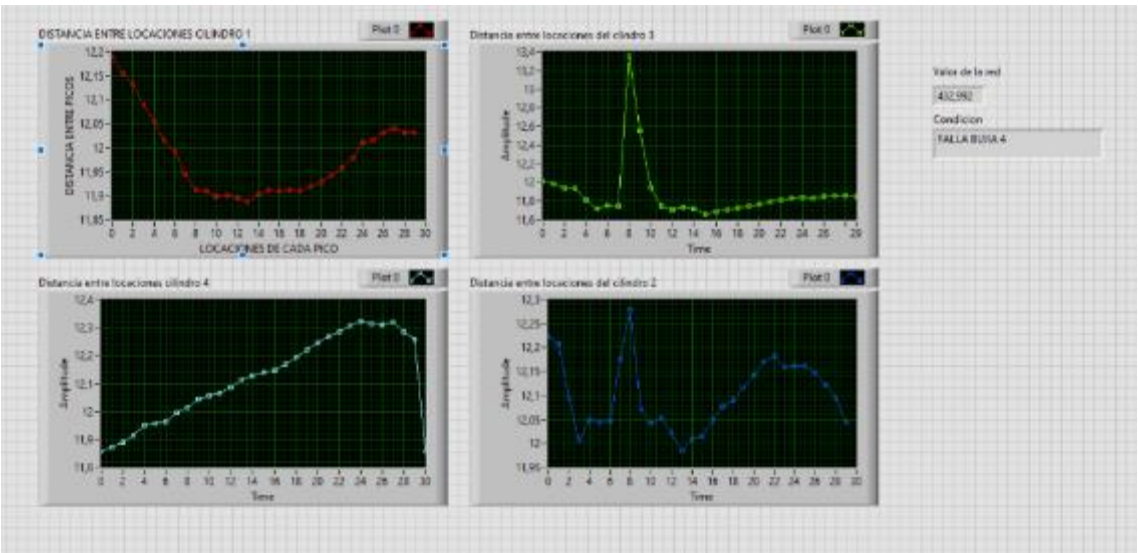

Figura 63. Resultado para avería Bujía 4. Fuente: Autores

En las Figura 60, Figura 61,Figura 62 y Figura 63 se corrobora la funcionalidad de la red. El algoritmo se muestra como una herramienta capaz de identificar los patrones de comportamiento de cada señal y por ende genera una respuesta acertada frente a una condición de fallo del motor únicamente con la información adquirida del sensor CKP.

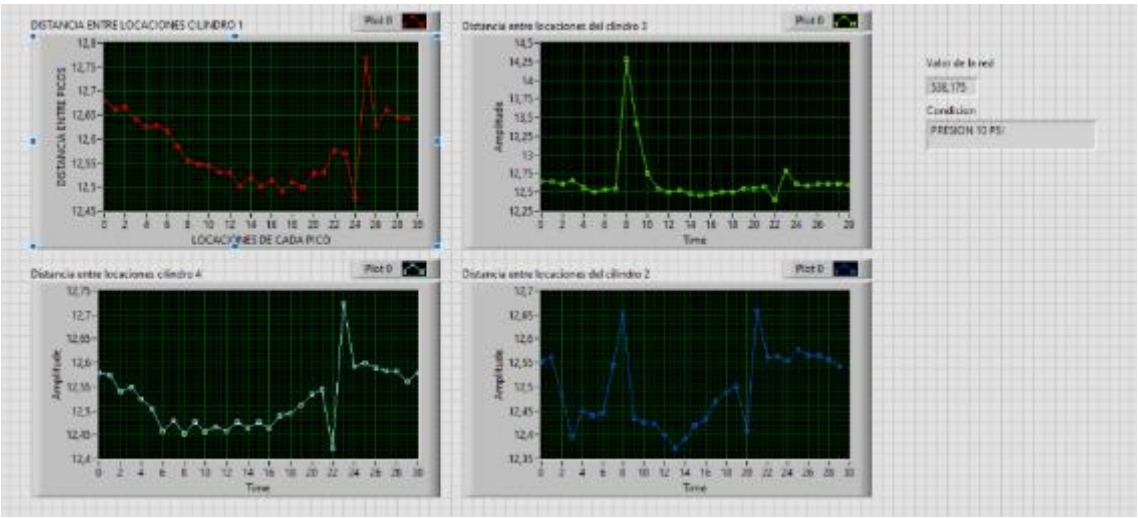

Figura 64 Resultado de avería con presión 10 psi. Fuente: Autores

La presión de combustible con un valor de 10 psi corresponde al código de fallo 500, para el que la red tiene una respuesta correcta. Este patrón se repite para las pruebas de las averías con código 600, 700 y 800 que corresponden a la avería en la presión de combustible. (Ver Figura 64,Figura 65, Figura 66Figura 67)

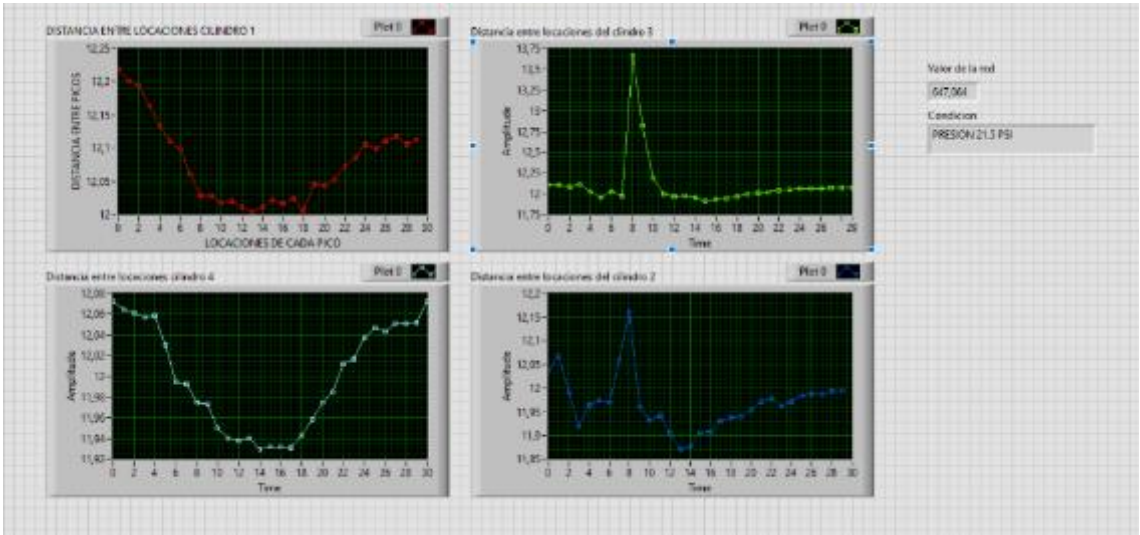

Figura 65. Resultado de avería con 21.5 psi. Fuente: Autores

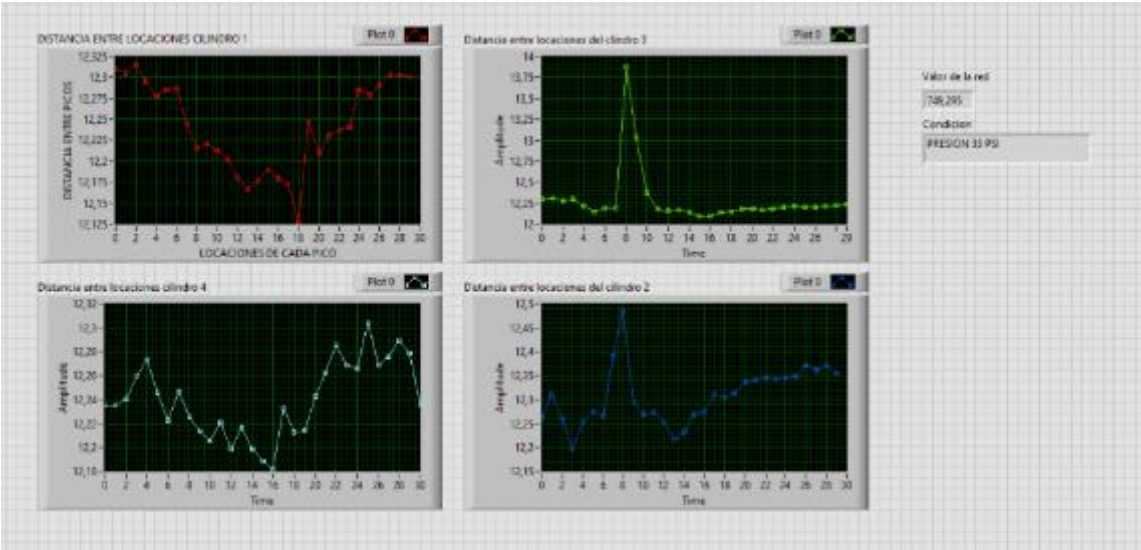

Figura 66. Resultado para avería Presión 33 psi. Fuente: Autores

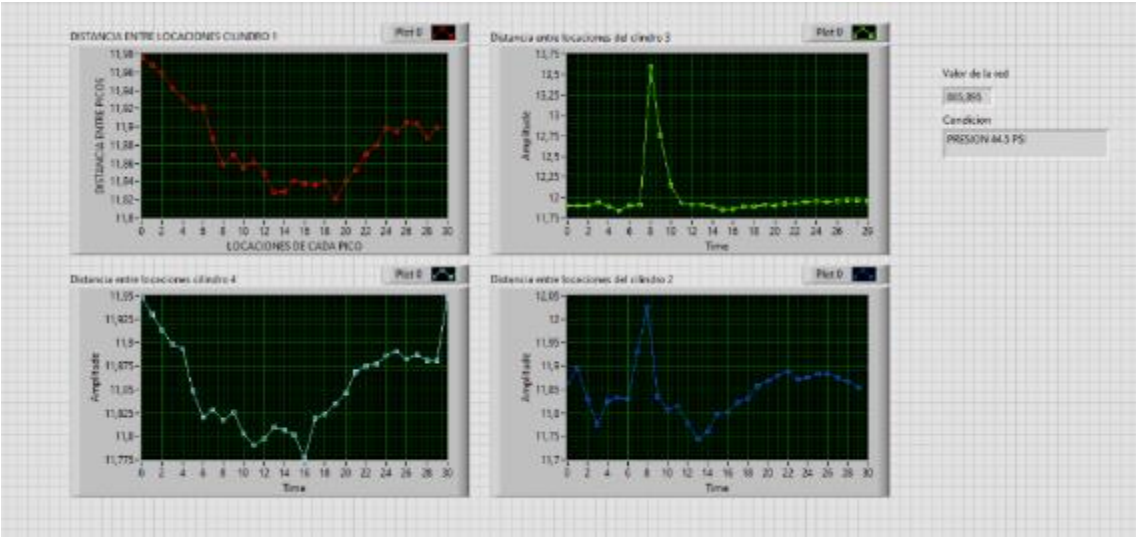

Figura 67. Resultado para avería presión 44.5 psi. Fuente: Autores

Cuando el filtro de aire es alterado en su capacidad filtrante hace que el motor actúe de manera ineficaz. Este fallo esta codificado con 900 para el filtro tapado al 50% y 1000 para el porcentaje del 75%.

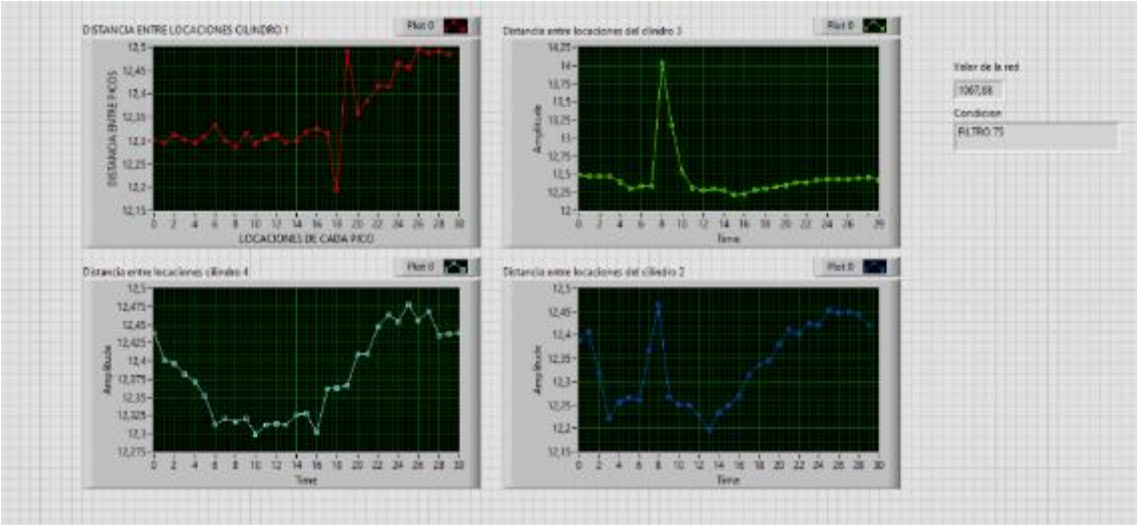

Figura 68. Respuesta para avería Filtro de aire tapado 75%. Fuente: Autores

En las Figura 68Figura 69 la respuesta de la red para ambos casos es favorable. Puesto que los valores procesados están en el mismo rango del código de falla.

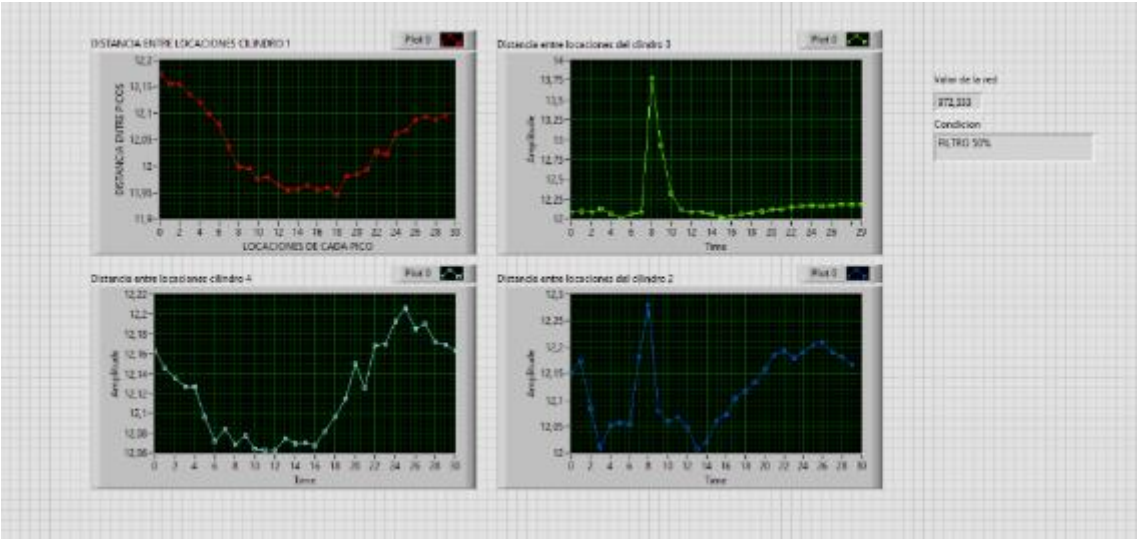

Figura 69. Respuesta de filtro tapado al 50%. Fuente: Autores

En el sensor IAT se muestra el mismo resultado favorable para todas las pruebas, no presenta inconsistencias y es preciso para este tipo de falla. (Ver Figura 80)

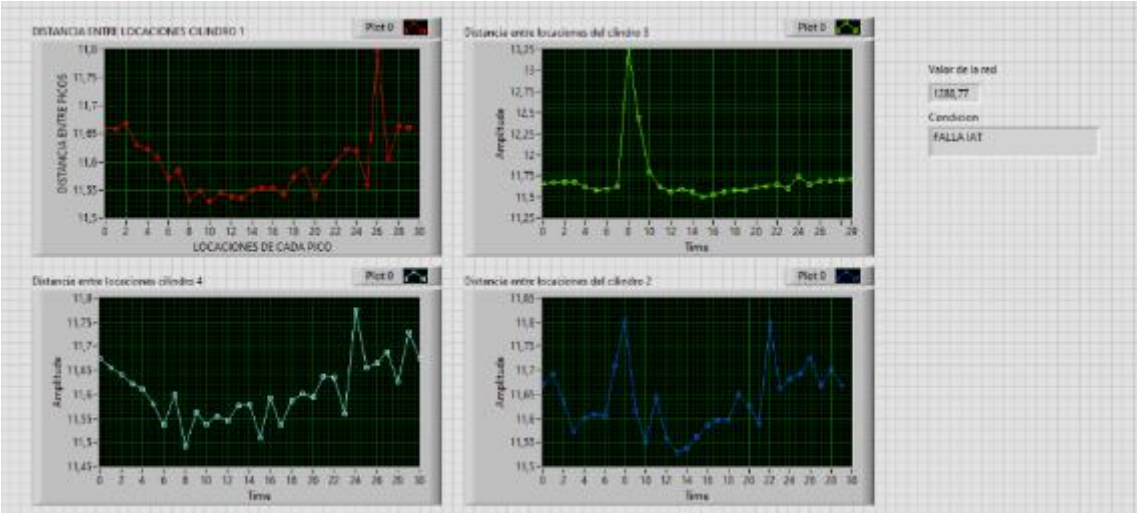

Figura 70. Repuesta de avería desconexión del sensor IAT. Fuente: Autores

En la Figura 71 el fallo en la válvula IAC también es detectado por el algoritmo y en todos los casos la respuesta de la red frente a la avería tiene un resultado óptimo.

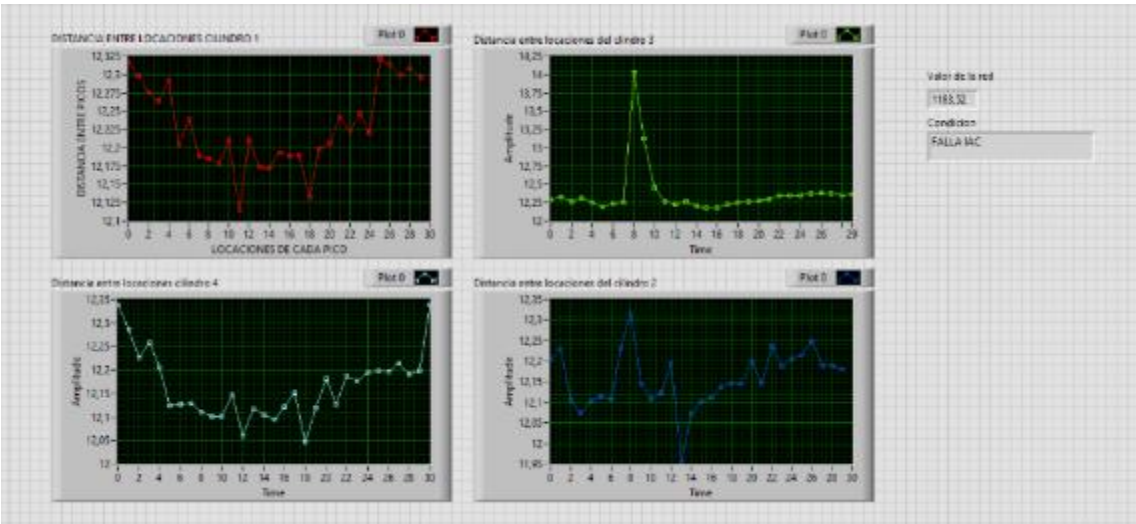

Figura 71. Respuesta a avería desconexión válvula IAC. Fuente: Autores

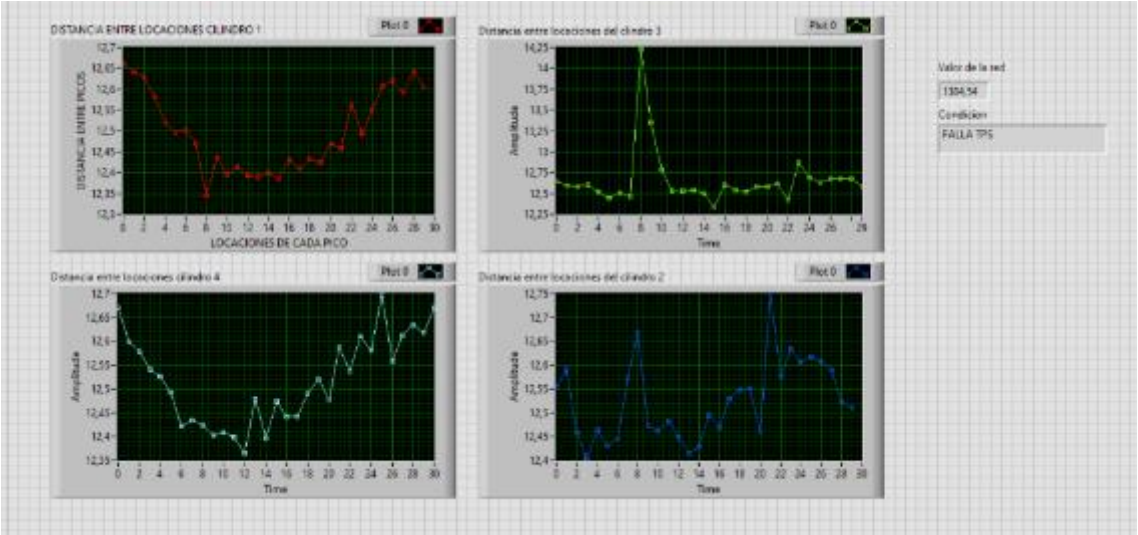

Figura 72. Respuesta a avería desconexión TPS. Fuente: Autores

Para el sensor TPS se presenta un correcto desempeño, sin embargo, tiene un error en algunas muestras que son procesadas de manera errónea e indican que el fallo es otro. Esto está justificado puesto que se habla de una eficacia del 95 % en todos los casos de análisis. (Ver Figura 72)

7.2 Análisis de varianzas para validación de resultados.

Por medio del Análisis de varianza se realiza la comparación entre los valores de media obtenidos de la muestra de cada una de las averías provocadas y los datos procesados por la red neuronal.

El software Minitab (Figura 73) es una de las herramientas para el cálculo estadístico con mayor presencia en el estudio de los factores de análisis en diferentes aplicaciones. En base a esta definición se realiza en esta interfaz el cálculo del ANOVA (Análisis de varianza).

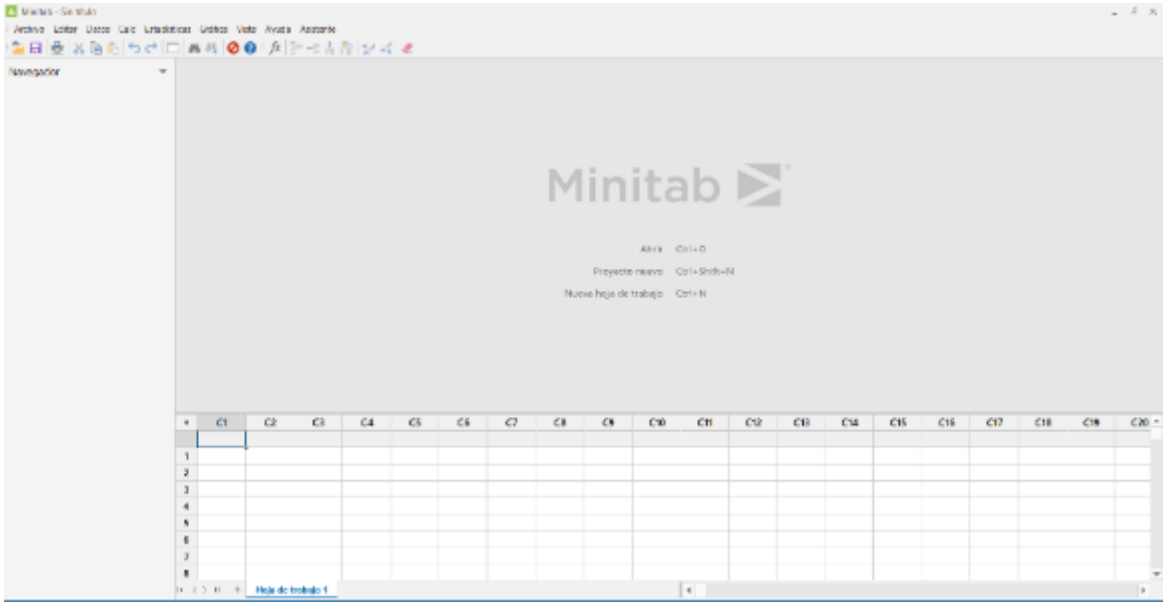

Figura 73 Interfaz de Minitab 19. Fuente: Autores

En la Tabla 13 se mencionan los valores indicados para cada una de las fallas provocadas, estos códigos se emplearán para validar la respuesta de la red a cada condición del motor.

Con todas las condiciones listas, como observa en la Figura 74, se insertan en una columna de Minitab los valores de la red sobre los asignados a cada falla. Para este proceso se aplica el fallo 1200 correspondiente a la desconexión del sensor IAT como ejemplo.

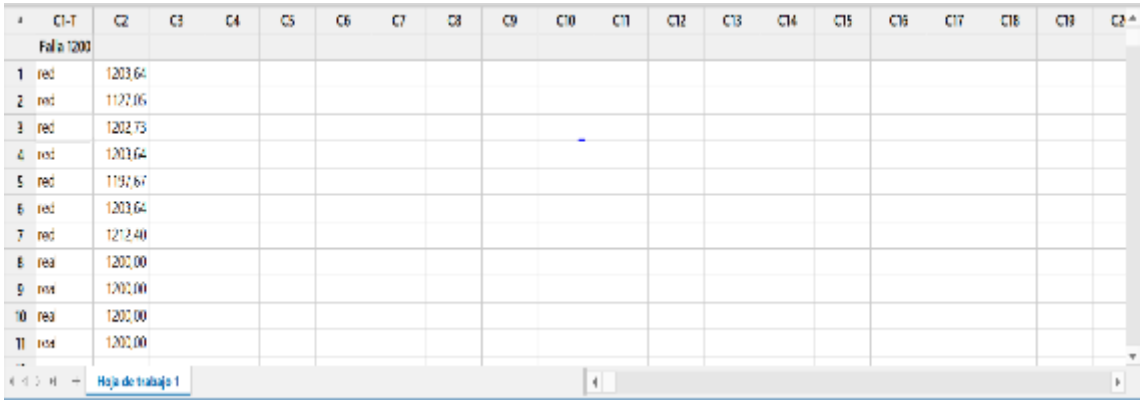

	C1-T	C2
	Fallo 1200	
1	red	1203.64
2	red	1127.06
3	red	1202.73
4	red	1203.64
5	red	1197.67
6	red	1203.64
7	red	1212.40
8	red	1202.00
9	red	1202.00
10	red	1202.00
11	red	1202.00

Figura 74 Datos para analizar en Minitab. Fuente: Autores

En la Figura 75 el método de ANOVA de un solo factor permite realizar la comparación de similitud entre los datos reales que son asignados previamente y los generados por la red neuronal.

