



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Maestría

Detección y Diagnóstico de Fallas en los Inyectores de un Motor
de Combustión Interna

presentada por
Ing. José Juan López Díaz

como requisito para la obtención del grado de
Maestra en Ciencias en Ingeniería Electrónica

Director de tesis
Dr. Ricardo Fabricio Jiménez Escobar

Codirector de tesis
Dra. Flor Lizeth Torres Ortiz

Cuernavaca, Morelos, México. Julio de 2021.



Cuernavaca,
Mor.,
No. de Oficio:
Asunto:

12/julio/2021
DIE/149/2021
Aceptación de documentos de
tesis

DR. Carlos Manuel Astorga Zaragoza
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial del **C. Ing. José Juan López Díaz**, con número de control **M17CE057** de la Maestría en Ciencias en Ingeniería Electrónica, le informamos que hemos revisado el trabajo de tesis profesional titulado **“Detección Y Diagnóstico De Fallas En Los Inyectores De Un Motor De Combustión Interna”** y hemos encontrado que se han realizado todas las correcciones y observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

DIRECTOR DE TESIS

Dr. Ricardo Fabricio Escobar Jiménez
Doctor en Ciencias en Ingeniería
Electrónica
Cédula profesional 7534115

CODIRECTOR DE TESIS

M.C. Flor Lizeth Torres Ortiz
Maestra en Ciencias en Ingeniería
Electrónica
Cédula Profesional 5075078

REVISOR 1

Dr. José Francisco Gómez Aguilar
Doctor en Física
Cédula profesional 9124781

REVISOR 2

Dr. Víctor Manuel Alvarado Martínez
Doctor en Ciencias en Ingeniería
Electrónica
Cédula profesional 8031070

C.p. M.E. Guadalupe Garrido Rivera- Jefa del Departamento de Servicios Escolares
Estudiante
Expediente

HEE/mrsr



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Centro Nacional de Investigación y Desarrollo Tecnológico
Subdirección Académica

Cuernavaca, Mor.,

14/julio/2021

No. de Oficio:

SAC/97/2021

Asunto:

Autorización de
impresión de tesis

JOSÉ JUAN LÓPEZ DÍAZ
CANDIDATO AL GRADO DE MAESTRO EN CIENCIAS
EN INGENIERÍA ELECTRÓNICA
PRESENTE

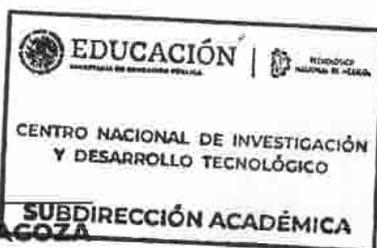
Por este conducto tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado "DETECCIÓN Y DIAGNÓSTICO DE FALLAS EN LOS INYECTORES DE UN MOTOR DE COMBUSTIÓN INTERNA", ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

"Excelencia en Educación Tecnológica"

"Educación Tecnológica al Servicio de México"



DR. CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO

C.c.p. M.E. Guadalupe Garrido Rivera, Jefa del Departamento de Servicios Escolares
Expediente
CMAZ/CHG

cenidet
Centro Nacional de Investigación
y Desarrollo Tecnológico



Interior Internado Palmira S/N, Col. Palmira, C. P. 62490,
Cuernavaca, Morelos Tel. (01) 777 3-62 77 73, ext. 4104,

e-mail: acad_cenidet@tecnm.mx

www.tecnm.mx | www.cenidet.tecnm.mx



Dedicatoria ...

A **Dios**, por haberme colocado en el camino correcto con las personas correctas.

A **Shamara** por ser mi motor para seguir adelante.

A **Miriam** por formar parte de mi vida y brindarme el mejor regalo del mundo.

A **mi Madre** por estar siempre conmigo.

A **Mis hermanos** los quiero mucho y gracias por todo.

A **Erick, Zetina, Henry, Eusebio, Christian, Jonathan, Cavita, Citlaly y Diana** gracias por formar parte de grandes anécdotas.

Agradecimientos

A mi familia, en especial a mi esposa e hija, gracias por motivarme, apoyarme y brindarme grandes momentos de alegría.

Mis hermanos, Hector y Bety gracias por estar conmigo y ser los hermanos que son, dejando un aprendizaje en cada ocasión.

A mi asesor, Dr. Fabricio Escobar Jiménez, gracias por paciencia, entusiasmo, enseñanzas, constancia y valor en este camino de desarrollo profesional.