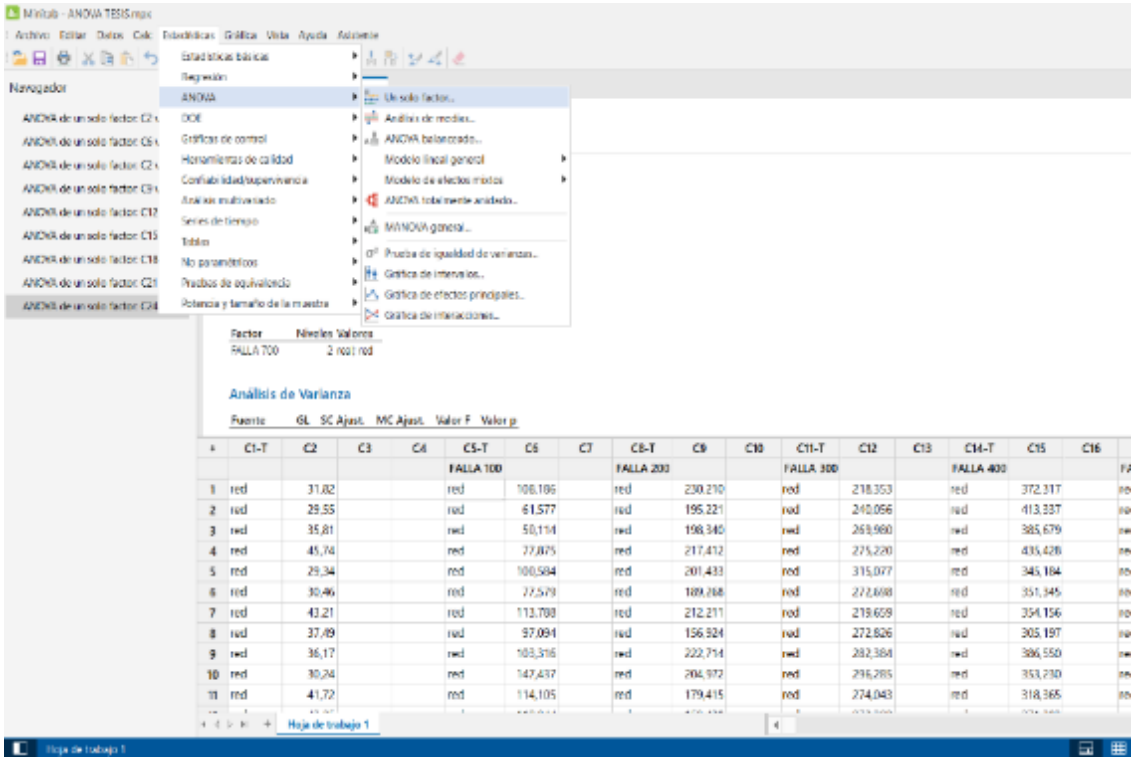

Figura 75 ANOVA de un factor en Minitab. Fuente: Autores

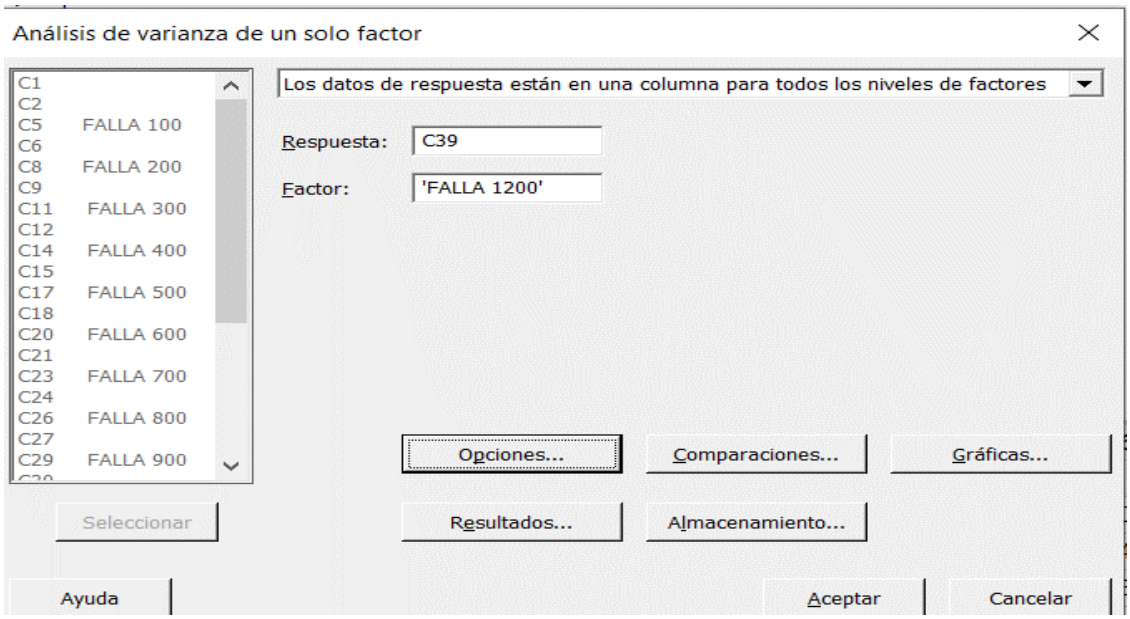

Figura 76 Parámetros de ANOVA de un factor. Fuente: Autores

En la Figura 76 se muestra la ventana del análisis de varianza, en donde se especifican las columnas en la que se encuentran el factor y la variable, además en el apartado de opciones (ver Figura 77) se puede indicar el nivel y tipo de confianza (95% de fiabilidad calibrado por defecto) del análisis, así como la posibilidad de asumir varianzas iguales.

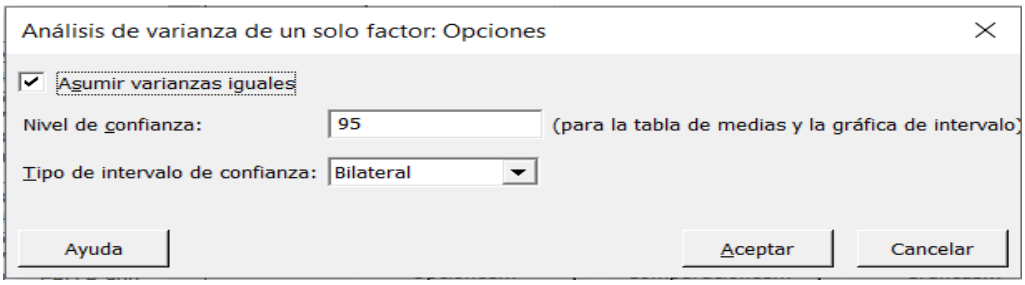

Figura 77 Opciones del ANOVA de un factor. Fuente: Autores

Para las comparaciones el método de Tukey es un complemento del ANOVA y se emplea para crear intervalos de fiabilidad adecuados a todas las diferencias de pares de las medias de los factores mientras controla la tasa de error por grupo de datos. EL método de Tukey (Ver Figura 78) ajusta el nivel de confianza de cada intervalo, puesto que al tener intervalos múltiples se puede generar errores en el nivel de confianza para la similitud de las muestras.

El método de Tukey garantiza que todo el conjunto de comparaciones tenga un error menor al 5%.

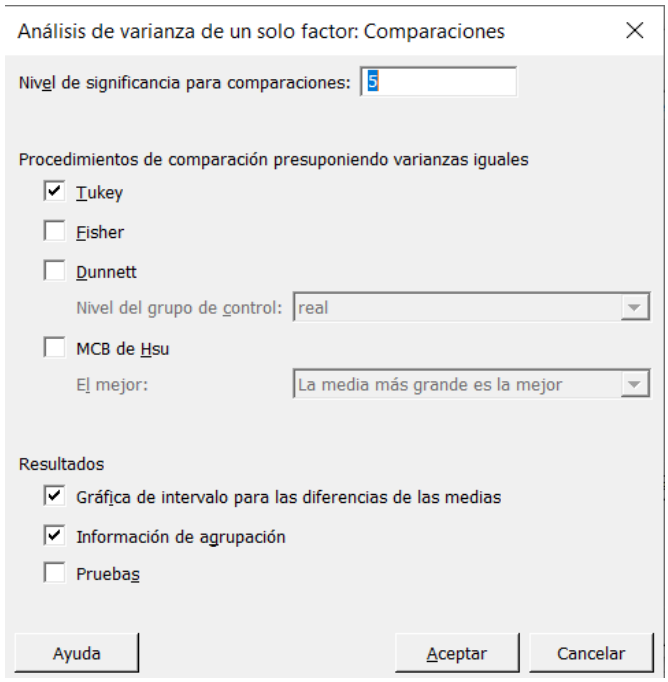

Figura 78 Método de Tukey. Fuente: Autores

Como se puede ver en las Figura 79 y Figura 80 la línea entrecortada interseca con la línea de confianza e indica que no existe significancia entre las medias de la muestra y sus intervalos.

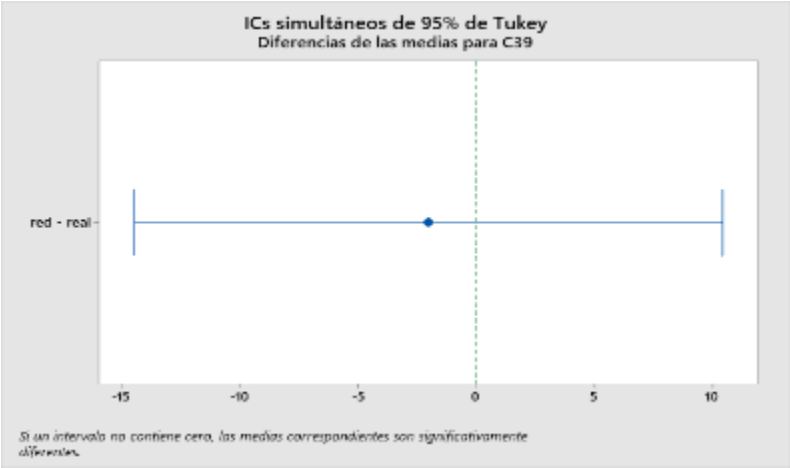

Figura 79 Grafica de intervalos de confianza de avería 1200. Fuente: Autores

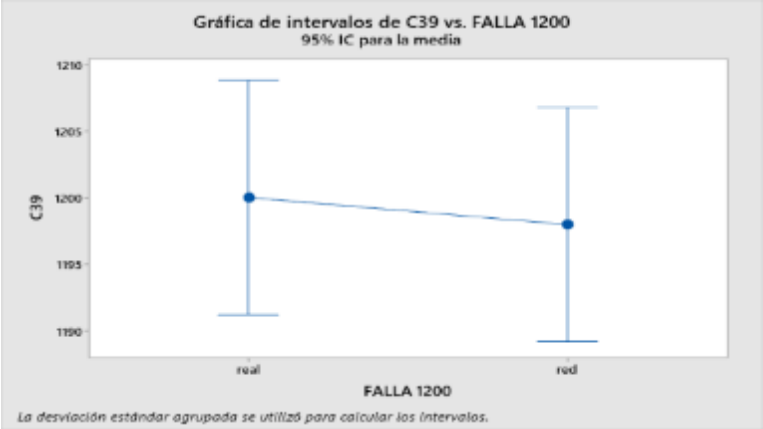

Figura 80 Grafica de intervalos de avería 1200. Fuente: Autores

Se puede ver en la Figura 81 que los valores de las medias son significativamente iguales puesto que comparten el mismo rango. Por lo tanto, se demuestra la funcionalidad de la red neuronal en base a la similitud de los grupos.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA 1200	N	Media	Agrupación
real	13	1200	A
red	13	1197,97	A

Las medias que no comparten una letra son significativamente diferentes.

Figura 81 Grupos de media de avería 1200. Fuente: Autores

7.2.1 ANOVA para avería de bujía 2.

Como se puede ver en las Figura 82Figura 83 la línea entrecortada se interseca con la línea de confianza e indica que las medias son estadísticamente iguales.

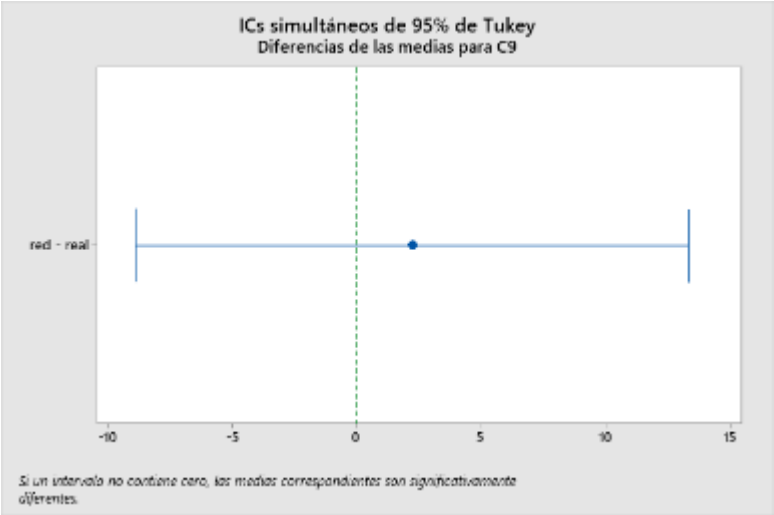

Figura 82. ANOVA para fallo de la bujía 2. Fuente: Autores

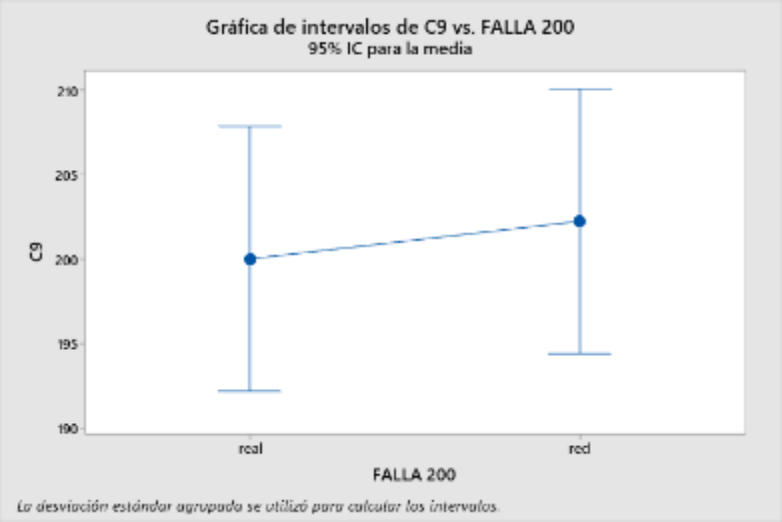

Figura 83. Intervalos de confianza para fallo en la bujía 2. Fuente: Autores

Se puede ver en la Figura 84 que los valores de las medias son significativamente iguales y comparten el mismo rango. Por lo tanto, para este fallo se esperan resultados óptimos.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA

200	N	Media	Agrupación
red	24	202,23	A
real	24	200,0	A

Las medias que no comparten una letra son significativamente diferentes.

Figura 84. Agrupación de las medias para falla de bujía 2. Fuente: Autores

7.2.2 ANOVA para avería de presión de combustible a 10 psi.

Como se puede ver en las Figura 85Figura 86 la línea entrecortada se interseca con la línea de confianza e indica que las medias son estadísticamente iguales.

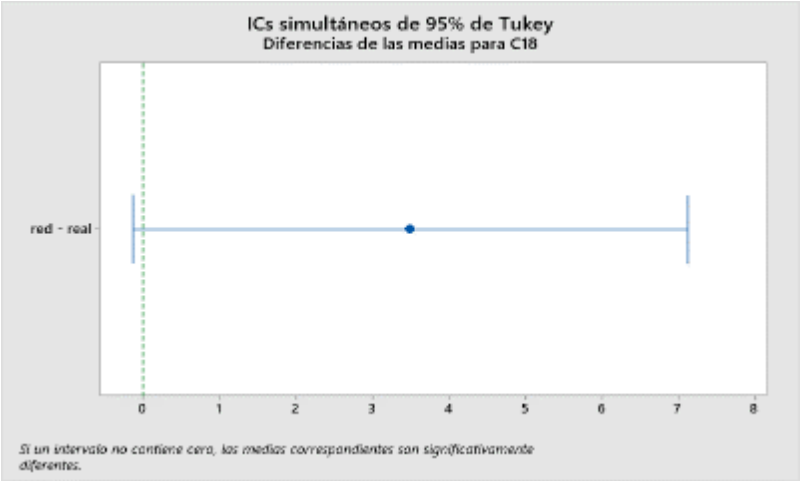

Figura 85. ANOVA para fallo con presión 10 psi. Fuente: Autores

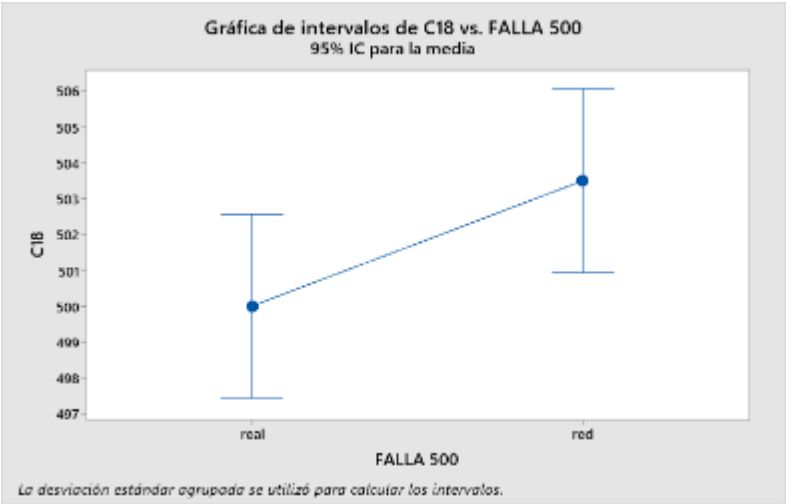

Figura 86.Intervalos de confianza para fallo con presión de 10 psi. Fuente: Autores

Se puede ver en la Figura 87 que los valores de las medias son significativamente iguales y comparten el mismo rango.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA

500	N	Media	Agrupación
red	22	503,49	A
real	22	500,0	A

Las medias que no comparten una letra son significativamente diferentes.

Figura 87. Agrupación de las medias para fallo con presión de 10 psi. Fuente: Autores

7.2.3 ANOVA para avería de presión de combustible a 33 psi.

Como se puede ver en las Figura 88 y Figura 89 la línea entrecortada se interseca con la línea de confianza e indica que las medias son estadísticamente iguales.

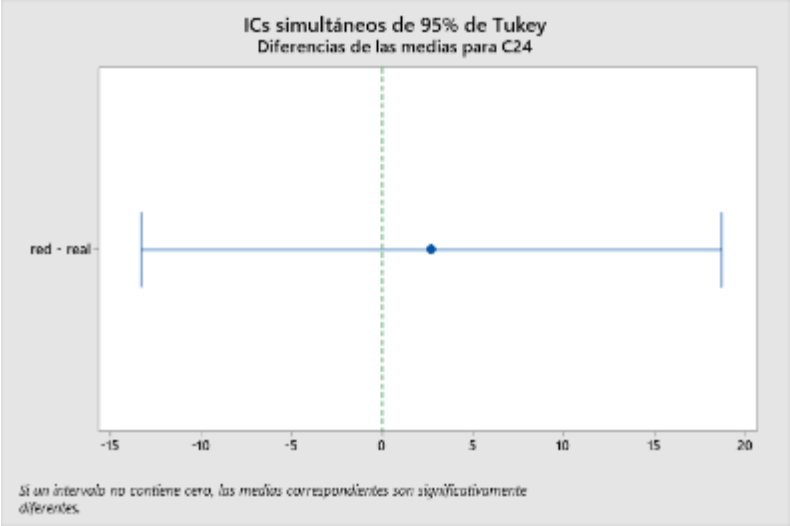

Figura 88.ANOVA para fallo con presión 33 psi. Fuente: Autores

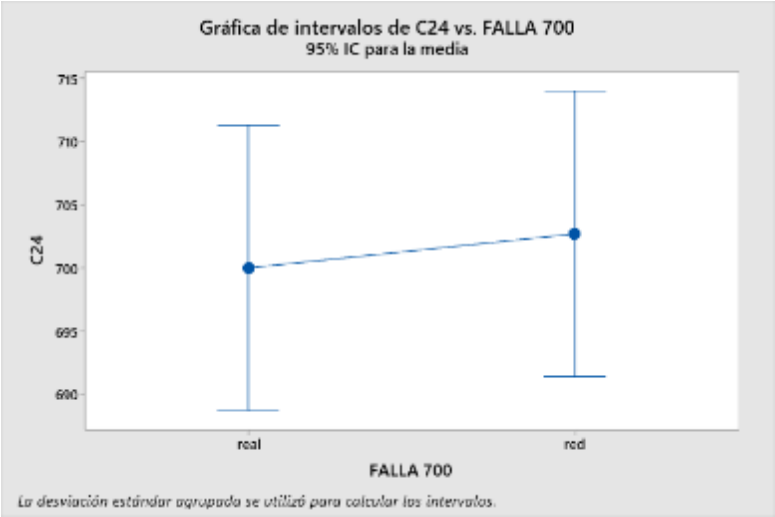

Figura 89. Intervalos de confianza para fallo con presión de 33 psi. Fuente: Autores

Se puede ver en la Figura 90 que los valores de las medias son significativamente iguales y comparten el mismo rango.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA 700	N	Media	Agrupación
red	20	702,70	A
real	20	700,0	A

Las medias que no comparten una letra son significativamente diferentes.

Figura 90 .Agrupación de las medias para fallo con presión de 33 psi. Fuente: Autores

7.2.4 ANOVA para avería de presión de combustible a 44.5 psi.

Como se puede ver en las Figura 91 Figura 92 la línea entrecortada se interseca con la línea de confianza e indica que las medias son estadísticamente iguales.

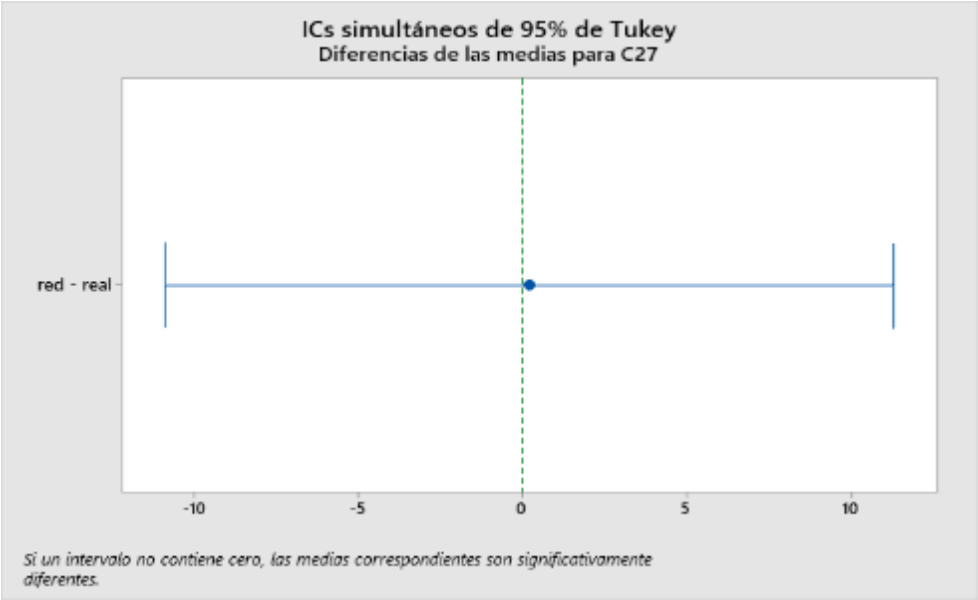

Figura 91..ANOVA para fallo con presión 44.5 psi. Fuente: Autores

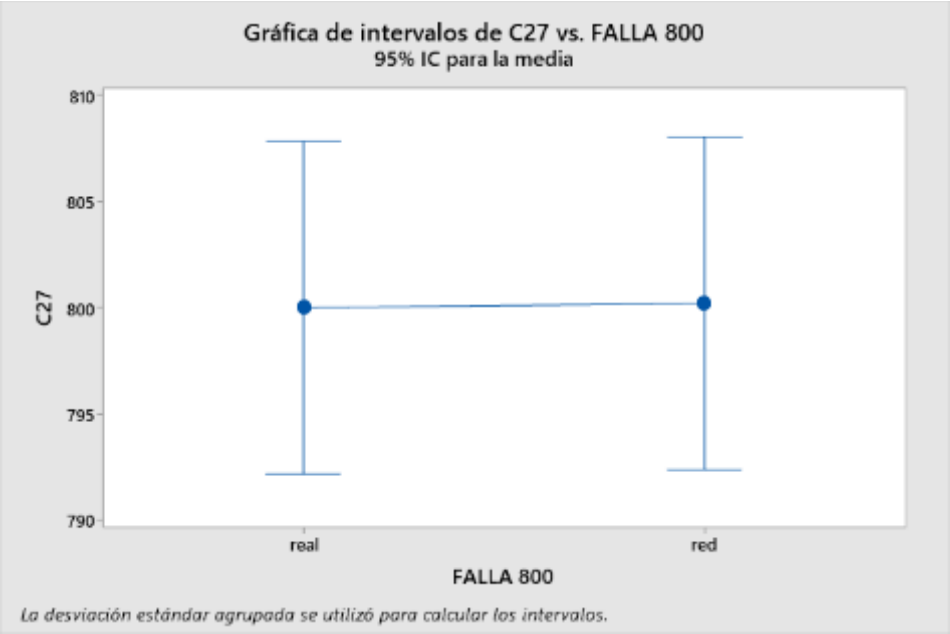

Figura 92.Intervalos de confianza para fallo con presión de 44.5 psi. Fuente: Autores

Se puede ver en la Figura 93 que los valores de las medias son significativamente iguales y comparten el mismo rango. Por lo que la respuesta de la RNA será favorable para mayor porcentaje de muestras.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA

800	N	Media	Agrupación
red	18	800,21	A
real	18	800,0	A

Las medias que no comparten una letra son significativamente diferentes.