A mi co-director, Dra. Flor Lizeth Torres Ortiz, gracias por su apoyo incondicional y valor en este camino de desarrollo profesional.

Muchas gracias. A mis revisores, Dr. José Francisco Gómez Aguilar y el Dr. Victor Manuel Alvarado Martínez, por sus sabios comentarios que enriquecieron este trabajo.

A todo el personal del CENIDET, mis maestros, compañeros, amigos, y todas aquellas personas que conocer durante este procedimiento.

A Maria del Rocio Salazar Ruiz por haberme brindado sus mejores atenciones.

CONACYT por su apoyo económico para la realización de mis estudios de maestría.

A Tecnológico Nacional de México por su apoyo en las instalaciones.

Resumen

Este tema de tesis habla sobre el desarrollo de un esquema de detección y diagnóstico de fallas basado en señales, dicho sistema se encuentra alimentado por una matriz de valores obtenida a partir de la transformada Stockwell, esta transformada utiliza una ventana variable según la distribución de frecuencia utilizada permitiendo trabajar en frecuencia y tiempo a comparación de otras transformadas más comunes como la transformada de Fourier que no, permite ello.

Previo a la obtención de la matriz antes mencionada se realiza un tratamiento de la señal efectuado con la transformada Wavelet y su inversa, dando como ventaja poder eliminar las características no deseadas de la señal.

Finalmente se introducen los datos a una red neuronal otorgando así una firma de fallas que sirve para aislar correctamente la falla.

Abstract

This thesis topic deals with the development of a fault detection and diagnosis scheme based on signals, said system is fed by a matrix of values obtained from the Stockwell transform, this transform benefits since it allows to work in frequency and time Compared to other more common transforms such as the Fourier transform.

Prior to obtaining the aforementioned matrix, a signal treatment is carried out which is carried out with the Wavelet transform and it's inverse, giving the advantage of being able to eliminate the unwanted characteristics of the signal.

Finally, the data is entered into a neural network which gives us a fault signature which serves to correctly isolate the fault.

Índice general

Dedicatoria	I
Agradecimientos	III
Resumen	IV
Abstract	V
Lista de figuras	VIII
Lista de tablas	IX
1. Introducción	1
1.1. Antecedentes	3
1.2. Planteamiento del problema	4
1.3. Objetivos	5
1.4. Metas	5
1.5. Justificación	6
1.6. Alcance	6
1.7. Hipótesis	7
1.8. Método de solución	7
1.9. Organización del documento.	9
2. Estado del arte y marco teórico	10
2.1. Estado del arte	10
2.1.1. Detección y diagnóstico de fallas	10
2.1.2. Detección y diagnóstico de fallas basado en ELM	11

2.1.3. Detección y diagnóstico de fallas aplicado a sistemas de inyección electrónica	12
2.2. Marco Teórico.	15
2.2.1. Diagnóstico de fallas	15
2.2.2. Análisis de señales	17
2.2.3. Extreme Learning Machine (ELM)	19
3. Caso de estudio	22
4. Diseño del FDD	26
4.1. Adquisición de señales	27
4.1.1. Filtro de señal	27
4.1.2. Extracción de características	30
4.1.3. 2D Extreme Learning Machine	30
4.2. Pruebas fuera de línea	33
5. Implementación y resultados	35
5.1. Sistema embebido	35
5.2. Resultados	35
6. Conclusión y trabajos futuros	39
6.1. Conclusión	39
6.2. Trabajos futuros	40
A. Producto académico	45

Índice de figuras

1.1. Algoritmo de solución	7
1.2. Sensor diferencial de presión MPX5700	8
2.1. Metodología de detección y diagnóstico de fallas, basado en modelos matemáticos y señales.	16
3.1. Sistema de inyección electrónica	22
3.2. Tarjeta NI myRIO	24
4.1. Algoritmo de solución	26
4.2. Programa en LabView	27
4.3. Adquisición de señales, mismas que no permiten distinguir la falla, por el exceso de ruido.	28
4.4. Señal filtrada, donde se aprecia la falla en las partes donde la caída de presión no es continua.	29
4.5. Señales sin filtro, donde no se aprecia la falla	31
4.6. Señales con filtro, se puede ver la falla en la falta de los puntos rojos.	32
4.7. Algoritmo del esquema de detección y diagnóstico de fallas.	33
4.8. Arquitectura de la red neuronal.	33
4.9. Prueba fuera de línea	34
5.1. Aislamiento en falla del inyector 2	37
5.2. Aislamiento en falla del inyector 3	38
5.3. Aislamiento en falla del inyector 4	38