Figura 93.Agrupación de las medias para fallo con presión de 44.5 psi. Fuente: Autores

7.2.5 ANOVA para la matriz general.

Como se puede ver en las Figuras 94 y 95 la línea entrecortada se interseca con la línea de confianza e indica que las medias son estadísticamente iguales. Por esta razón se demuestra que la red obtiene valores de respuesta favorables a cada condición del motor.

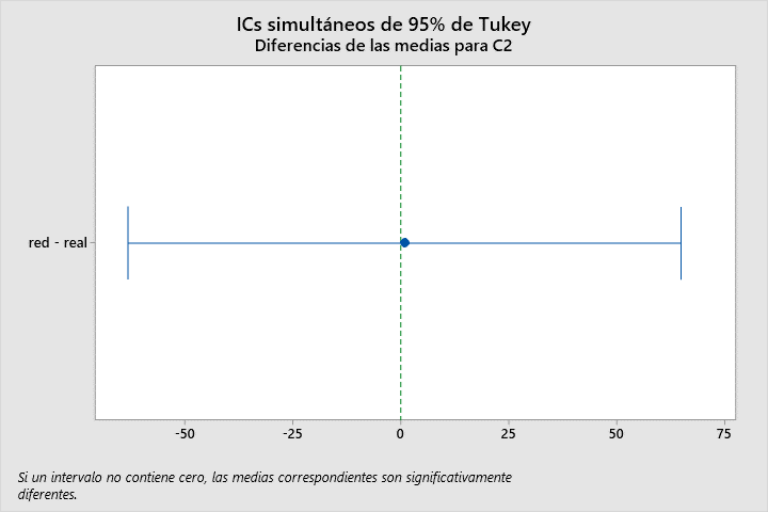

Figura 94.ANOVA para matriz general. Fuente: Autores

Como la desviación estándar de la muestra es mínima, se puede decir que el intervalo de confianza de la muestra se encuentra contemplado dentro del error del 5%.

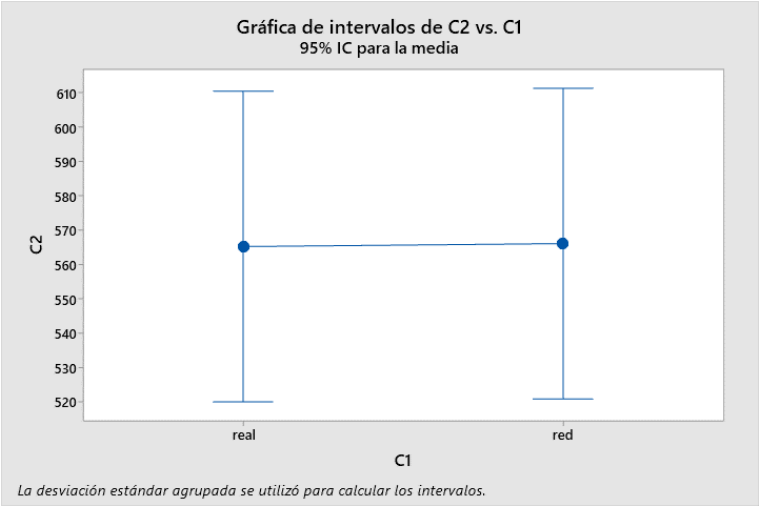

Figura 95.Intervalos de confianza para matriz general. Fuente: Autores

Se puede ver en la Figura 96 que los valores de las medias son significativamente iguales y comparten el mismo rango. Este parámetro garantiza el funcionamiento de la red para el mayor de los casos de análisis, pues el error se encuentra menor al 1%.

Agrupar información utilizando el método de Tukey y una confianza de 95%

C1	N	Media	Agrupación
red	313	566,0	A
real	313	565,2	A

Las medias que no comparten una letra son significativamente diferentes.

Figura 96.Agrupación de las medias para matriz general. Fuente: Autores

8. Conclusiones

- El sistema planteado es capaz de determinar el patrón de comportamiento del motor con respecto a las averías que se crearon bajo un protocolo supervisado, lo que afirma que el objetivo general de la investigación se ha desarrollado con éxito.
- En base al compendio bibliográfico y revisión sistemática de la literatura existente se determinaron las mejores condiciones de avería para el motor durante la experimentación, además se emplearon métodos comprobados como el análisis de varianzas y redes neuronales para el diseño del sistema de diagnóstico.
- La toma de datos se realizó con una frecuencia de muestreo de 10KH cumpliendo de esta manera con el criterio de Nyquist en donde se indica que la frecuencia mínima de muestreo debe ser al menos el doble de la original. Por ende, se tiene un proceso de adquisición de datos fiable.
- Para la creación de la red neuronal se realizaron enteramientos de varios tipos de red. Ello con el objetivo de conseguir una RNA que mejor se adapte a las condiciones requeridas para el experimento, de esta manera se reflejan los mejores resultados:
    - Tipo Newff con una función de transferencia trainscg, error del 3.88%.
    - Tipo Newff con una función de transferencia traincgb, error del 0.68%.

  En base al análisis de cada una de las redes se elige la que corresponde al menor error obtenido y de esta forma garantizar el correcto resultado del sistema de diagnóstico. El estudio realizado por el método de ANOVA permitió definir la validez de los resultados de la red frente a la condición del motor. Se demuestra además que existe similitud entre los valores reales y los valores de la res puesto que el valor obtenido para “p” se encuentra muy próximo a 1 (p =0.979). Por medio de la comparación de Tukey se determina que la mayoría de las medias comparten el mismo grupo, consecuentemente se valida la clasificación de los parámetros estadísticos.
- Con respecto a la fase de comprobación de la herramienta se corrobora el error esperado en la detección de las averías, presentándose confusión del sistema de diagnóstico al identificar la avería de los sensores O2 y TPS, sin embargo, se determina que este parámetro se encuentra dentro del rango de error. De esta manera se demuestra que los métodos no intrusivos de diagnóstico mediante programas computacionales como las redes neuronales son de gran utilidad dentro del esquema de diagnóstico automotriz, puesto que ayudan a optimizar los recursos empleados dentro de las técnicas de mantenimiento convencionales.

9. Recomendaciones

- Para futuras investigaciones se recomienda continuar con el desarrollo de esta investigación con el propósito de profundizar en el diagnóstico de nuevas averías que pueden presentarse en los MCIA.
- En próximas investigaciones se recomienda estudiar las señales del sensor CMP y CKP conjuntamente para obtener mejores resultados.
- Analizar otros métodos de inteligencia artificial como: Lógica difusa, Máquinas de soporte vectorial y Random Forest para la detección de averías dentro del campo automotriz como herramienta de comparación de resultados es un punto de partida para nuevas investigaciones.
- Se puede ampliar la investigación hacia el diagnóstico de averías del motor mediante el análisis de otro tipo de sensores que aporten información relevante de la condición de funcionamiento.
- Este trabajo se limita a la detección de fallas con el motor en ralentí, para futuras investigaciones se puede analizar el comportamiento del motor cuando este se encuentra en régimen transitorio y bajo condiciones de carga.
- Existen fallos del motor que involucran varios componentes o viceversa. De acuerdo con este planteamiento se recomienda implementar un sistema de diagnóstico que identifique fallos combinados.
- Se recomienda implementar un sistema de diagnóstico basado en redes neuronal que pueda ser empleado para cualquier MEP sin importar el fabricante al que pertenezca

10.Bibliografía

1. Ahmed, R et al. (2015). "*Automotive Internal-Combustion-Engine Fault Detection and Classification Using Artificial Neural Network Techniques*".
2. Alonso Pérez, J. M. (2000). *Técnicas del Automóvil Motores* (10.ª ed.). Paraninfo.
3. Alonso Pérez, J. M. (2009). *Técnicas del Automóvil Motores* (11.ª ed.). Paraninfo.
4. Arias, C. (2020)*Detección y Diagnóstico de Fallas en Rodamientos con Velocidad Variable Aplicando Aprendizaje Profund*o. https://reunir.unir.net/handle/123456789/10700
5. Asanza, W. & Mazón, O. (2018). *Redes neuronales* artificiales *aplicadas al reconocimiento de patrones*. UTMACH. http://repositorio.utmachala.edu.ec/handle/48000/12499
6. Autocosmos. (2011, enero 21). *GM Daewoo cambia de nombre a Chevrolet en Corea.* Autocosmos. https://noticias.autocosmos.com.mx/2011/01/21/gm-daewoo-cambia-de-nombre-a-chevrolet-en-cor
7. Basogain, X. (2019). *Redes Neuronales Artificiales y sus Aplicaciones* (1.ª ed.). Escuela Superior de Ingeniería de BIlbao. https://d1wqtxts1xzle7.cloudfront.net/38647082
8. Bolaños, D. (2007). *Planificación y programación del mantenimiento del parque automotor del departamento de obras públicas del ilustre municipio de Latacunga, mediante el uso de normas ISO 9000*. Repositorio de la Escuela Politécnica del Ejercito. http://repositorio.espe.edu.ec/bitstream/21000/3858/1/T-ESPEL-0235.pdf
9. Burgos, B. & Freire, E. (2008). A*nálisis de fallas atípicas ocurridas en motores de combustión interna, tanto estacionarios como móviles, del Ecuador*. Repositorio institucional de la Escuela Politécnica Nacional. http://bibdigital.epn.edu.ec/handle/15000/667
10. Buqué, R & Maroto, A (1997). *El análisis de la varianza (ANOVA).* Universidad Rovira i Virgili.
11. Carrera, D., & Paredez, A. (2020). *Diseño y construcción de un banco de pruebas para filtros de aire de distintas marcas de vehículos*. https://repositorio.uide.edu.ec/handle/37000/4349.
12. Contreras, W.& Fajardo, J. (2015). *Diseño y construcción de un sistema prototipo para determinar la cilindrada total de un motor ciclo Otto por un método no*

invasivo mediante Labview. [Escuela Politécnica Nacional] http://bibdigital.epn.edu.ec/handle/15000/12298

13. Contreras Urgilés, Wilmer, Maldonado Ortega, José, & León Japa, Rogelio. (2019).*Application of feed-forward backpropagation neural network for the diagnosis of mechanical failures in engines provoked ignition*, (21), https://doi.org/10.17163/ings.n21.2019.03
14. Delgado, E. (2018). *Desarrollo de un algoritmo de diagnóstico para la detección de fallas mecánicas en motores de encendido provocado basados en la transformada Wavelet*. http://dspace.ups.edu.ec/handle/123456789/15300
15. Escuder, M. (2016). *Estudio del desequilibrio de un motor de 6 cilindros en V*. Universidad Politécnica de Cataluña.
16. Exxotest, E. (2018). *Measuring Engine Speed and Crankshaft Position.* Francia: Exxotest Education. Recuperado de https://exxotest.com/wp-content/uploads/2018/03/GU_DT-M006_EN.pdf
17. FuelTech. (2015). *Rueda Fónica Construcción e Instalación y Calibrado de la Ignición*. Issuu. https://issuu.com/fueltechargentina/docs/rueda_f__nica_construcci__n_e_insta
18. Garzón, G., Urdiales, M. (2017). *Diseño e implementación de un sistema para determinar fallas mecánicas en motores de encendido provocado mediante redes neuronales artificiales.* https://dspace.ups.edu.ec/handle/123456789/14397
19. GMSA Chevrolet. (2011). *Manual del propietario de Chevrolet Aveo*. GMSA. https://www.chevrolet.com.ec/content/dam/chevrolet/south-america/ecuador/espanol/index/matenimiento/manuales/01-pdf/manual-spark-gt.pdf
20. Gómez, S. (2018). *Análisis tensional de un cigüeñal de un MCIA mediante elementos finitos*. https://repositorio.unican.es/xmlui/bitstream/handle/10902/14692/410584.pdf;jsessionid=68E8A7B39A7C0B00B38E754395162329?sequence=1
21. Gualán, P., & Ordoñez, J. (2012). *Variacion del rendimiento de un motor A12, al implementar un sistema de inyección electronica MPFI* [Universidad del Azuay]. http://dspace.uazuay.edu.ec/bitstream/datos/1441/1/09609.pdf
22. Gutiérrez, E., & Vladimirovna, O. (2016). *Estadística Inferencial 1 para ingeniería y ciencias* (1.ª ed.). Grupo Editorial Patria.

23. Higuera, J. (2006). *Diagnóstico de fallas en motores térmicos mediante el análisis de la variación de la* velocidad *angular*. Universidad Industrial de Santander
24. Hilera González, J., & Martínez Hernando, V. (1995). *Redes neuronales artificiales*. Ra-ma.
25. Hua, M Q et al. (2011). *"Fault Diagnosis of Electronic Controlled Engine by Using Oxygen Sensor*". En: Measuring Technology and Mechatronics Automation (ICMTMA), 2011 Third International Conference
26. Hurtado, J., Morocho, J., & Pinguil, J. (2014). *Desarrollo de un algoritmo para el diagnóstico del estado porcentual del rendimiento de los cilindros, mediante el análisis de la señal del sensor de posición del cigüeñal de un motor Nissan FD 6 cilindros*. https://dspace.ups.edu.ec/handle/123456789/6975
27. Isermann, R. (1995). *Model base fault detection and diagnosis methods.* Proceedings of 1995 American Control Conference - *ACC'95, 3*, 1605-1609 vol.3.
28. Isermann, R. (2011). *Terminology in fault detection and diagnosis.*
29. Jafari, S M, H Mehdigholi, and M Behzad (2014). "V*alve Fault Diagnosis in Internal Combustion Engines Using Acoustic Emission and Artificial Neural Network*".
30. León, R., & Maldonado, J. (2018). *Identificación de patrones de fallas mecánicas mediante redes neuronales artificiales para el diagnóstico de motores de encendido provocado*. http://dspace.ups.edu.ec/handle/123456789/16161
31. Minitab. (2019). *¿Qué es ANOVA?* [Mtbconcept]. Soporte de Minitab. https://support.minitab.com/es-mx/minitab/18/help-and-how-to/modeling-statistics/anova/supporting-topics/basics/what-is-anova/
32. Moreno, O. (2015). *Diseño e implementación de un prototipo para una interfaz humano-maquina del sistema de encendido electronico DIS como apoyo de las materias electivas I y II de Sistemas Industriales.* [Universidad Politécnica Salesiana]. http://dspace.ups.edu.ec/handle/123456789/10176
33. Moreira, M. & Suquillo, W.& Meza, M. (2017). *Estudio comparativo de las variables en sensores de posición.* [Universidad Internacional del Ecuador] https://repositorio.uide.edu.ec/bitstream/37000/2189/1/T-UIDE-1598.pdf?fbclid=IwAR3IpAAXz2oiRVXeA5T0_Yly659ldDOvpJbSCJ2l1fA1MO9DZjhN-BRK6rY

34. Namburu, Setu (1999). “S*istematic data-driven approach to real-time fault detection and diagnosis in automotive engines*”.
35. National Instruments. (2021a). *¿Qué es LabVIEW?* Productos. https://www.ni.com/es-cr/shop/labview.html
36. National Instruments. (2021b). *USB-6212*. https://www.ni.com/es-cr/support/model.usb-6212.html
37. Norton, R. (2012). *Diseño de maquinaria*. McGraw-Hill.
38. Payri González, F., & Desantes Fernández, J. M. (2014). *Motores de combustión interna alternativos*. Reverté ; Universitat Politècnica de València.
39. Ponce, P. (2010). *Inteligencia Artificial con Aplicaciones a la Ingeniería.* (1.ª ed.). Alfaomega Grupo.
40. Rt, L. R. (2015). *EFI R1000*. http://www.racetec.com.ar/files/Manual_EFI_R1000.pdf
41. Sánchez, E. (2011). *Sistemas Auxiliares del Motor*. Macmillan Iberia, S.A. https://bibliotecas.ups.edu.ec:3488/es/ereader/bibliotecaups/52815
42. SANGYONG, (2015). *Service manual.* China: SANGYONG Motors. http://neon.lofis.net/SsangYong/Service_Manuals/Rexton/RextonA1F204001.pdf
43. *SENSOR IAT | Guía 2020 | Funcionamiento y fallas*. (2019, enero 8). Sensor automotriz. https://sensorautomotriz.com/sensor-iat/
44. *SENSOR TPS | Guía 2020 | Funcionamiento y fallas*. (2019, enero 2). Sensor automotriz. https://sensorautomotriz.com/sensor-tps/
45. Universidad Politécnica Salesiana. (2019). *Pruebas en el sistema de alimentacion de combustible.* https://automotrizenvideo.com/wp-content/sp-resources/forum-file-uploads/adriangalindo/2012/11/Comprobacion-sistema-de-Combustible.pdf
46. Sharkey, A. (1999). Combining Artificial Neural Nets: Ensemble and Modular Multi-Net Systems.
47. Vidal, K., & Moreira, M. (2014). *DISEÑO Y CONSTRUCCIÓN DE UN BANCO DE ENTRENAMIENTO PARA* DIAGNÓSTICO *DE SENSORES AUTOMOTRICES*.
48. Wu, Jian-Da and Chiu-Hong Liu (2009a). “*An expert system for fault diagnosis in internal combustion engines using probability neural network*”.

11.Anexos.

Anexo 1: Unidad Experimental

Figura A. 1 Vehículo para experimentación. Fuente: Autores

Figura A. 2 Motor Daewoo GM. Fuente: Autores

Anexo 2. Señales temporales correspondientes a cada falla mecánica.

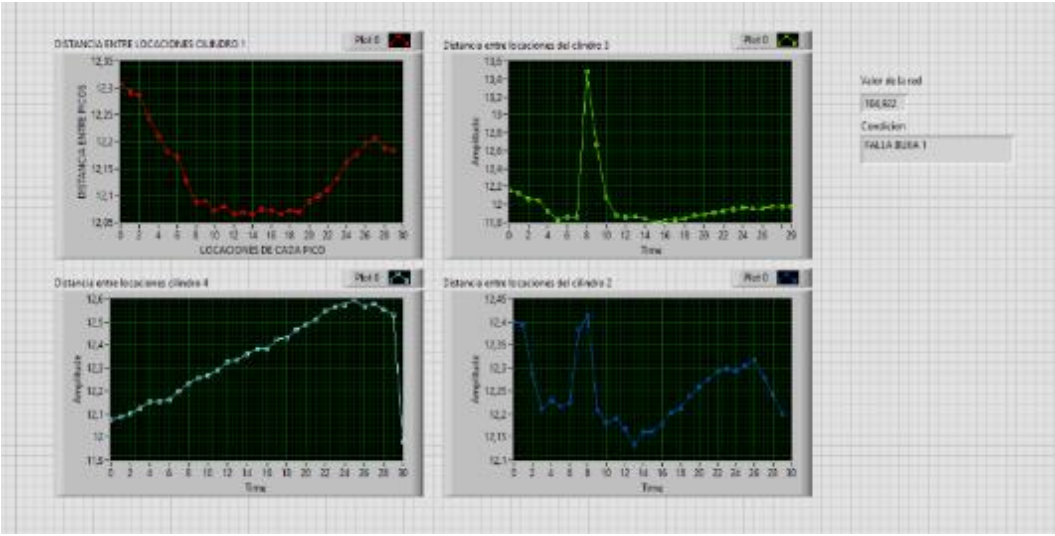

Figura A. 3 Patrón para falla 100 (1). Fuente: Autores.

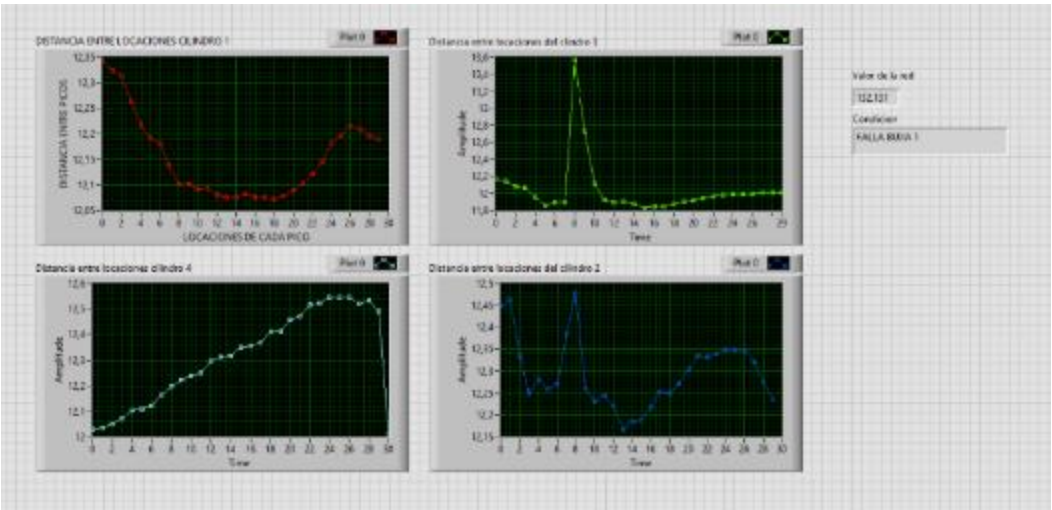

Figura A. 4 Patrón para falla 100 (2). Fuente: Autores.

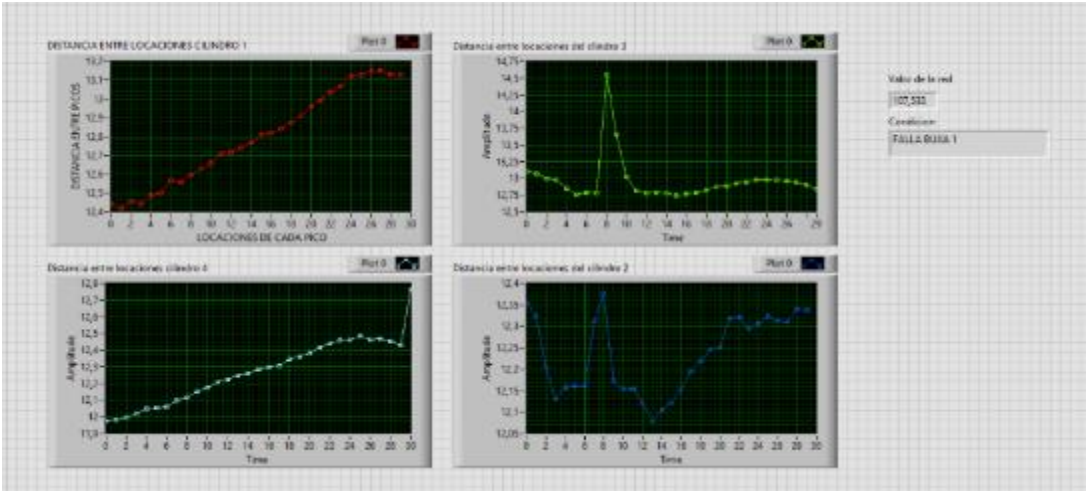

Figura A. 5. Patrón para falla 100 (3). Fuente: Autores.

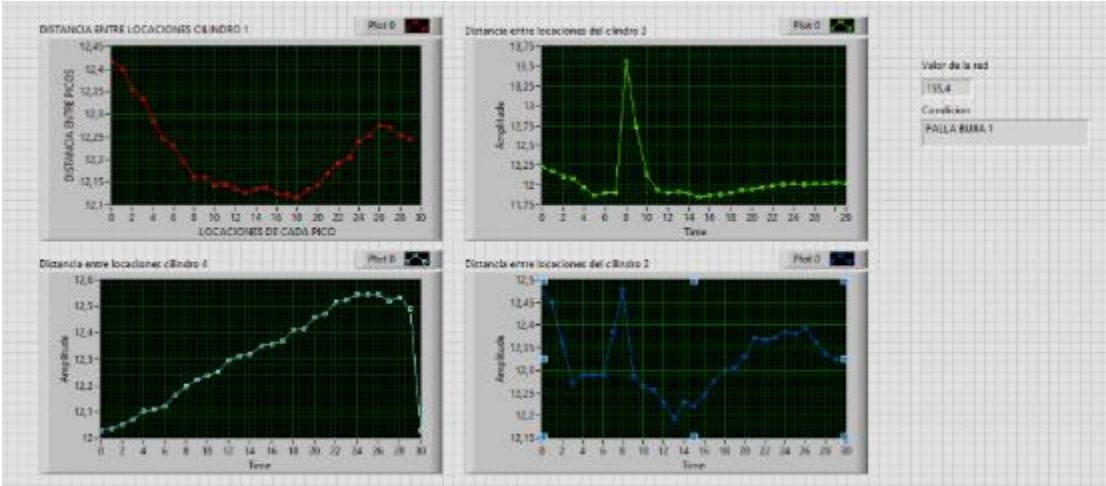

Figura A. 6 Patrón para falla 100 (4). Fuente: Autores.

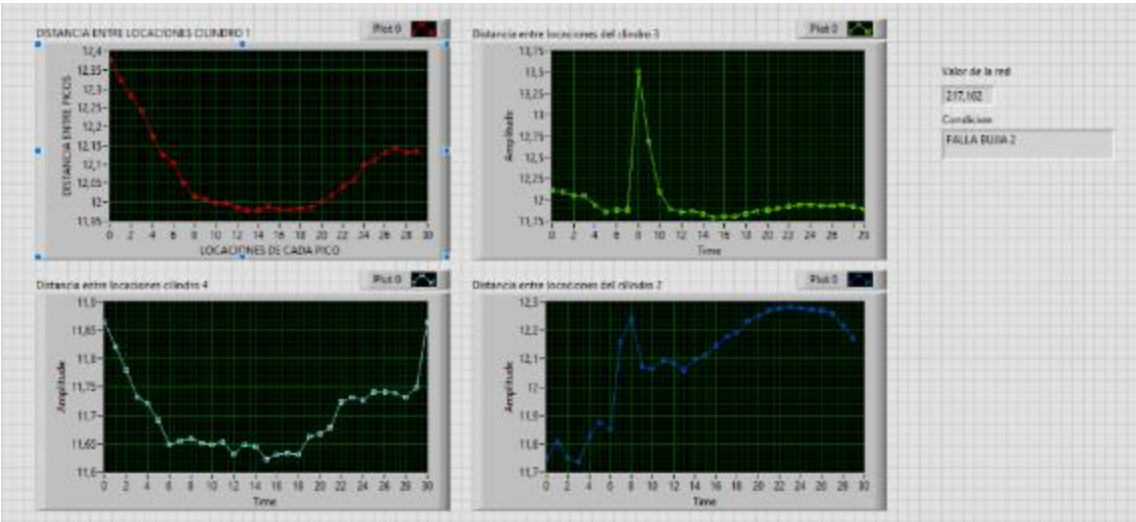

Figura A. 7. Patrón para falla 200 (1). Fuente: Autores.

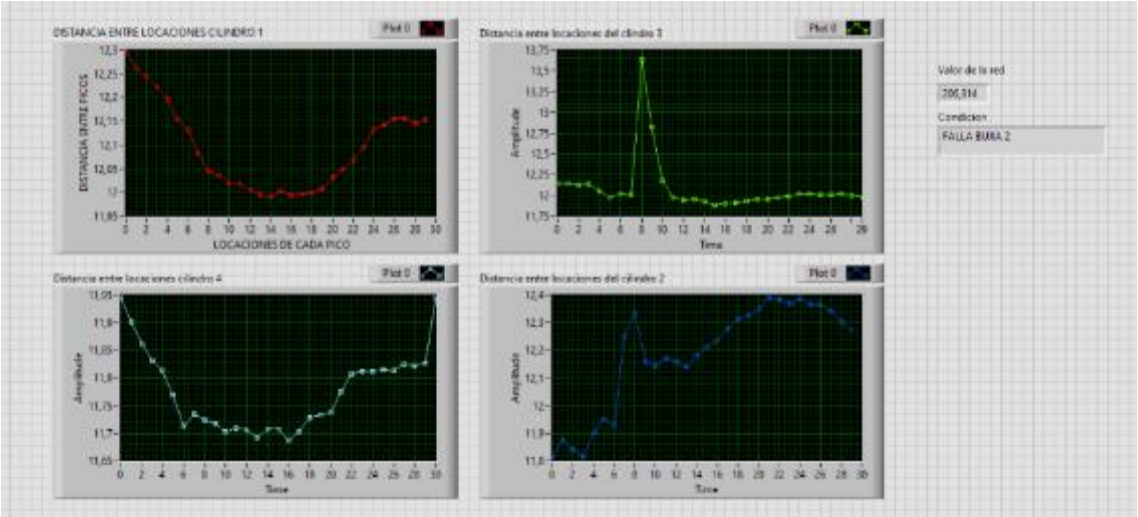

Figura A. 8.Patrón para falla 200 (2). Fuente: Autores.

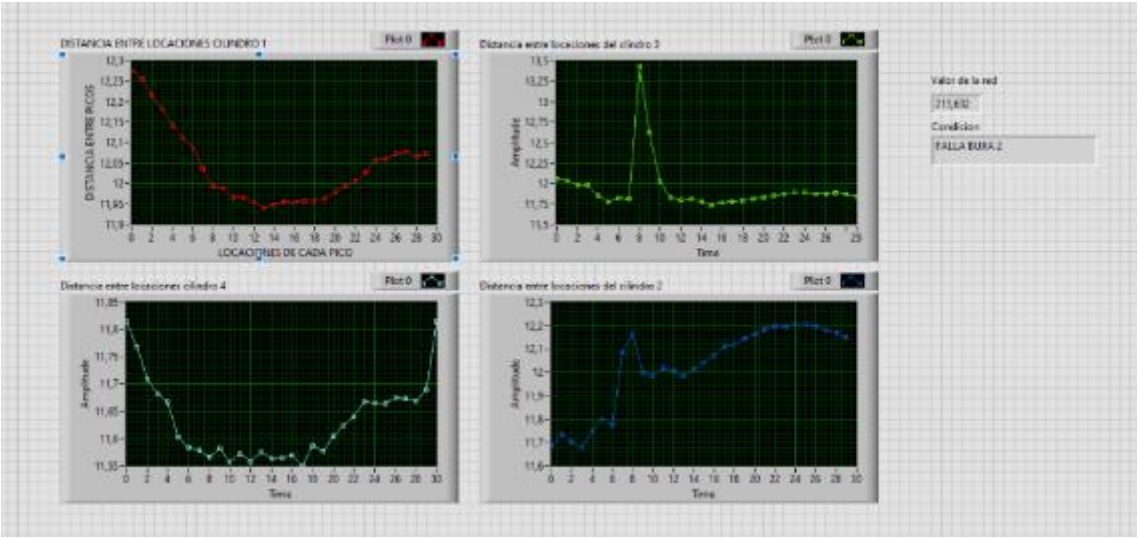

Figura A. 9.Patrón para falla 200 (3). Fuente: Autores.

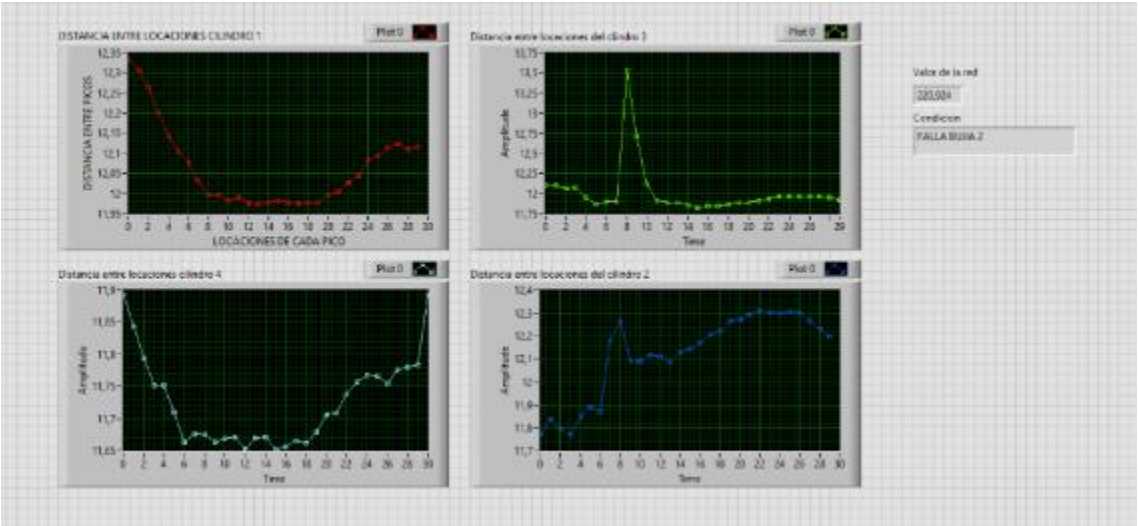

Figura A. 10.Patrón para falla 200 (4). Fuente: Autores.

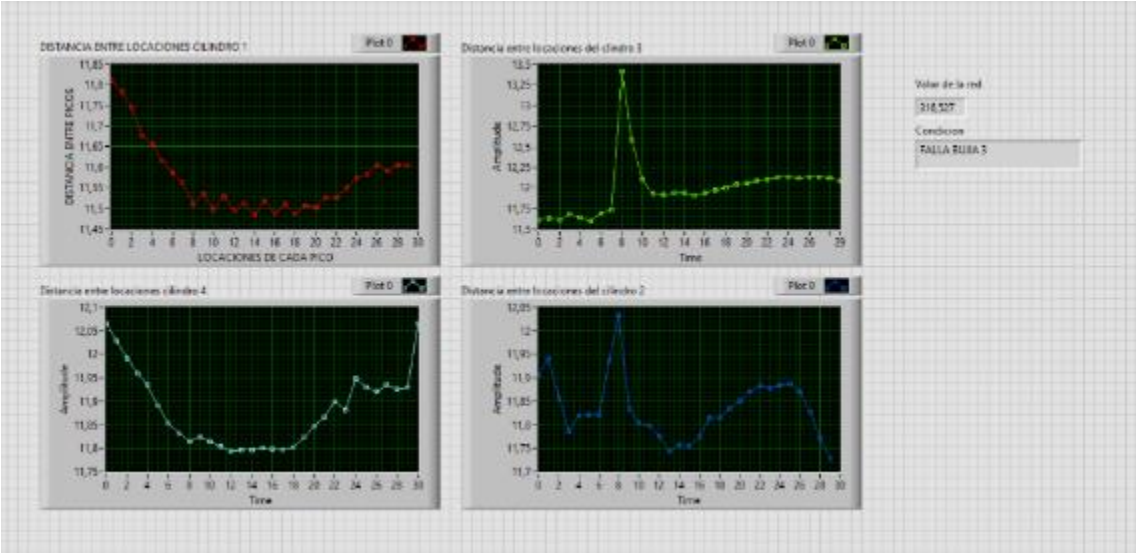

Figura A. 11.Patrón para falla 300 (1). Fuente: Autores.

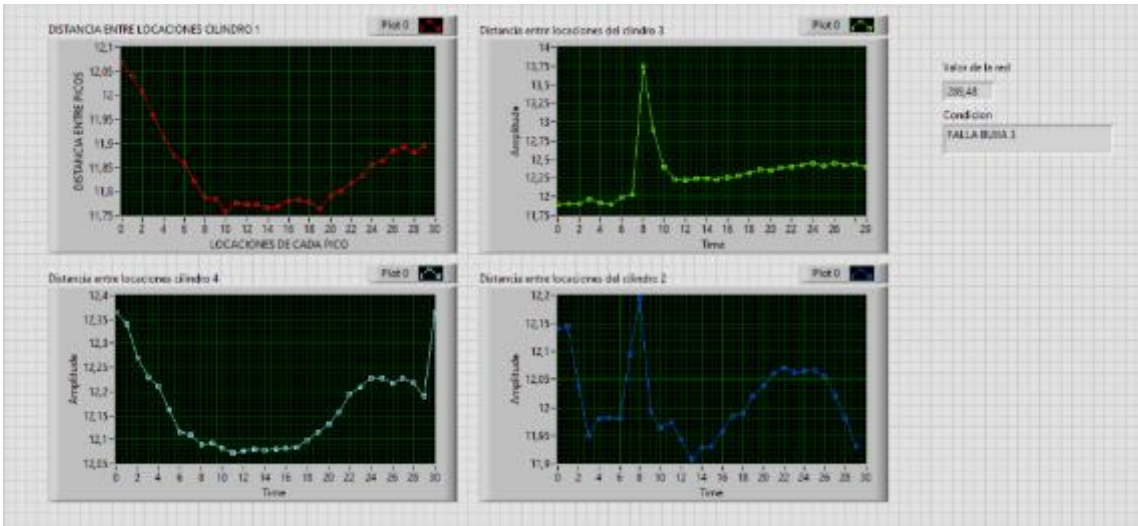

Figura A. 12.Patrón para falla 300 (2). Fuente: Autores.

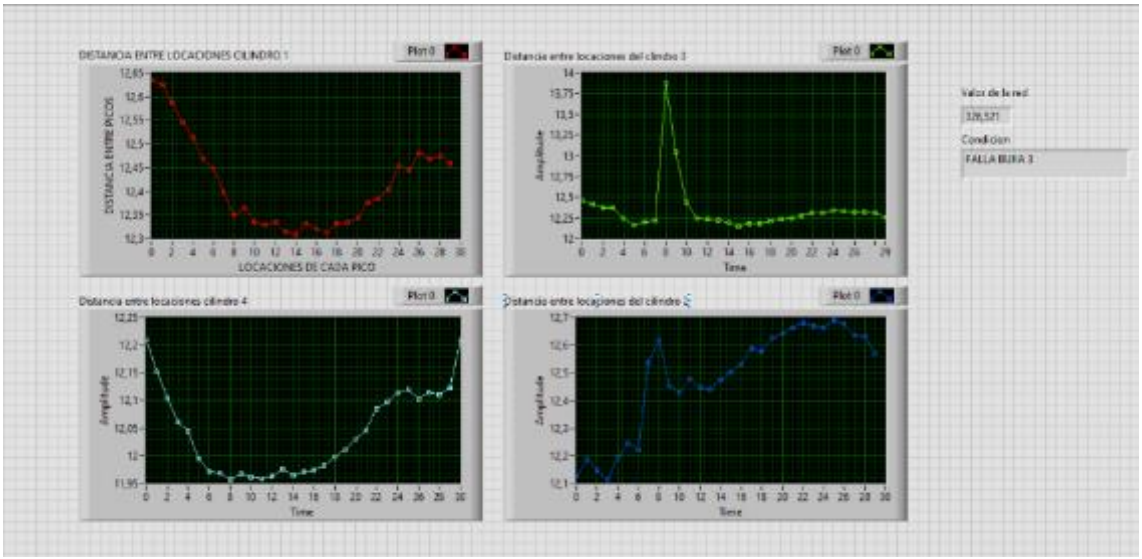

Figura A. 13.Patrón para falla 300 (3). Fuente: Autores.

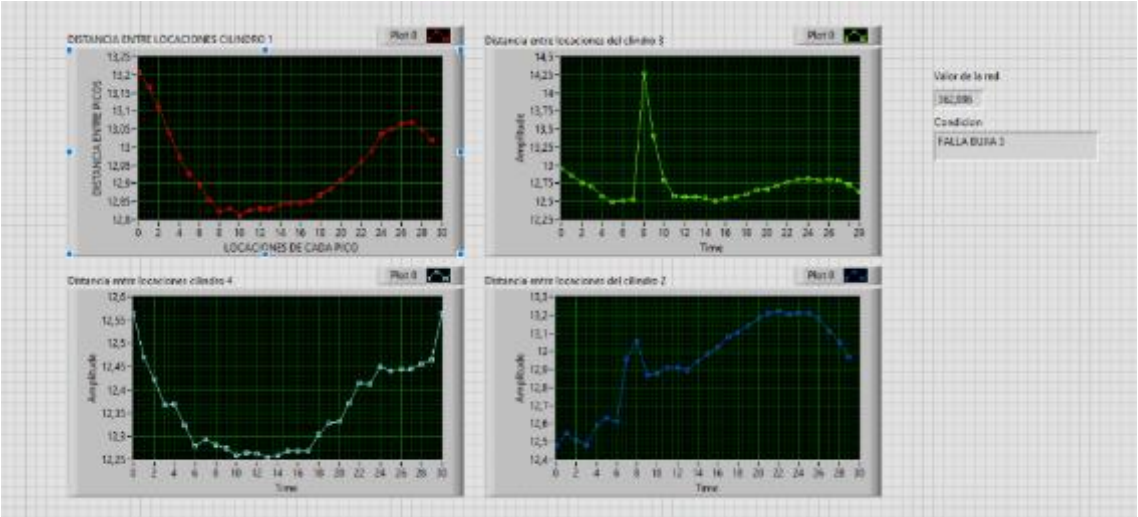

Figura A. 14.Patrón para falla 300 (4). Fuente: Autores.

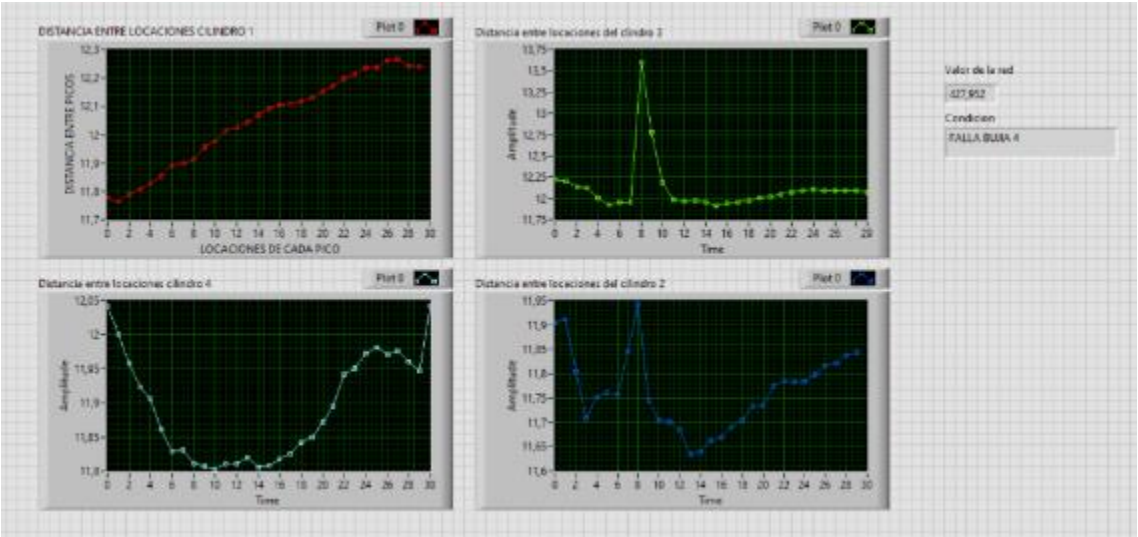

Figura A. 15. Patrón para falla 400 (1). Fuente: Autores.

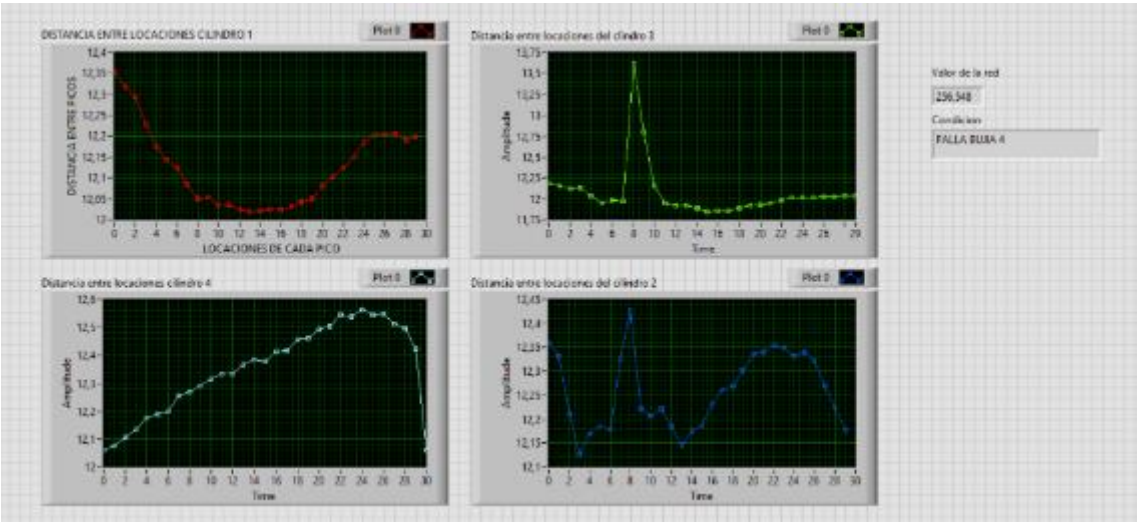

Figura A. 16.Patrón para falla 400 (2). Fuente: Autores.

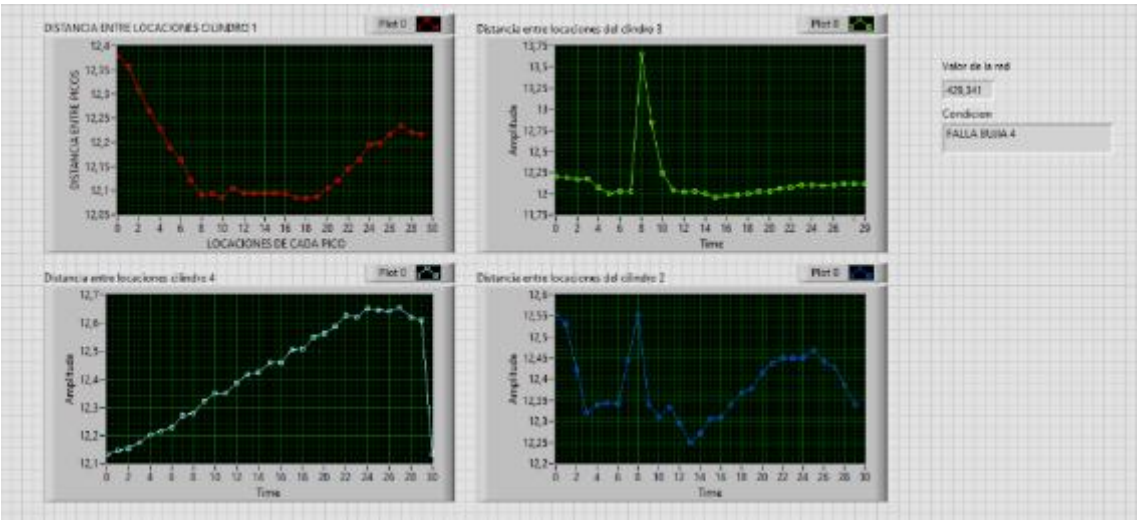

Figura A. 17.Patrón para falla 400 (3). Fuente: Autores.

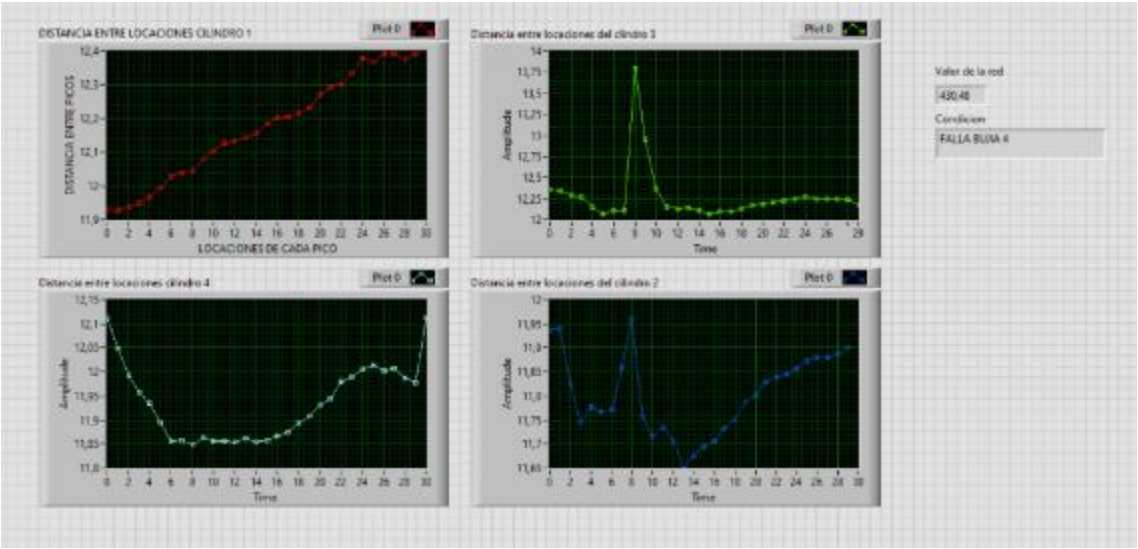

Figura A. 18. Patrón para falla 400 (4). Fuente: Autores.

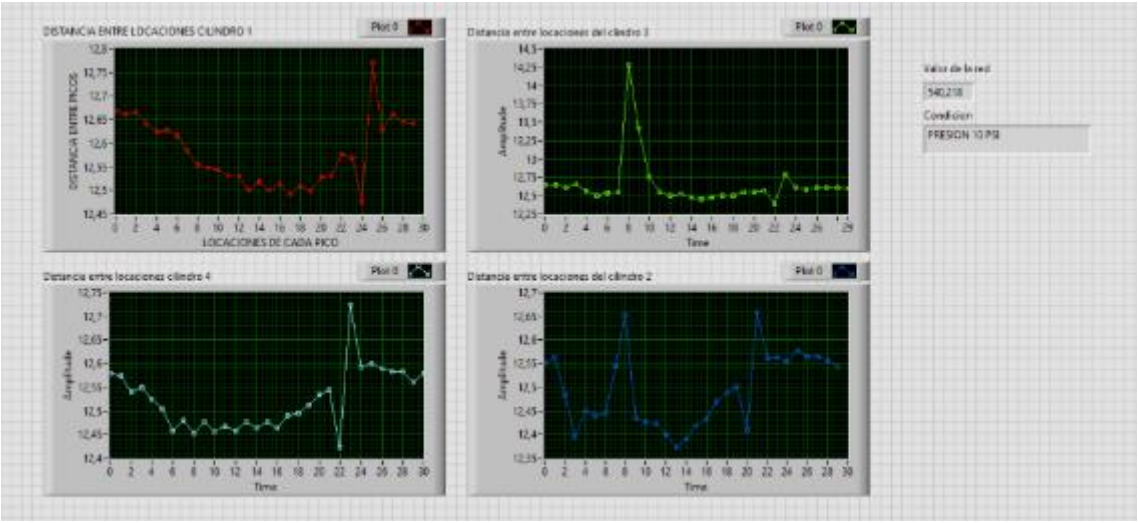

Figura A. 19. Patrón para falla 500 (1). Fuente: Autores.

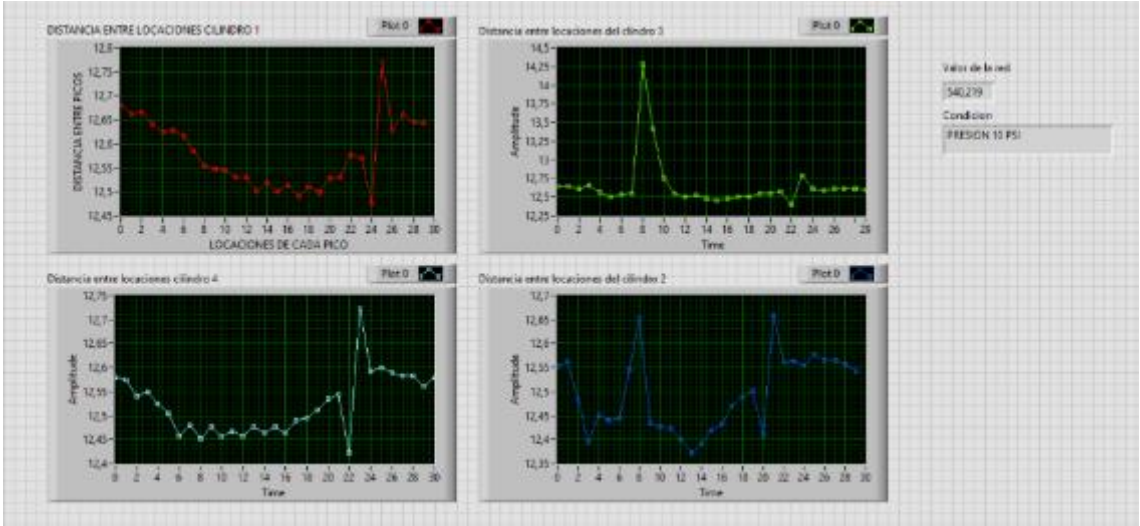

Figura A. 20.Patrón para falla 500 (2). Fuente: Autores.

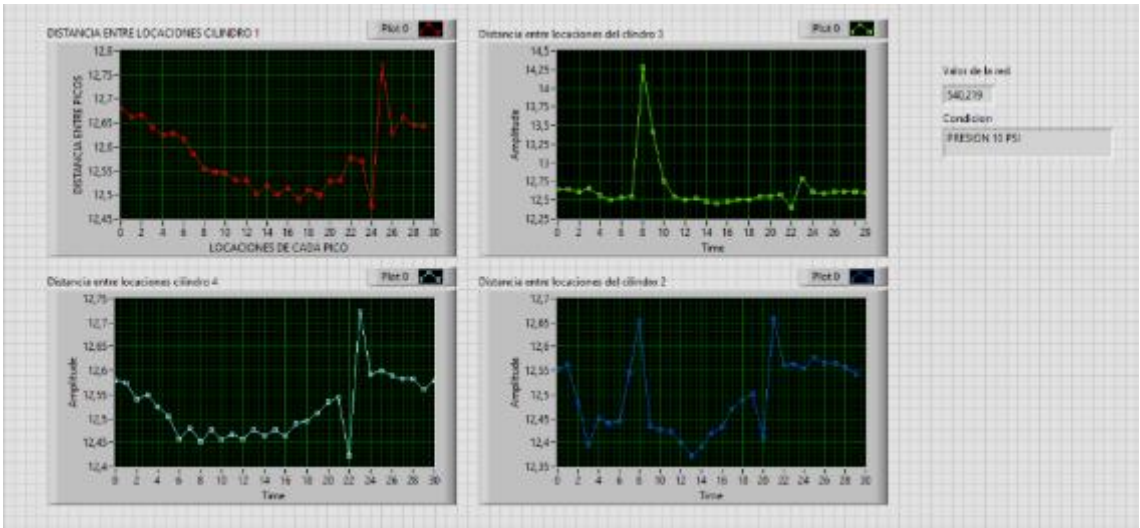

Figura A. 21Patrón para falla 500 (3). Fuente: Autores.

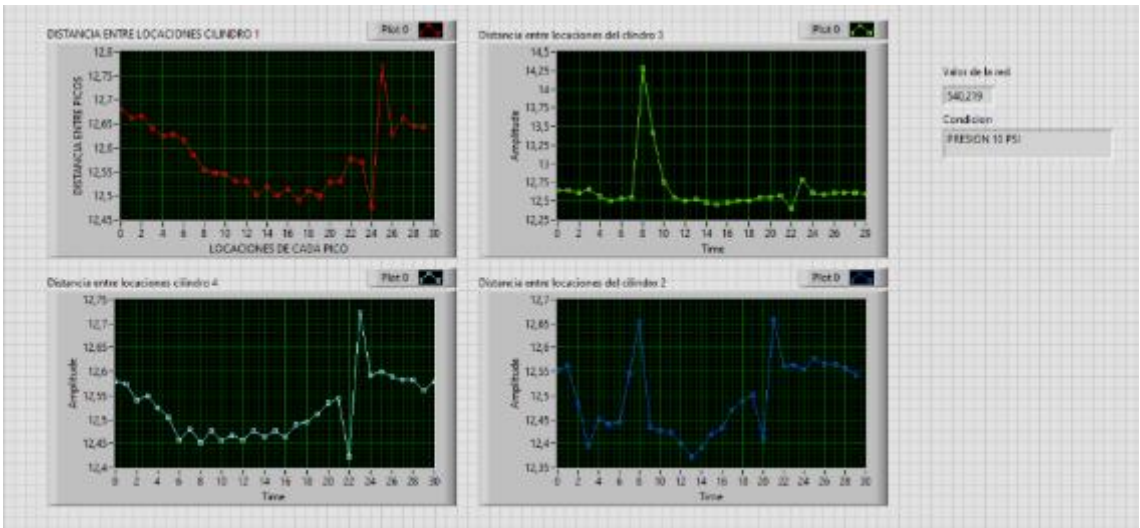

Figura A. 22.Patrón para falla 500 (4). Fuente: Autores.

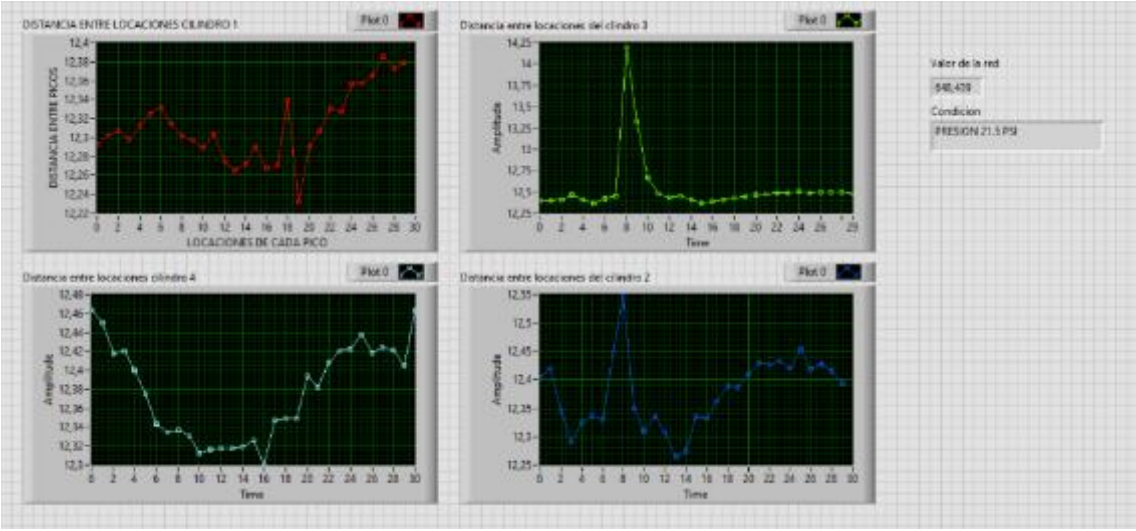

Figura A. 23.Patrón para falla 600 (1). Fuente: Autores.

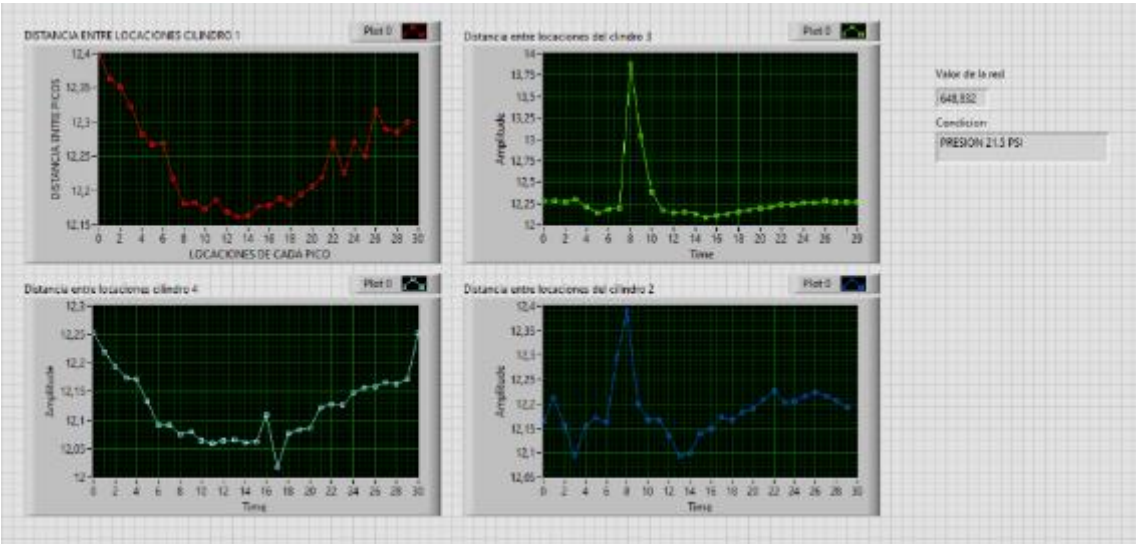

Figura A. 24.Patrón para falla 600 (2). Fuente: Autores.

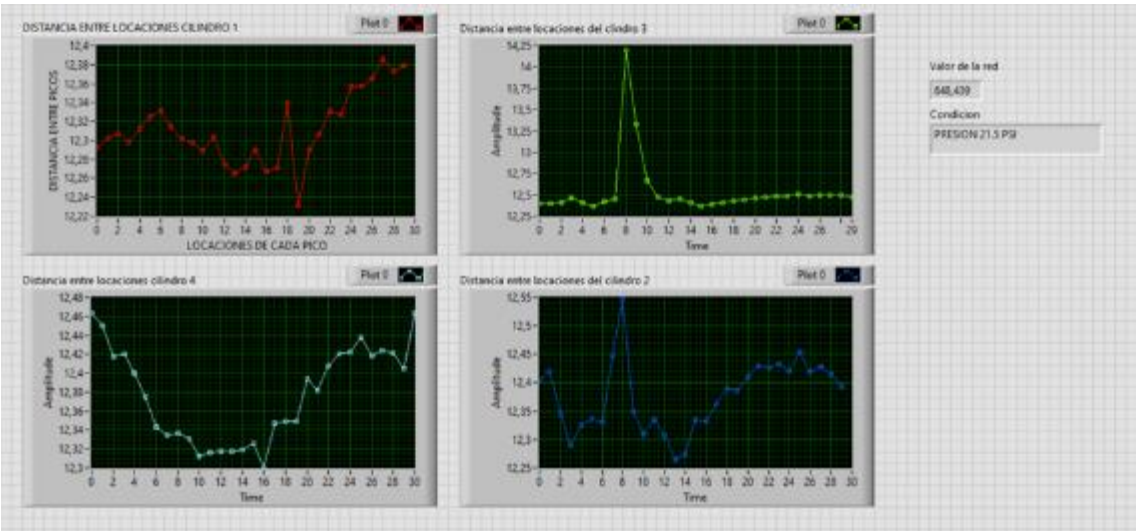

Figura A. 25.Patrón para falla 600 (3). Fuente: Autores.

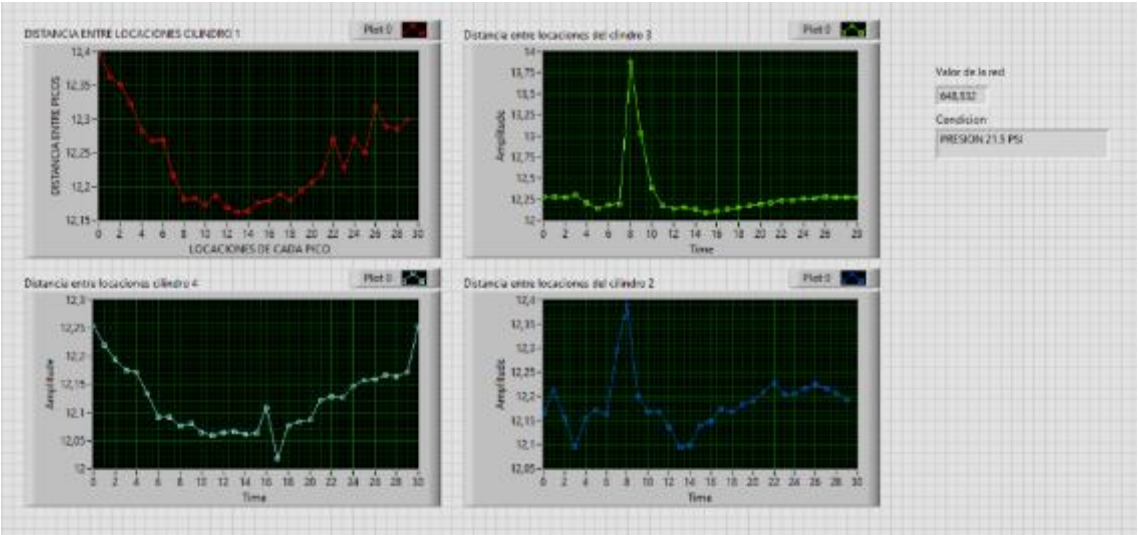

Figura A. 26.Patrón para falla 600 (4). Fuente: Autores.

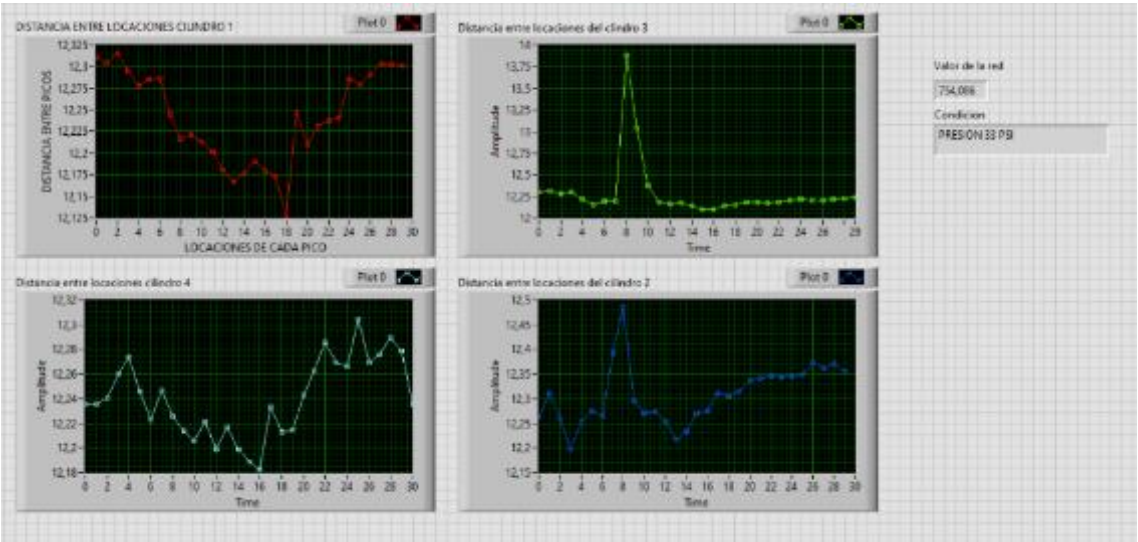

Figura A. 27.Patrón para falla 700 (1). Fuente: Autores.

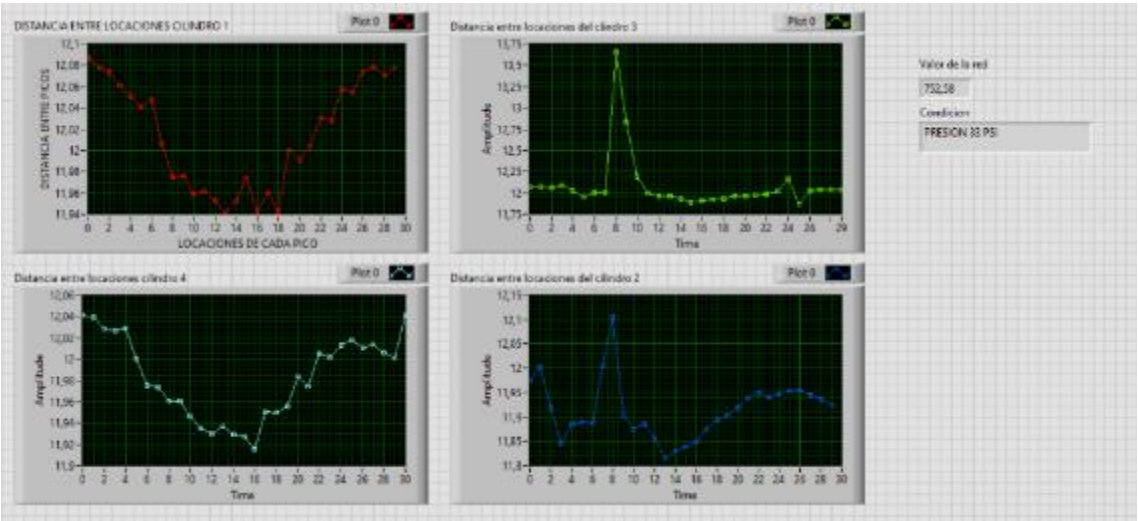

Figura A. 28 Patrón para falla 700 (2). Fuente: Autores.

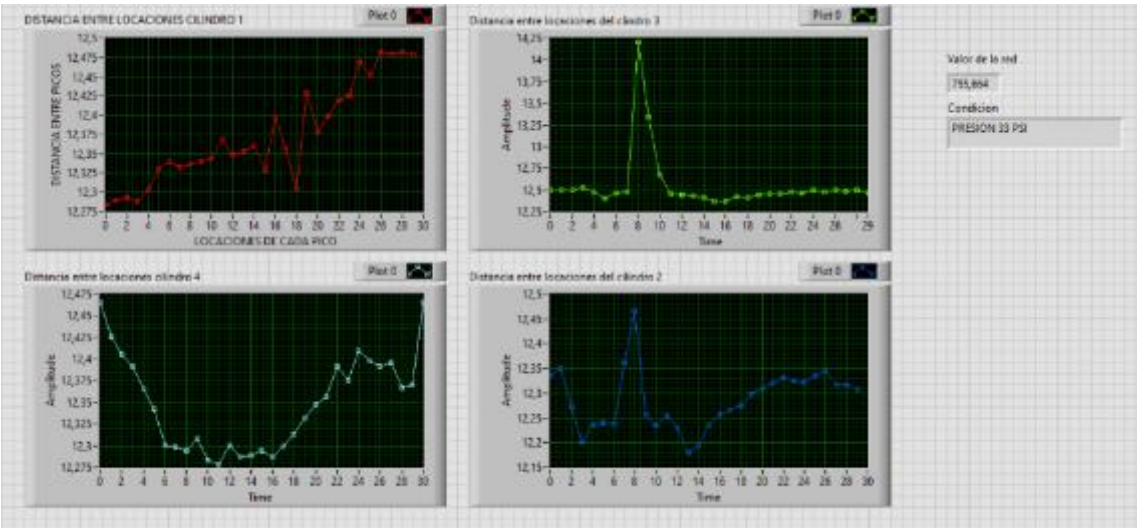

Figura A. 29.Patrón para falla 700 (3). Fuente: Autores.

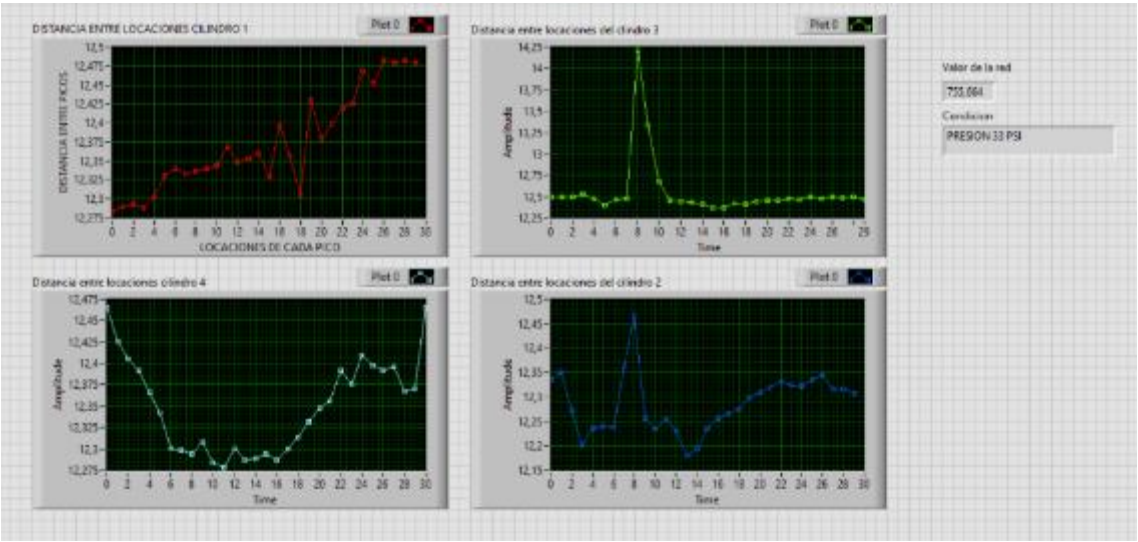

Figura A. 30.Patrón para falla 700 (4). Fuente: Autores.

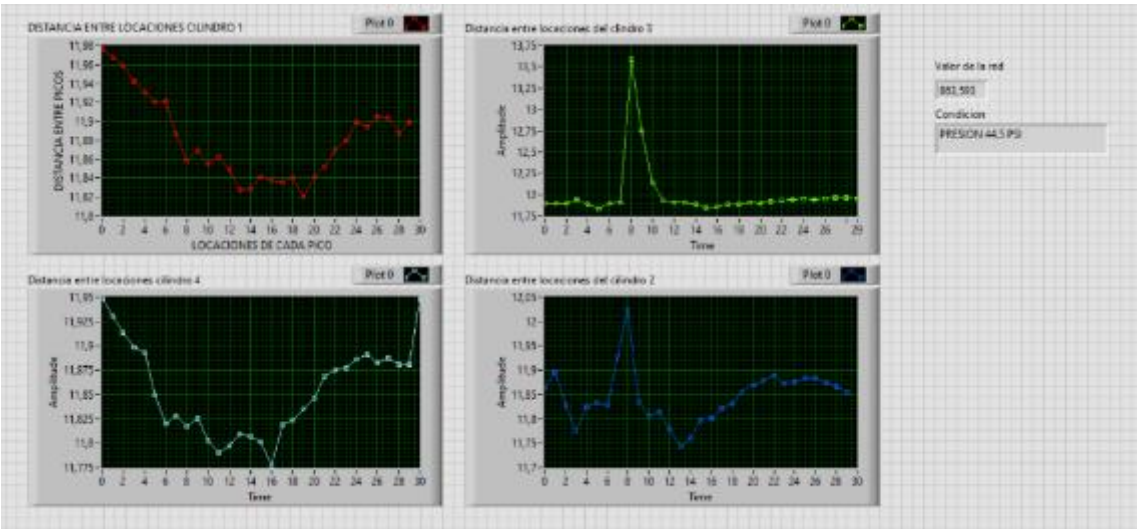

Figura A. 31. Patrón para avería 800 (1). Fuente: Autores.

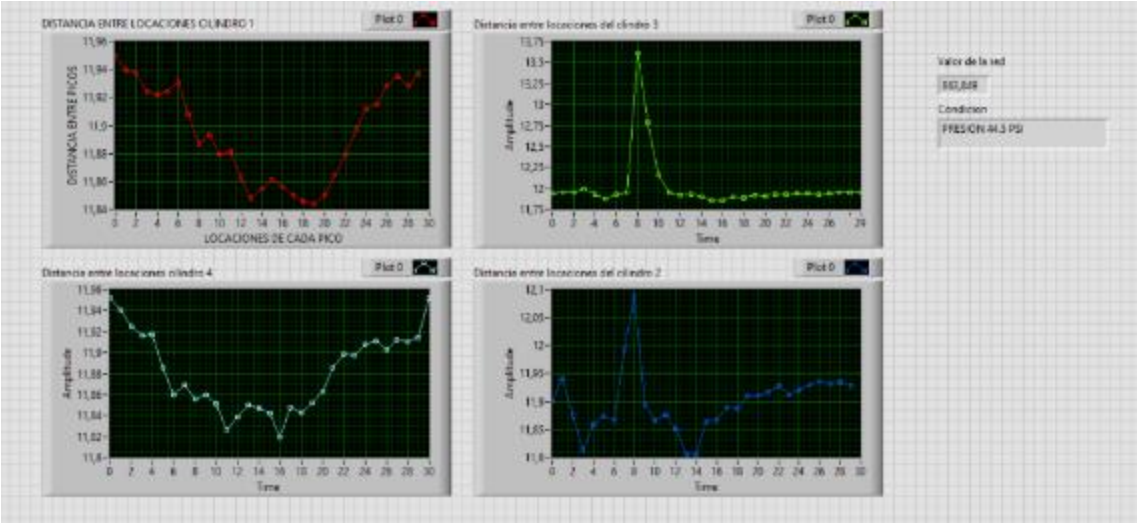

Figura A. 32.Patrón para fallo 800 (2). Fuente: Autores.

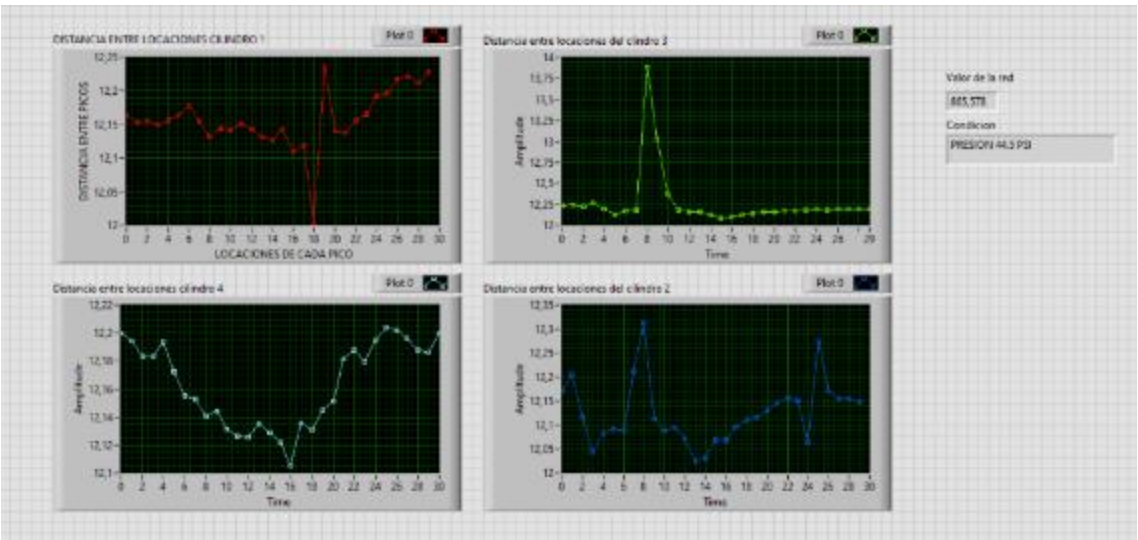

Figura A. 33.Patrón para fallo 800 (3). Fuente: Autores.

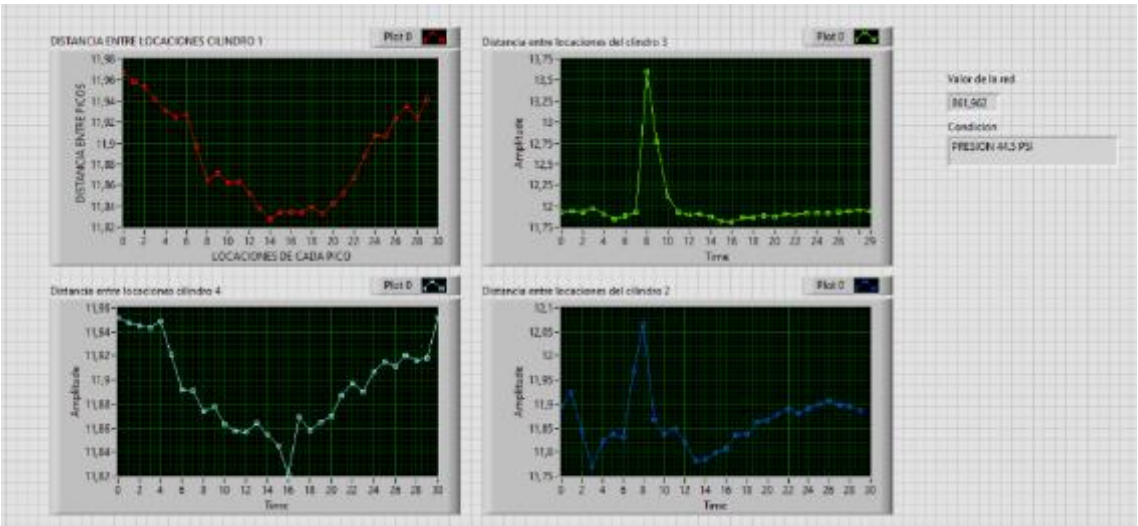

Figura A. 34. Patrón para fallo 800 (4). Fuente: Autores.

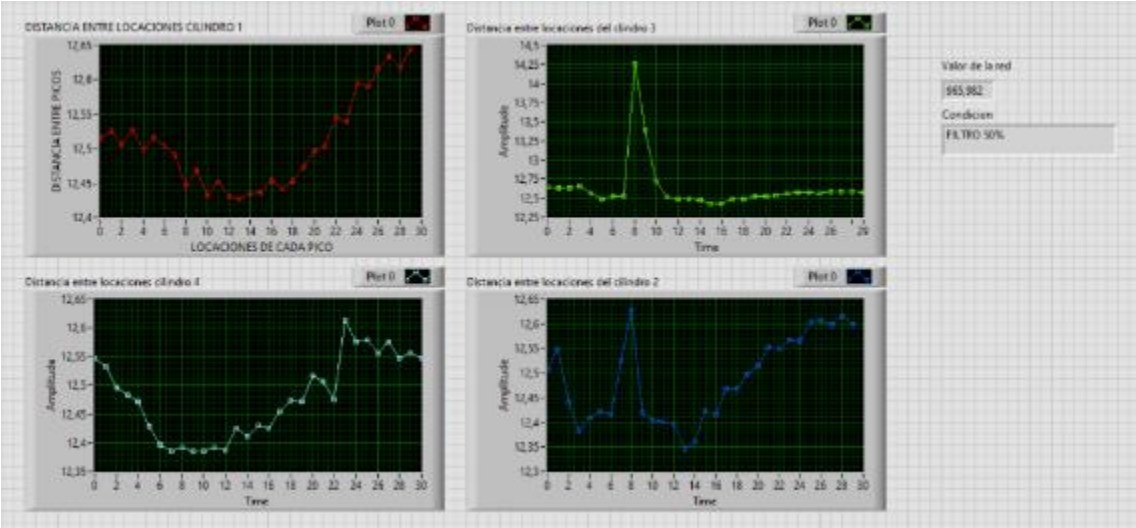

Figura A. 35.Patrón para fallo 900 (1). Fuente: Autores.

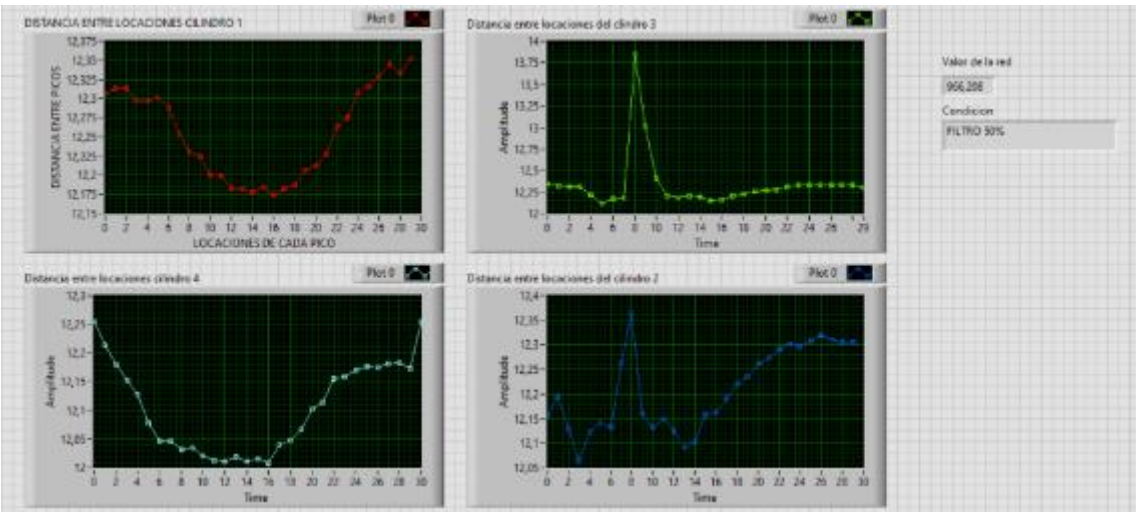

Figura A. 36.Patrón para fallo 900 (2). Fuente: Autores.

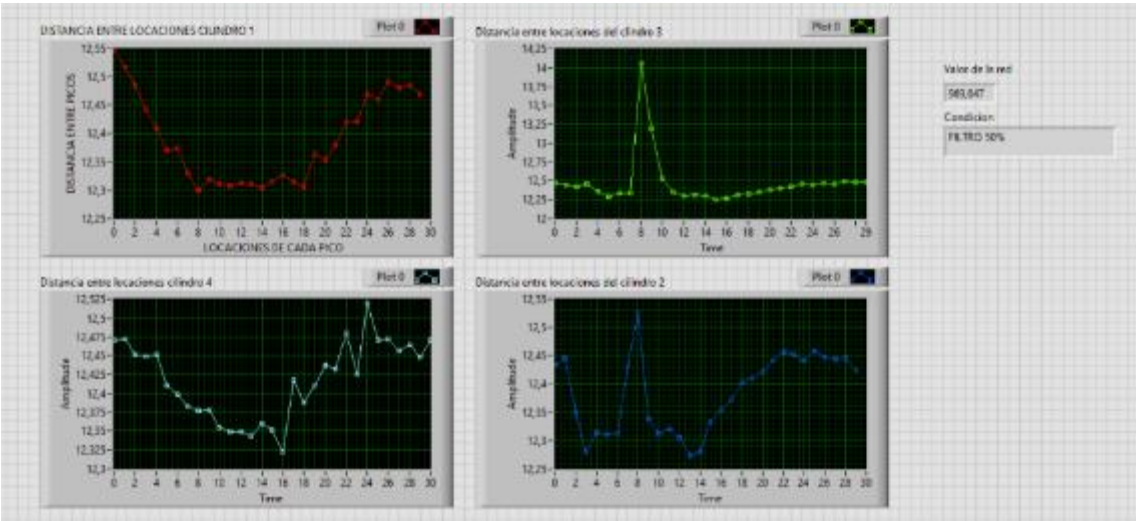

Figura A. 37.Patrón para fallo 900 (3). Fuente: Autores.

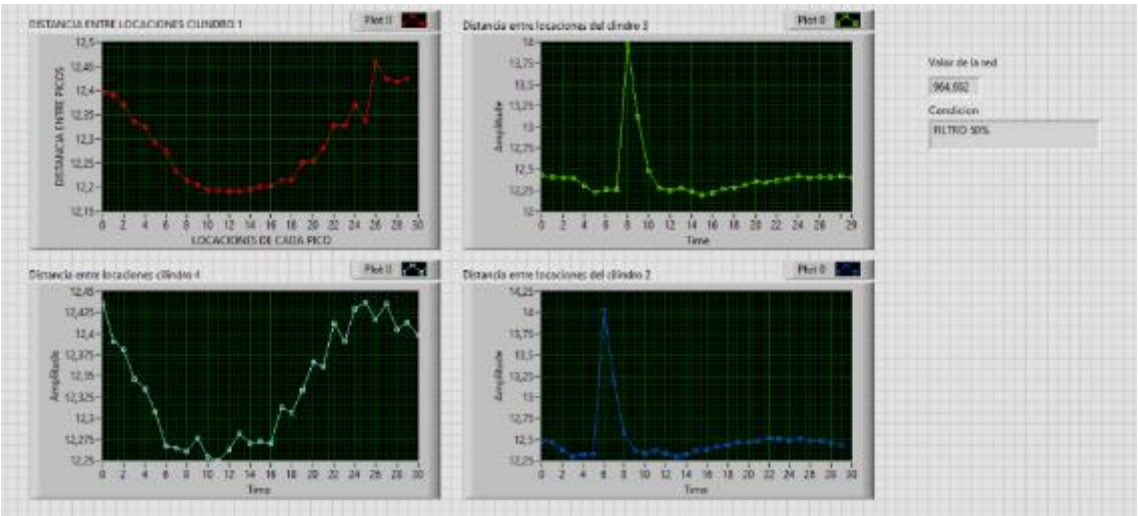

Figura A. 38.Patrón para fallo 900 (4). Fuente: Autores.

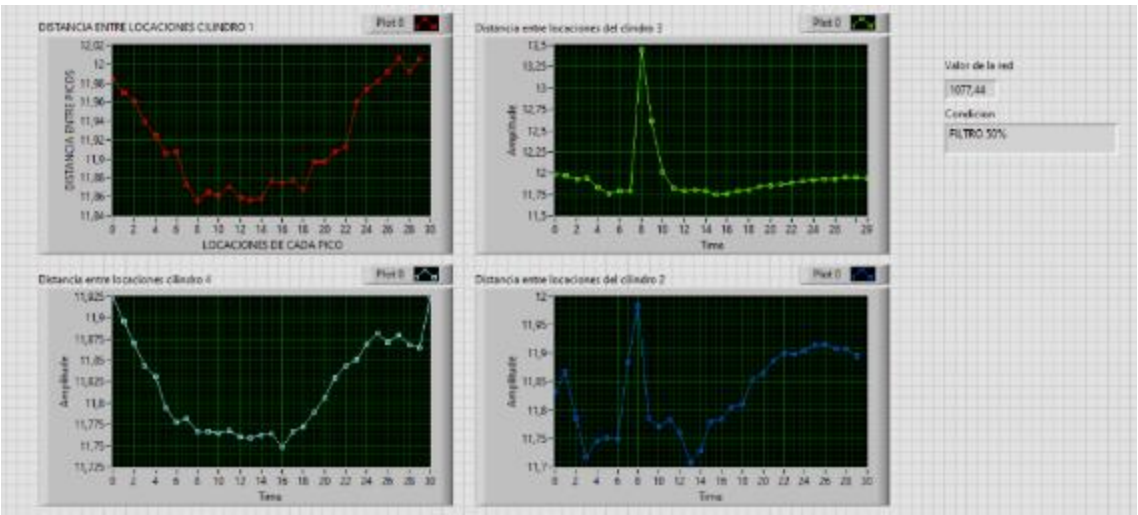

Figura A. 39 Patrón para fallo 1000 (1). Fuente: Autores.

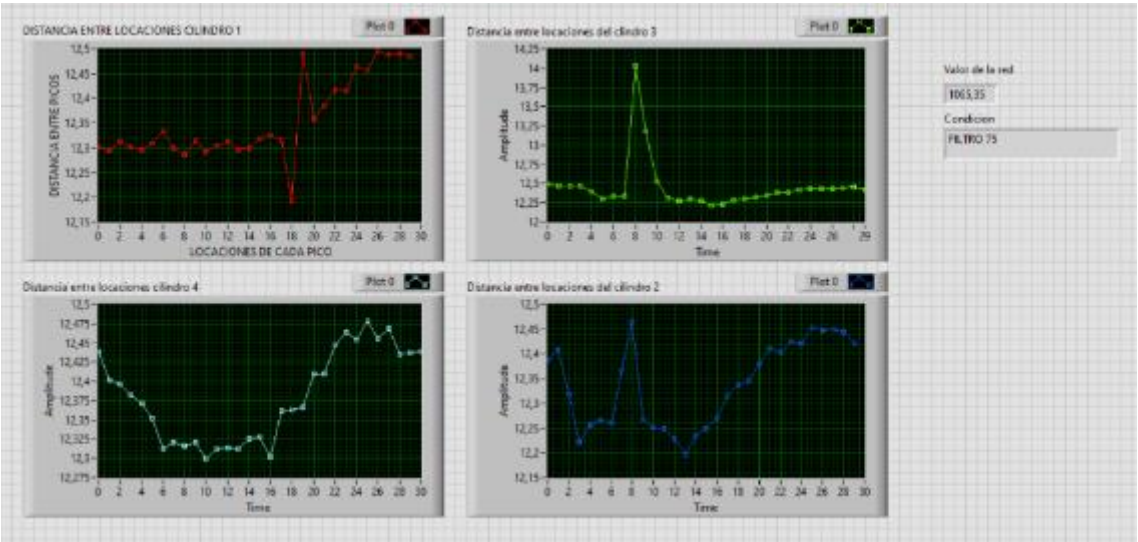

Figura A. 40.Patrón para fallo 1000 (2). Fuente: Autores.

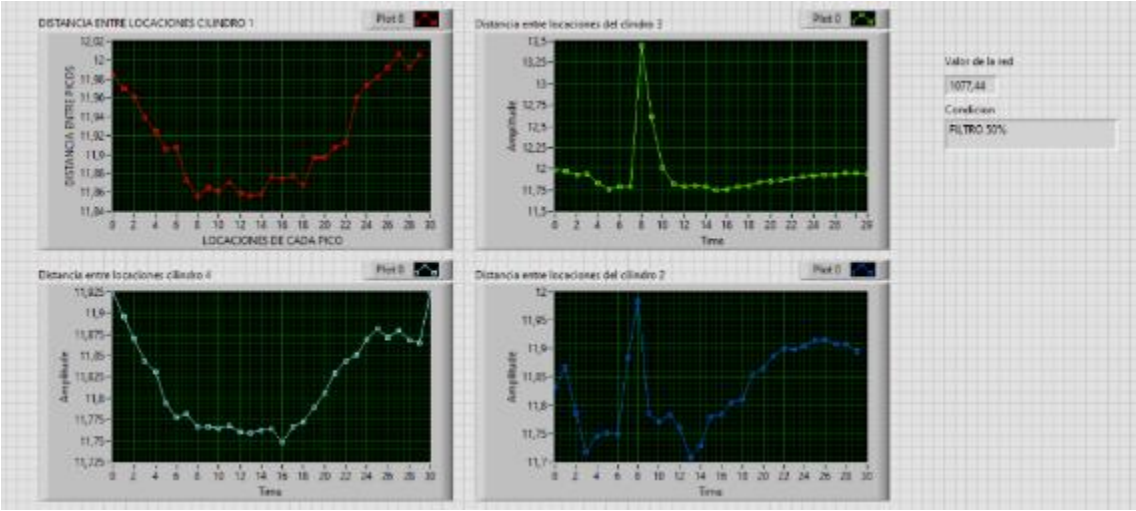

Figura A. 41.Patrón para fallo 1000 (3). Fuente: Autores.

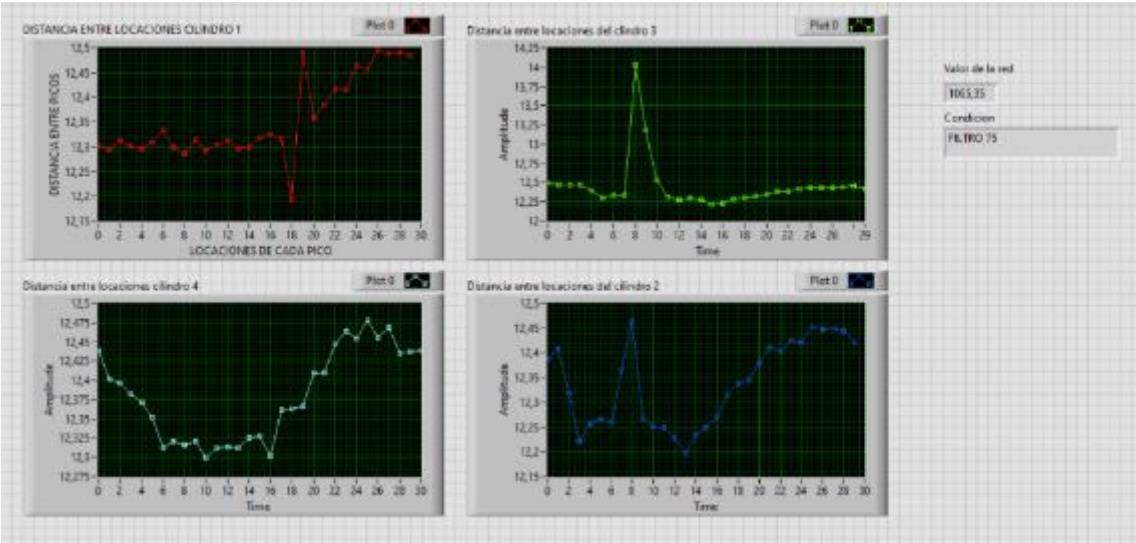

Figura A. 42.Patrón para fallo 1000 (4). Fuente: Autores.

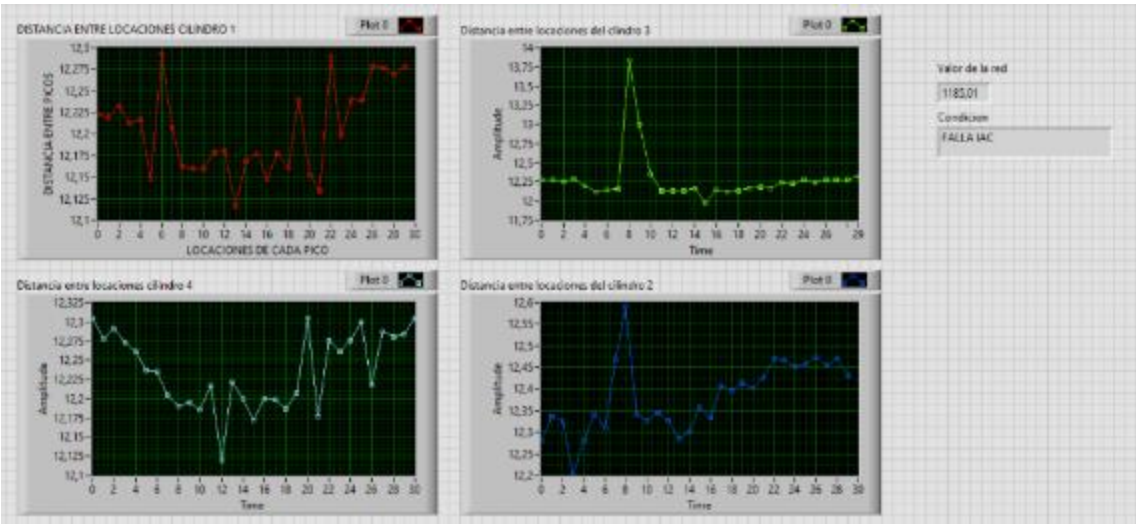

Figura A. 43.Patrón para fallo 1100 (1). Fuente: Autores.

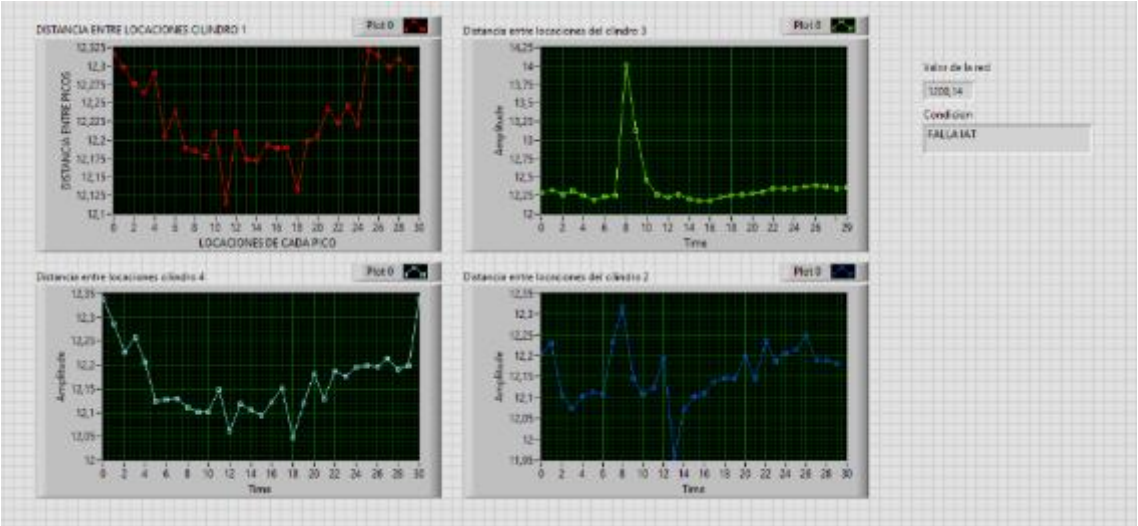

Figura A. 44.Patrón para fallo 1100 (2). Fuente: Autores.

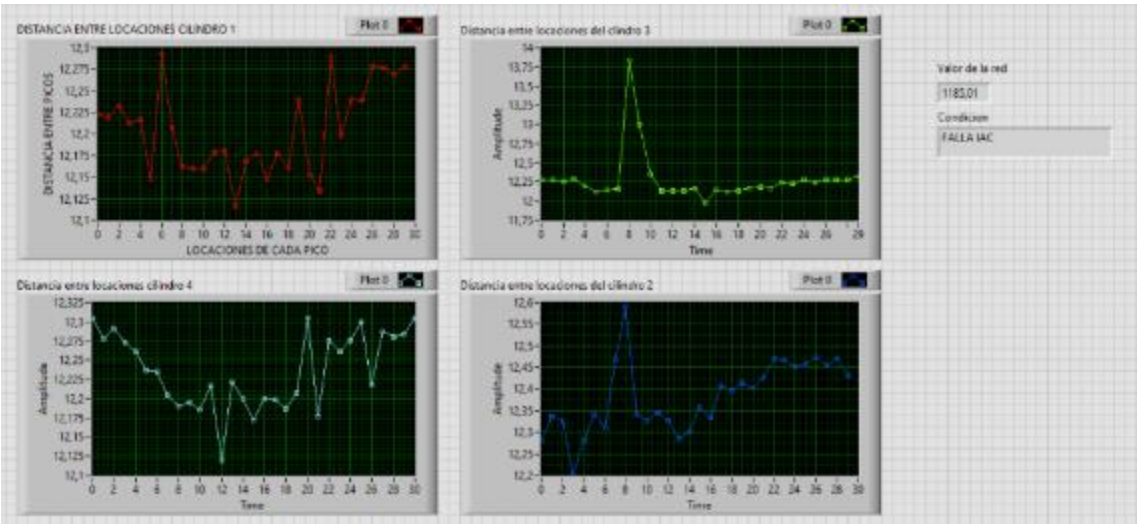

Figura A. 45. Patrón para fallo 1100 (3). Fuente: Autores.

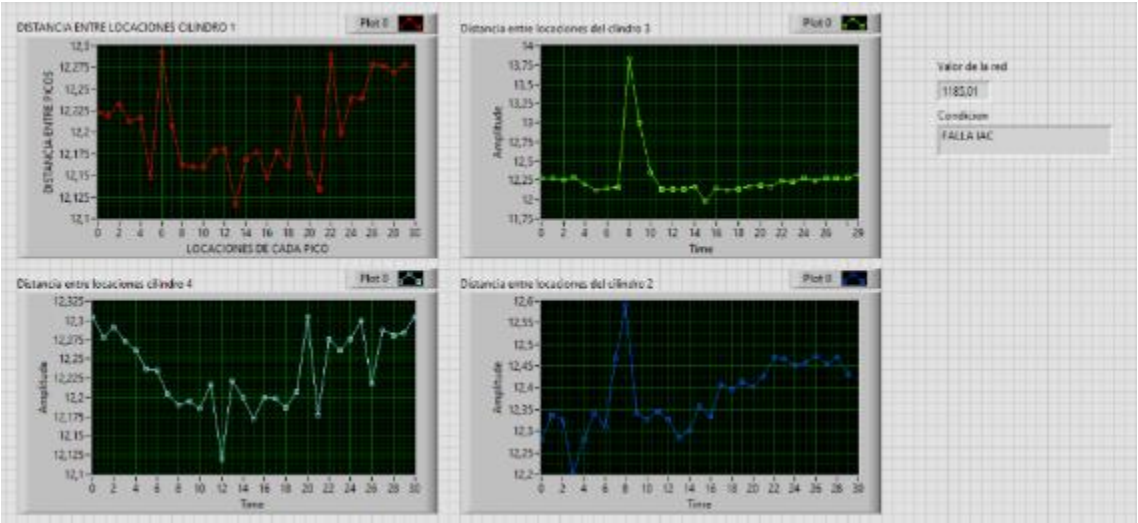

Figura A. 46. Patrón para fallo 1100 (4). Fuente: Autores.

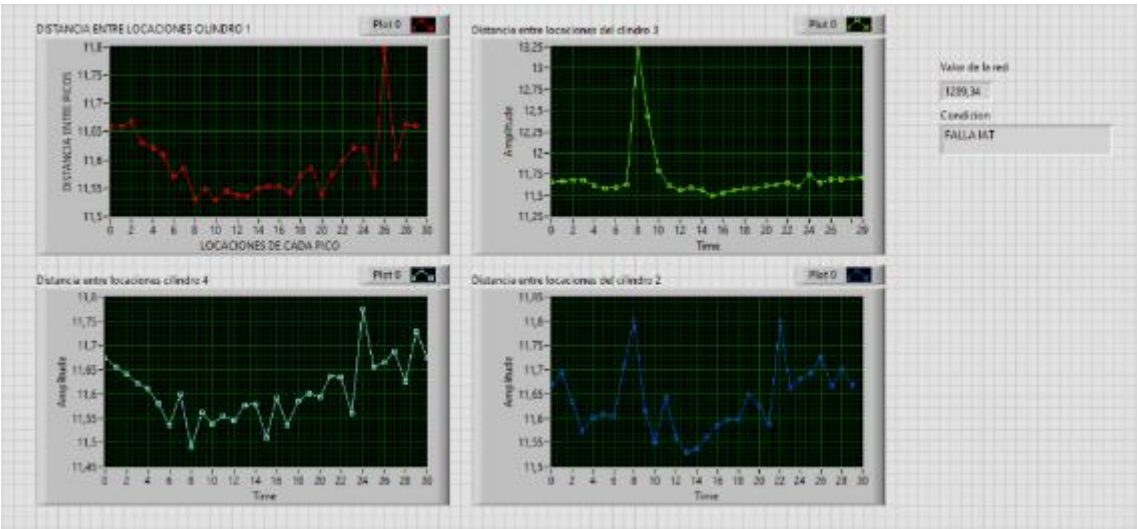

Figura A. 47.Patrón para fallo 1200 (1). Fuente: Autores.

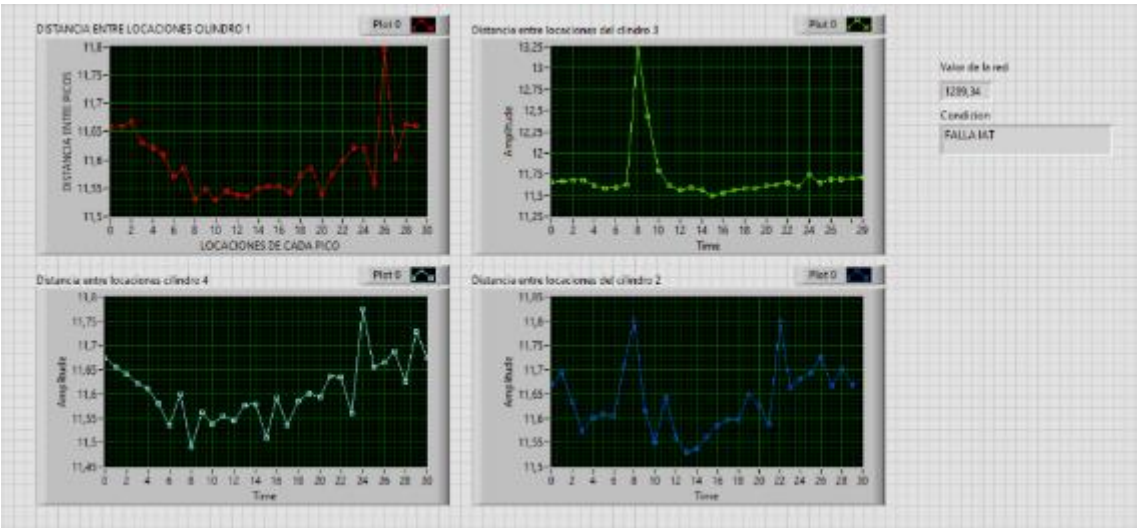

Figura A. 48.Patrón para fallo 1200 (2). Fuente: Autores.

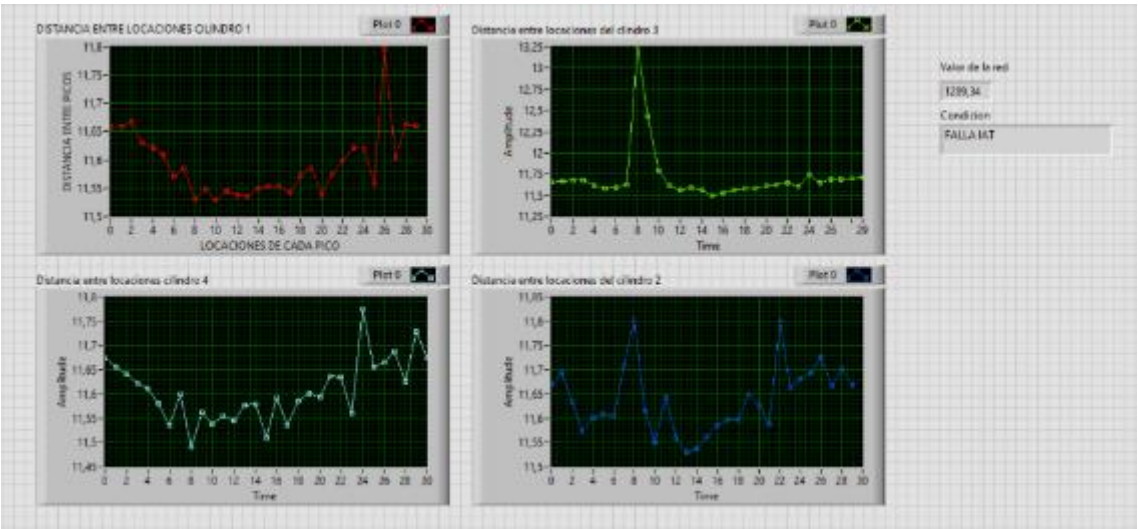

Figura A. 49.Patrón para fallo 1200 (3). Fuente: Autores.

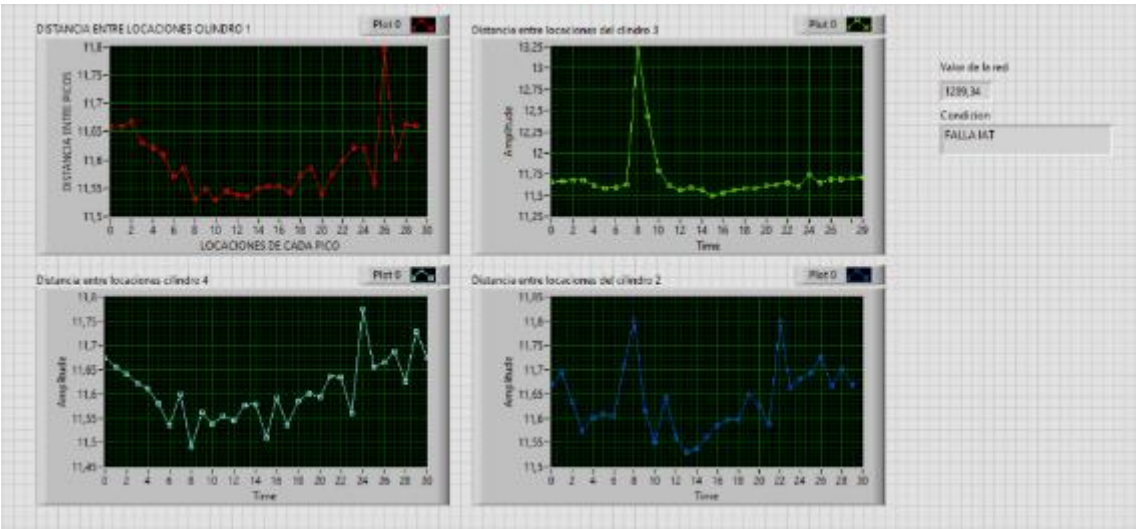

Figura A. 50. Patrón para fallo 1200 (4). Fuente: Autores.

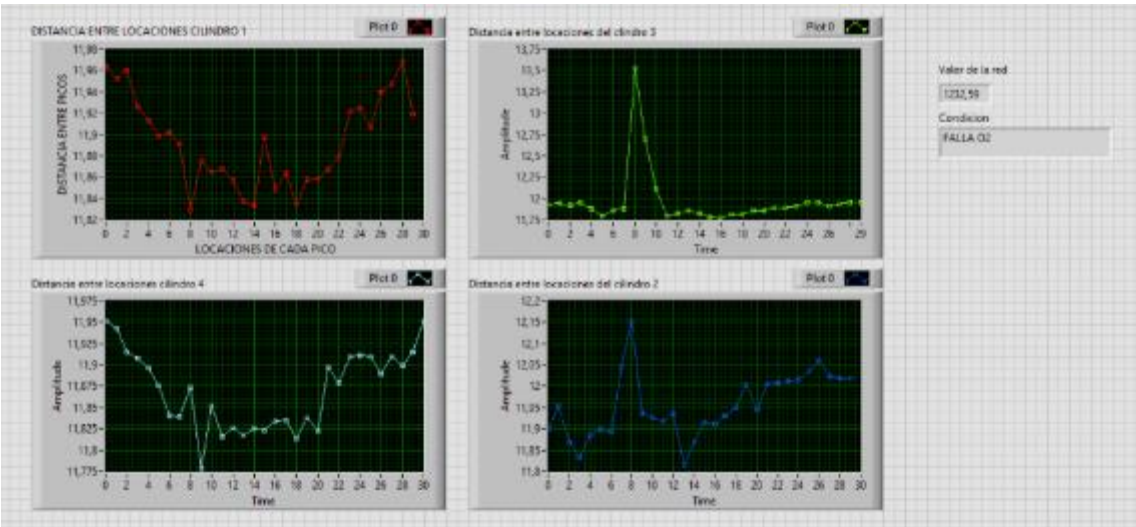

Figura A. 51.Patrón para fallo 1300 (1). Fuente: Autores.

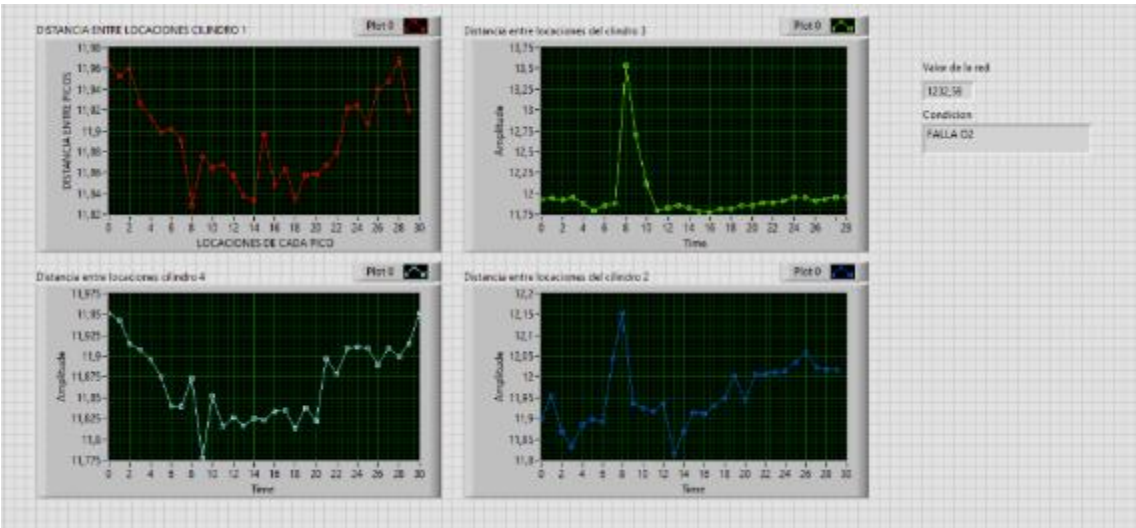

Figura A. 52.Patrón para fallo 1300 (2). Fuente: Autores.

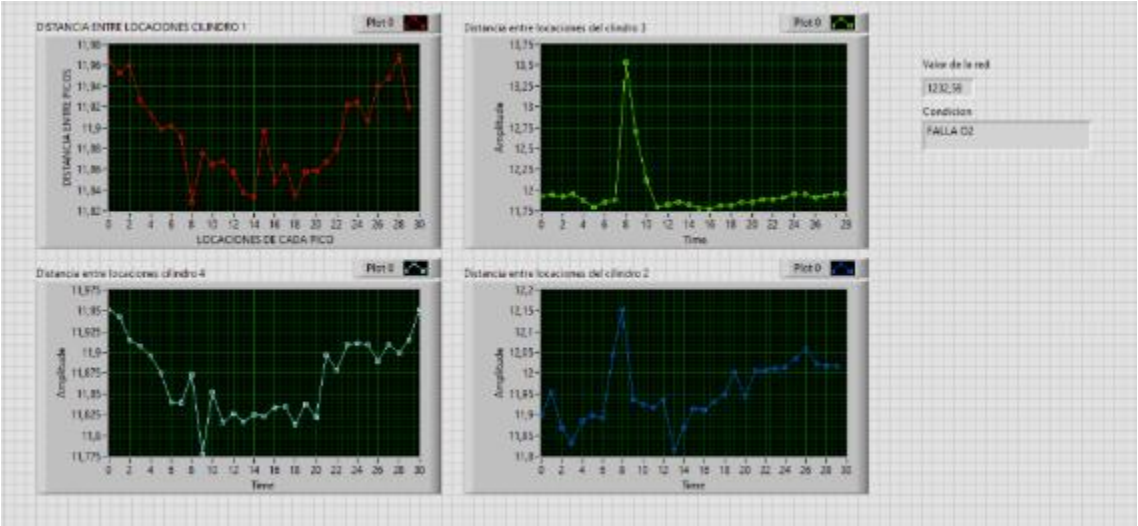

Figura A. 53.Patrón para fallo 1300 (3). Fuente: Autores.

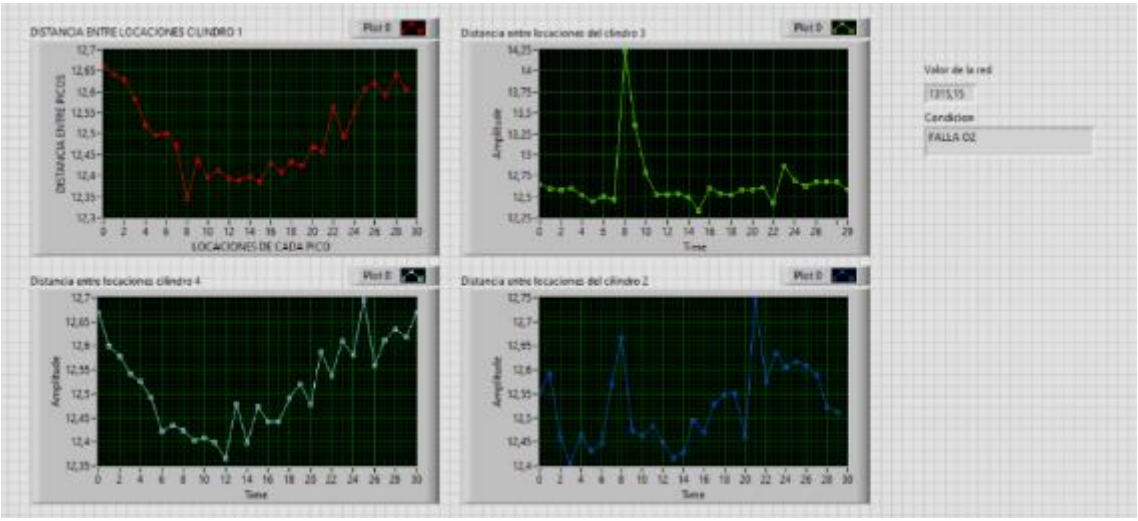

Figura A. 54.Patrón para fallo 1300 (4). Fuente: Autores.

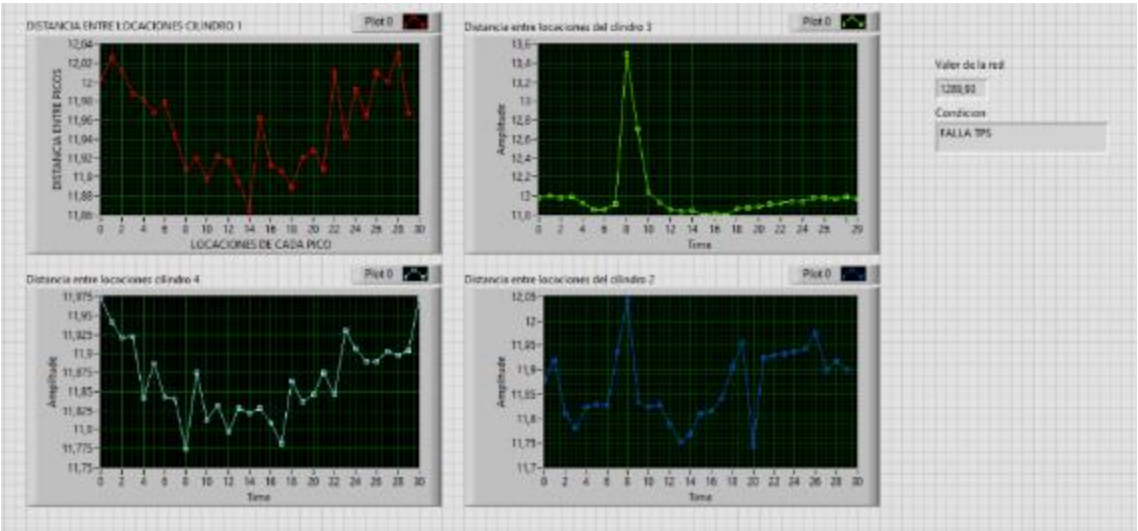

Figura A. 55.Patrón para fallo 1400 (1). Fuente: Autores.

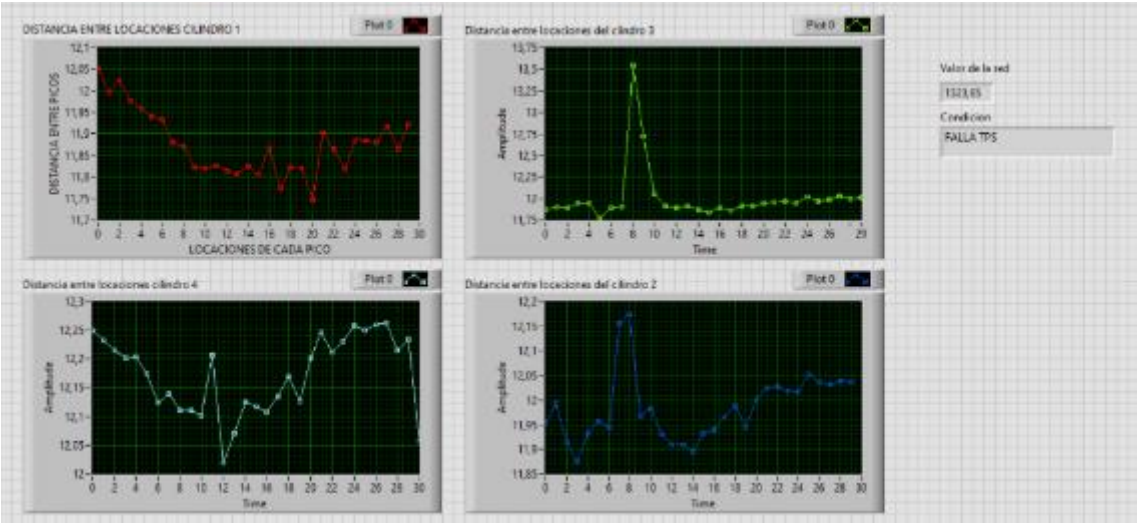

Figura A. 56.Patrón para fallo 1400 (2). Fuente: Autores.

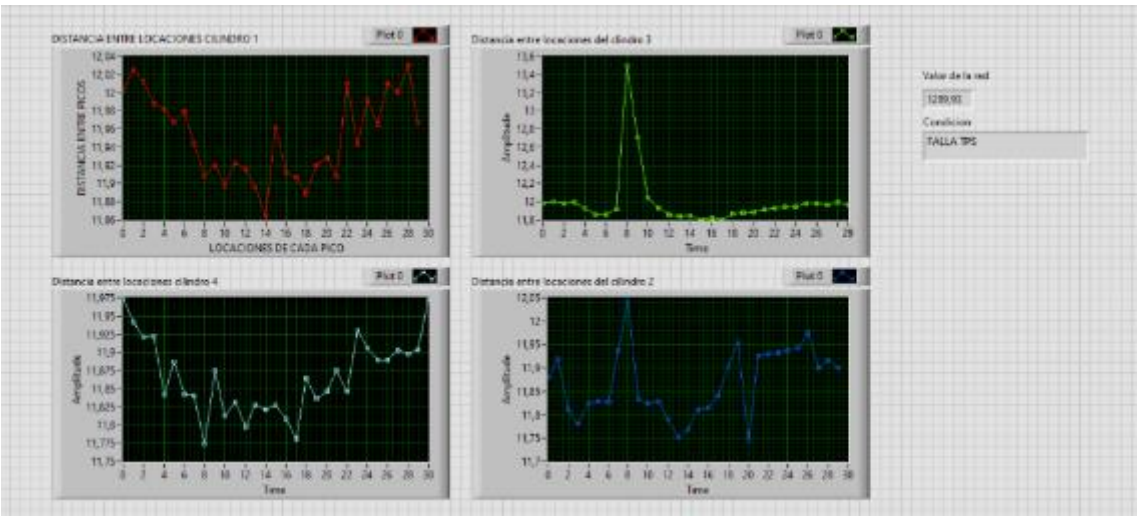

Figura A. 57.Patrón para fallo 1400 (3). Fuente: Autores.

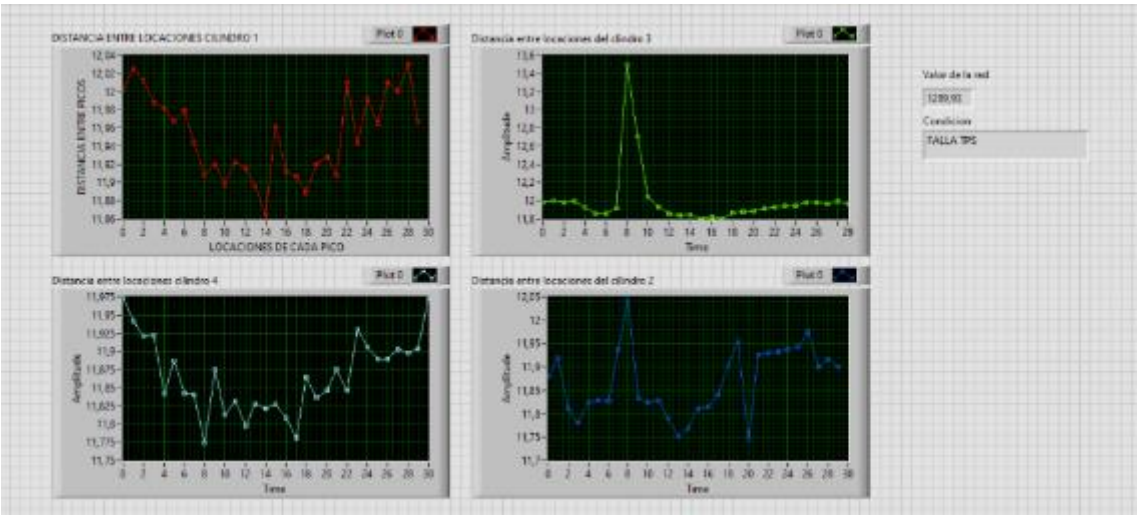

Figura A. 58.Patrón para fallo 1400 (4). Fuente: Autores.

Anexo 3. Resultados de ANOVA.

- **ANOVA para avería de bujía 1.**

Como se puede ver en las Figuras A59 y A60 la línea entrecortada no se interseca con la línea de confianza e indica que las medias son estadísticamente diferentes. Sin embargo, los valores no son significativamente distantes, por lo que se considera que se encuentran dentro del rango del 5% de error.

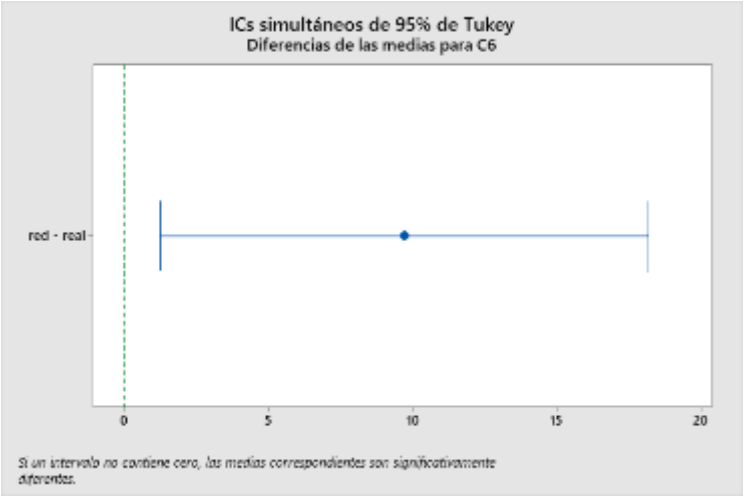

Figura A. 59.ANOVA para fallo de la bujía 1. Fuente: Autores

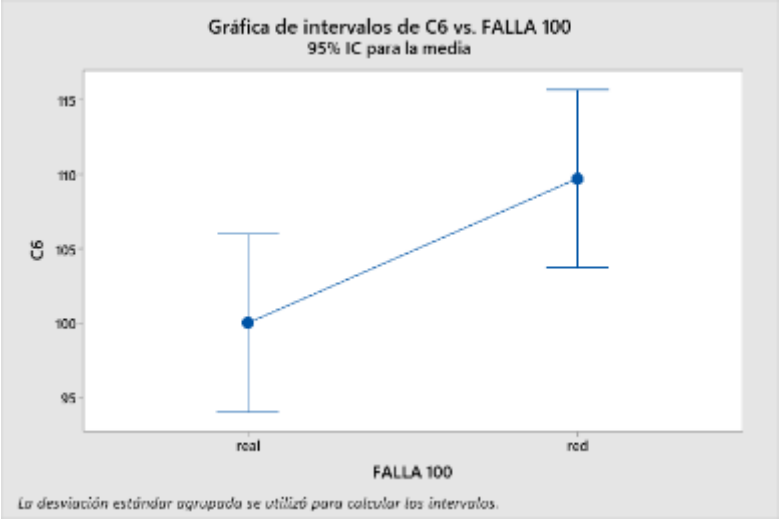

Figura A. 60.Intervalos de confianza para fallo en la bujía 1. Fuente: Autores

Se puede ver en la Figura A61 que los valores de las medias no son significativamente iguales y no comparten el mismo rango. Por lo tanto, para este fallo se prevé inconsistencias en la determinación de la avería.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA

100	N	Media	Agrupación	
red	34	109,70	A	
real	34	100,0		B

Las medias que no comparten una letra son significativamente diferentes.

Figura A. 61.Agrupación de las medias para falla de bujía 1. Fuente: Autores

- **ANOVA para avería de filtro de aire con capacidad del 50%.**

Como se puede ver en las Figuras A62 y A63 la línea entrecortada no se interseca con la línea de confianza e indica que las medias no son estadísticamente iguales.

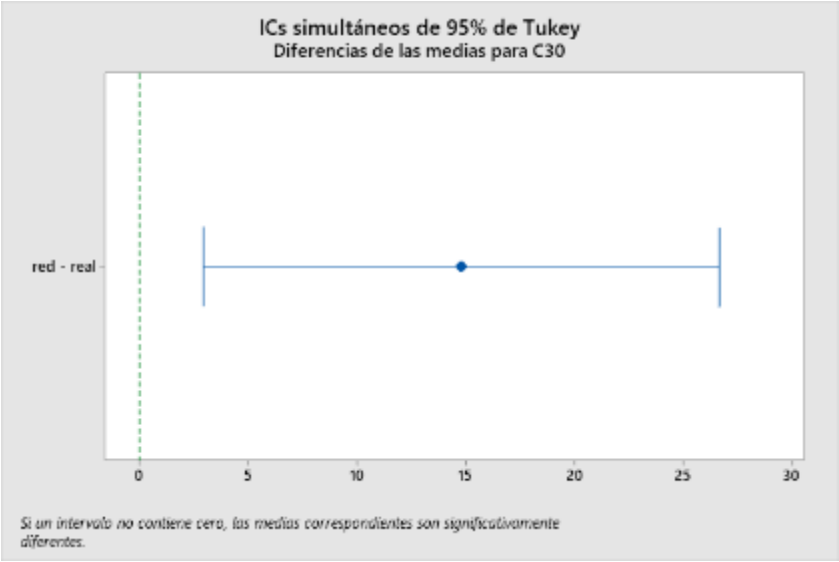

Figura A. 62.ANOVA para fallo de filtro de aire con capacidad del 50%. Fuente: Autores

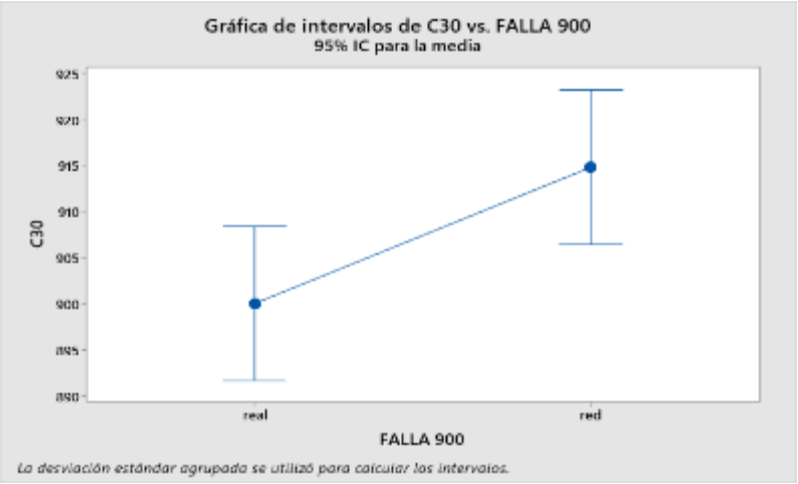

Figura A. 63.Intervalos de confianza para fallo de filtro de aire al 50%. Fuente: Autores

Se puede ver en la Figura A64 que, aunque los valores de las medias son diferentes, este desfase no es mayor. En base al error del 5% se valida la respuesta de la red para esta condición del motor.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA 900	N	Media	Agrupación	
red	26	914,79	A	
real	26	900,0		B

Las medias que no comparten una letra son significativamente diferentes.

Figura A. 64.Agrupación de las medias para fallo de filtro de aire al 50%. Fuente: Autores

- **ANOVA para avería de presión de combustible a 21.5 psi.**

Como se puede ver en las Figuras A65 y A66 la línea entrecortada no se interseca con la línea de confianza e indica que las medias no son estadísticamente iguales.

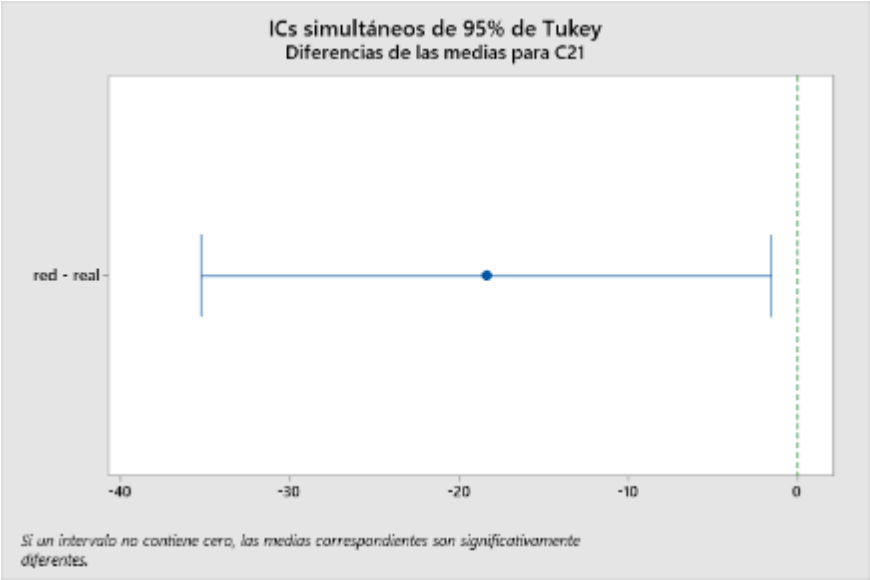

Figura A. 65.ANOVA para fallo con presión 21.5 psi. Fuente: Autores

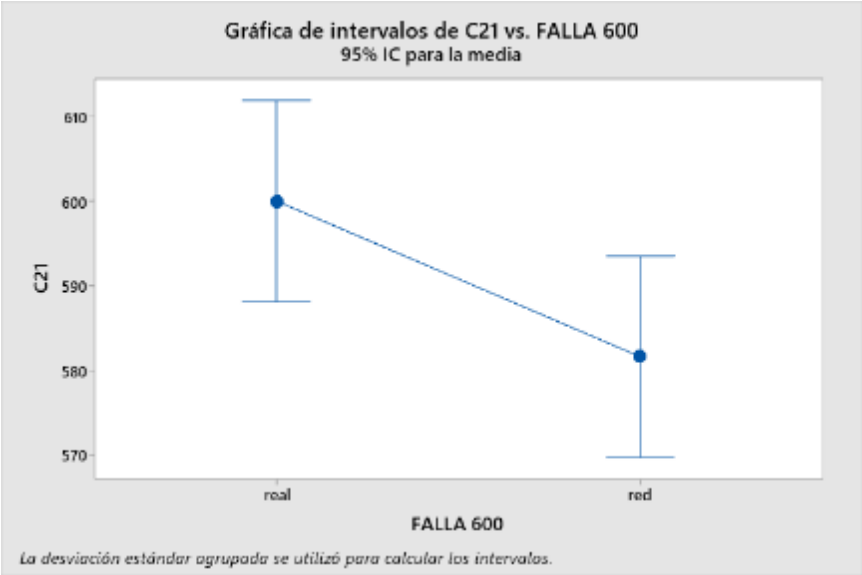

Figura A. 66.Intervalos de confianza para fallo con presión de 21.5 psi. Fuente: Autores

Se puede ver en la Figura A67 que los valores de las medias son significativamente diferentes, sin embargo, el parámetro de error del 5% ampara el resultado.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA

600	N	Media	Agrupación	
real	17	600,0	A	
red	17	581,61		B

Las medias que no comparten una letra son significativamente diferentes.

Figura A. 67.Agrupación de las medias para fallo con presión de 21.5 psi. Fuente: Autores

- **ANOVA para avería de sensor TPS.**

Como se puede ver en las Figuras A68 y A69 la línea entrecortada no se interseca con la línea de confianza e indica que las medias no son estadísticamente iguales.

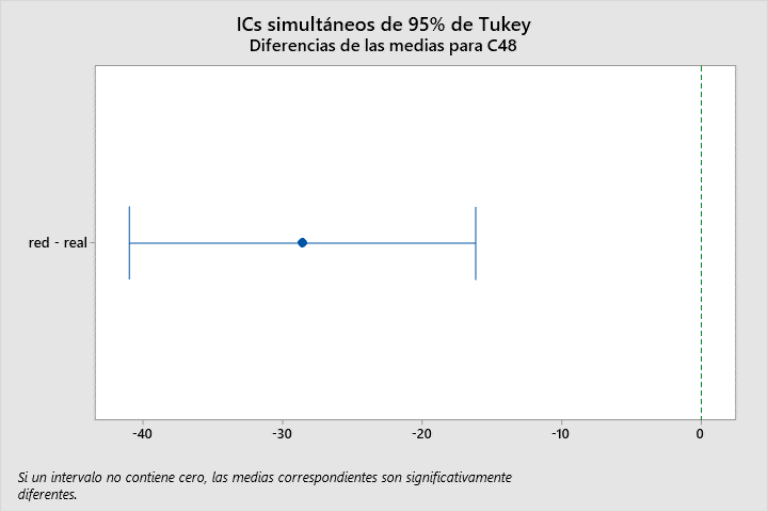

Figura A. 68.ANOVA para fallo de sensor TPS. Fuente: Autores

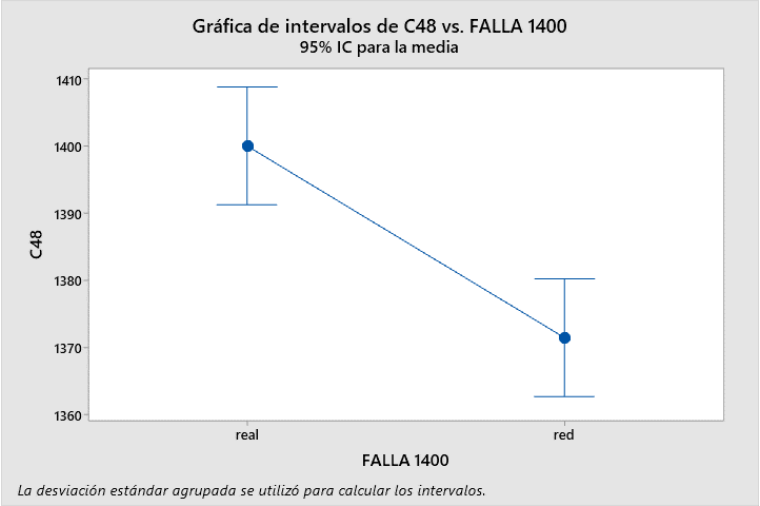

Figura A. 69.Intervalos de confianza para fallo de sensor TPS. Fuente: Autores

Se puede ver en la Figura A70 que los valores de las medias no son significativamente iguales y no comparten el mismo rango.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA 1400	N	Media	Agrupación	
real	19	1400	A	
red	19	1371,43		B

Las medias que no comparten una letra son significativamente diferentes.

Figura A. 70.Agrupación de las medias para fallo de sensor TPS. Fuente: Autores

- **ANOVA para avería de la válvula IAC.**

Como se puede ver en las Figuras A71 y A72 la línea entrecortada no se interseca con la línea de confianza e indica que las medias no son estadísticamente iguales.

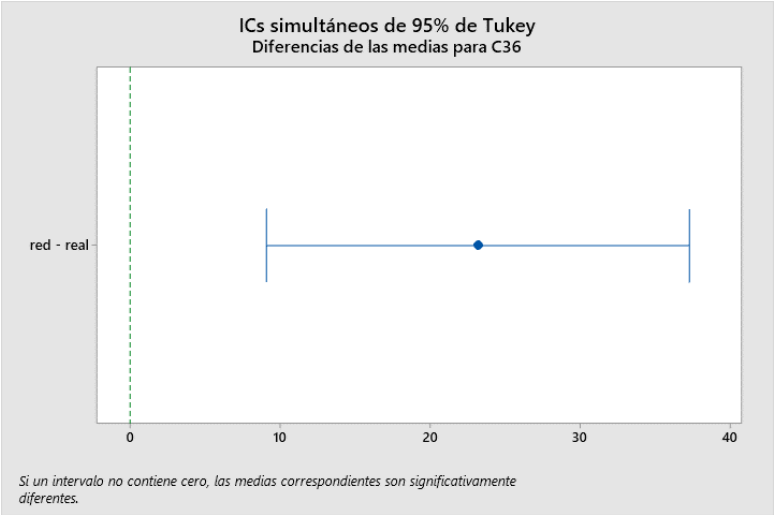

Figura A. 71. ANOVA para fallo de válvula IAC. Fuente: Autores

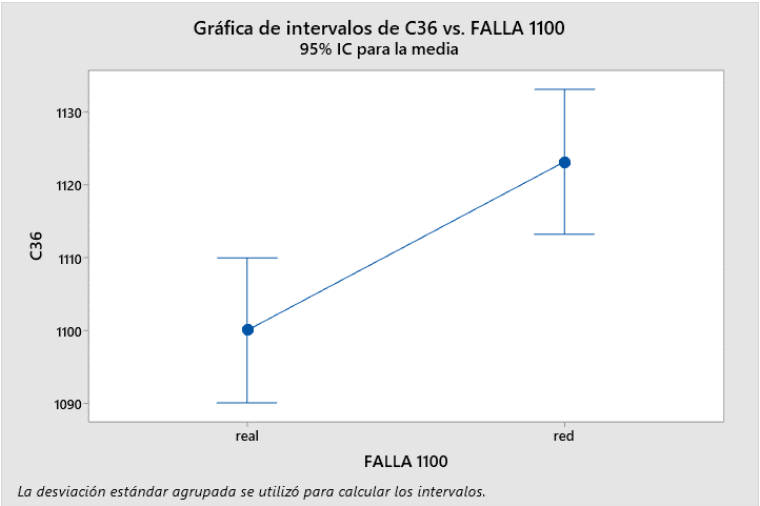

Figura A. 72.Intervalos de confianza para fallo de válvula IAC. Fuente: Autores

Se puede ver en la Figura A73 que los valores de las medias no son significativamente iguales y no comparten el mismo rango.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA 1100	N	Media	Agrupación	
red	10	1123,16	A	
real	10	1100		B

Las medias que no comparten una letra son significativamente diferentes.

Figura A. 73.Agrupación de las medias para fallo de válvula IAC. Fuente: Autores

- **ANOVA para avería de filtro de aire con capacidad del 75%.**

Como se puede ver en las Figuras A74 y A75 la línea entrecortada no se interseca con la línea de confianza e indica que las medias no son estadísticamente iguales.

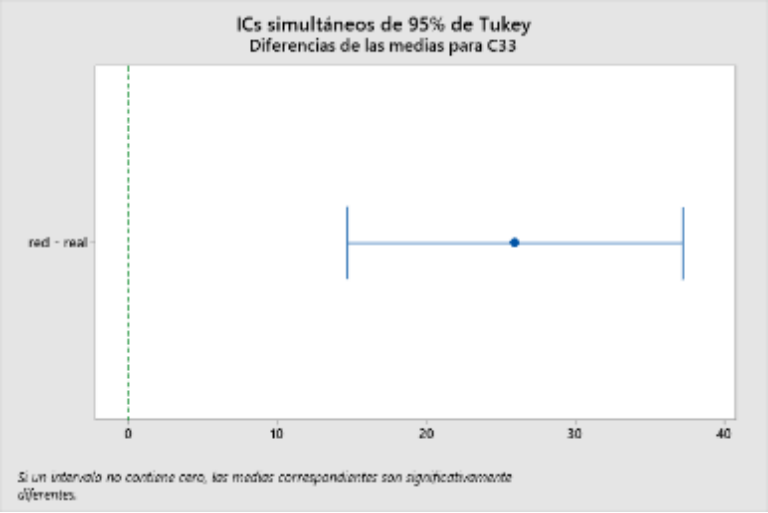

Figura A. 74.ANOVA para fallo de filtro de aire con capacidad del 75%. Fuente: Autores

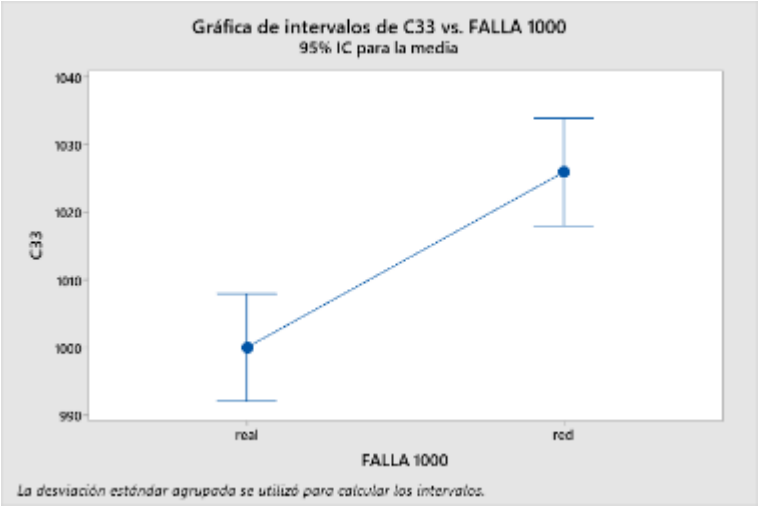

Figura A. 75.Intervalos de confianza para fallo de filtro de aire al 75%. Fuente: Autores

Se puede ver en la Figura A76 que los valores de las medias no son significativamente iguales y no comparten el mismo rango.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA

1000	N	Media	Agrupación	
red	29	1025,94	A	
real	29	1000		B

Las medias que no comparten una letra son significativamente diferentes.

Figura A. 76.Agrupación de las medias para fallo de filtro de aire al 75%. Fuente: Autores

- **ANOVA para avería de bujía 4.**

Como se puede ver en las Figuras A77 y A78 la línea entrecortada no se interseca con la línea de confianza e indica que las medias no son estadísticamente iguales.

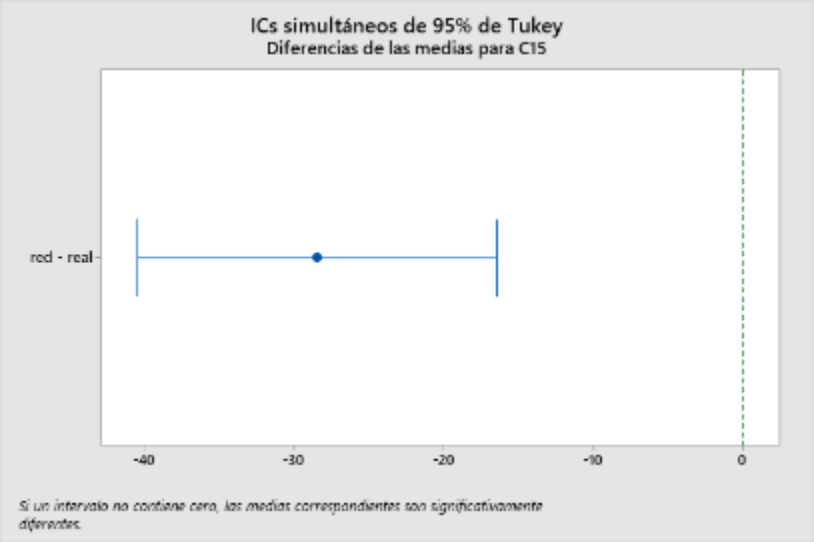

Figura A. 77.ANOVA para fallo de la bujía 4. Fuente: Autores

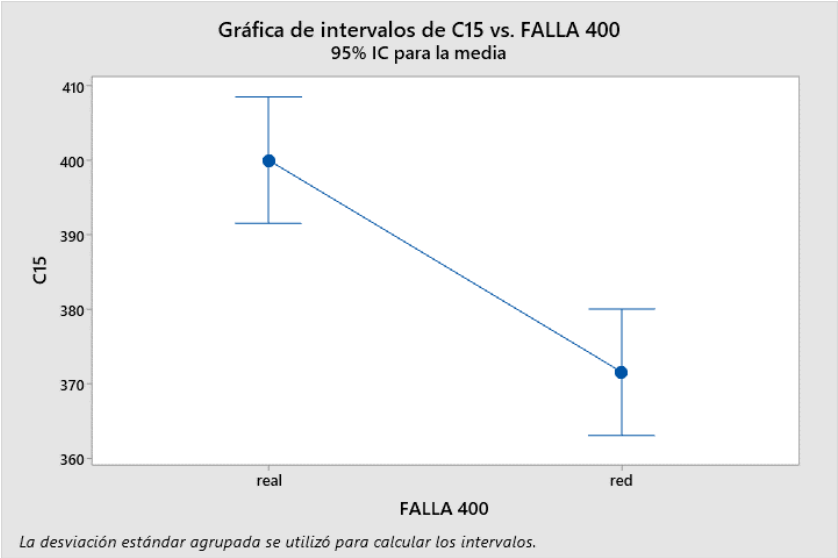

Figura A. 78.Intervalos de confianza para fallo en la bujía 4. Fuente: Autores

Se puede ver en la Figura A79 que los valores de las medias no son significativamente iguales y no comparten el mismo rango. Entonces el error contemplado está dentro del 5%.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA 400	N	Media	Agrupación	
real	25	400,0	A	
red	25	371,53		B

Las medias que no comparten una letra son significativamente diferentes.

Figura A. 79.Agrupación de las medias para falla de bujía 4. Fuente: Autores

- **ANOVA para avería de sensor O2.**

Como se puede ver en las Figuras A80 y A81 la línea entrecortada no se interseca con la línea de confianza e indica que las medias no son estadísticamente iguales.

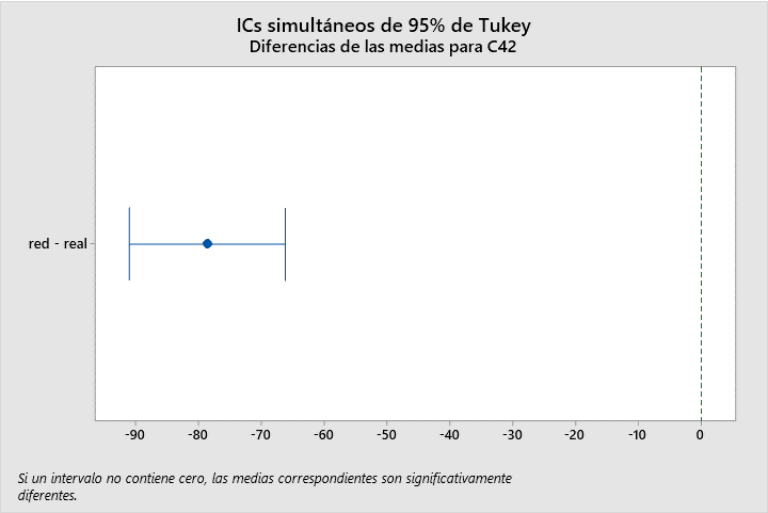

Figura A. 80.ANOVA para fallo de sensor O2. Fuente: Autores

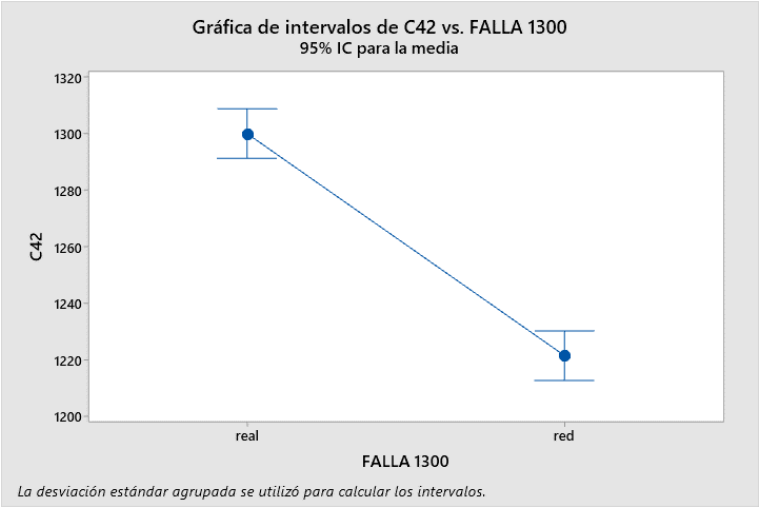

Figura A. 81.Intervalos de confianza para fallo de sensor O2. Fuente: Autores

Se puede ver en la Figura A82 que los valores de las medias no son significativamente iguales y no comparten el mismo rango.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA

1300	N	Media	Agrupación	
real	19	1300	A	
red	19	1221,43		B

Las medias que no comparten una letra son significativamente diferentes.

Figura A. 82.Agrupación de las medias para fallo de sensor O2. Fuente: Autores

- **ANOVA para avería de bujía 3.**

Como se puede ver en las Figuras A83 y A84 la línea entrecortada no se interseca con la línea de confianza e indica que las medias no son estadísticamente iguales.

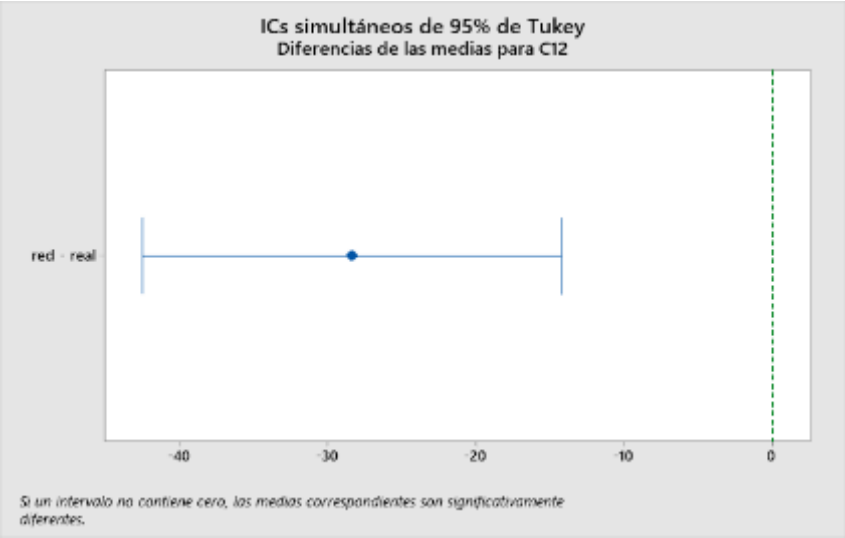

Figura A. 83.ANOVA para fallo de la bujía 3. Fuente: Autores

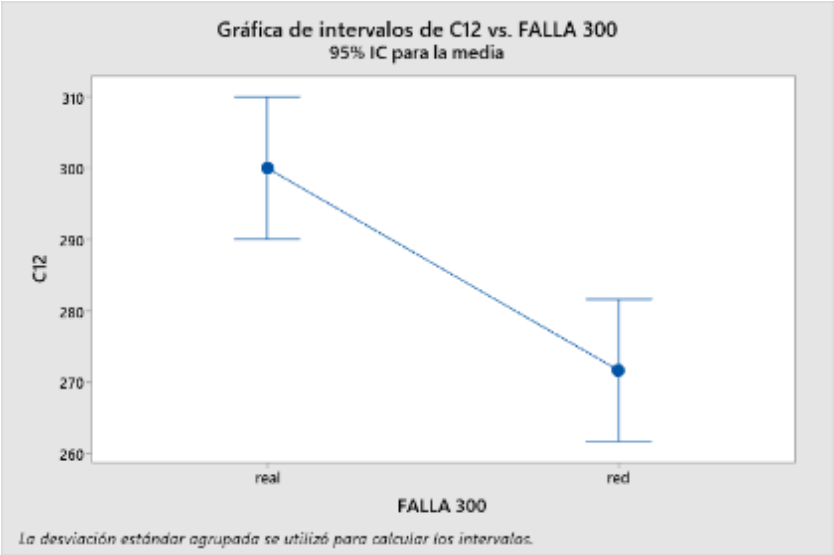

Figura A. 84.Intervalos de confianza para fallo en la bujía 2. Fuente: Autores

Se puede ver en la Figura A85 que los valores de las medias no son significativamente iguales y no comparten el mismo rango. Entonces el error contemplado está dentro del 5%.

Agrupar información utilizando el método de Tukey y una confianza de 95%

FALLA 300	N	Media	Agrupación	
real	18	300,0	A	
red	18	271,65		B

Las medias que no comparten una letra son significativamente diferentes.

Figura A. 85.Agrupación de las medias para falla de bujía 3. Fuente: Autores