Índice de tablas

4.1. Tabla de pruebas a nivel simulación	34
--	----

Capítulo 1

Introducción

Un motor de combustión interna es un sistema que ofrece energía mecánica directamente de la energía química de un combustible debido a una explosión. Esta explosión se genera por medio de una chispa dentro de una cámara de combustión. Para que esta explosión se lleve a cabo de manera eficiente debe existir una relación estequiométrica entre el aire y el combustible; en el caso de la gasolina se debe tener una relación estequiométrica de 14.7 kg de aire por 1 kg de combustible de acuerdo con Alippi et al. (2003). En un automóvil, la mezcla homogénea entre aire y gasolina depende del sistema de inyección.

De tal forma que este subsistema debe de estar monitoreado para detectar y diagnosticar fallas y así evitar deficiencia en el desempeño del motor. En el trabajo presentado por Filipczyk (2013) se realizó una investigación sobre las fallas más comunes en los motores de combustión interna. Dicha investigación la llevo a cabo en el departamento de mantenimiento de motores automotrices de la Facultad de Transporte de la Universidad Politécnica de Silesia en Polonia. Recopiló información de 628 motores a partir del año 2000 hasta el 2012. El resultado de esta recopilación le permitió determinar la existencia de al menos 16 fallas comunes, y además las colocó según el porcentaje de ocurrencia; de las que destacó en primer lugar el sistema de control eléctrico y de ignición, en segundo lugar, el sistema de enfriamiento y en tercer lugar el sistema de inyección de combustible. Cabe señalar que la extracción

de información la obtuvo con ayuda de un esquema de diagnóstico a bordo OBD (On board diagnostic, por sus siglas en inglés).

Los esquemas de detección y diagnóstico de fallas FDD (Fault Detection and Diagnosis, por sus siglas en inglés) que logran conseguir características y atributos de cambios de las señales bajo el efecto de una falla para posteriormente localizarla, diagnosticarla, identificarla y estimar la forma de su evolución. En los esquemas FDD existen dos métodos, el método basado en modelos matemáticos y el método basado en análisis de señales.

En este tema de tesis se plantea el uso de un esquema de detección y diagnóstico de fallas basado en el análisis de señales con el uso de la transformada de Wavelet y Stockwell, así como una red neuronal Extreme Learning Machine.

Para el desarrollo del esquema de detección y diagnóstico de fallas se realizó un estudio bibliográfico, donde se encontraron dos investigaciones realizadas dentro del Centro Nacional de Investigación y Desarrollo Tecnológico. En el trabajo realizado por Namigtle (2018) se utilizan tres redes neuronales alimentadas por los valores característicos de la señal en el dominio del tiempo y frecuencia. En el trabajo que presenta Montiel (2016) solo utiliza una red neuronal con una capa oculta que lleva a cabo un aprendizaje Extreme Learning Machine.

En otros trabajos como Mahmoud Mufeed (2003), se realizó un estudio en dónde muestran algunos de los métodos utilizados en el diagnóstico de fallas en los sistemas automotrices. Mientras que, el trabajo de Gertler et al. (1993) describen un algoritmo desarrollado para la detección en línea y el diagnóstico de fallas en sensores y actuadores de motores de automóviles, mientras que en el trabajo de Albarracín (2015) consistió en un análisis de imágenes espectrales y de análisis estadístico, sobre los efectos más significativos o críticos que presenta el funcionamiento del motor CRDi a distintos regímenes (820, 1660 y 2500 rpm), cuando existe una variación de la densi-

dad y la presión del combustible.

1.1. Antecedentes

El objetivo de detectar y diagnosticar fallas es brindar seguridad dando una información detallada sobre el estado del sistema. En este concepto se brindan los posibles eventos a detectar. En el trabajo de Mahmoud Mufeed (2003), se realizó un estudio en donde muestran algunos de los métodos utilizados en el diagnóstico de fallas en los sistemas automotrices. Los autores consideran que una falla es aquella que afecta al sistema automotriz llevándola al incremento de emisiones de gases contaminantes, incremento en el consumo de gasolina y/o cuando genere un daño en el motor. Además, mencionan que, estas fallas se pueden evitar si se prevén ya sea para minimizar el impacto o aislarlo en un cierto tiempo.

Como antecedentes de trabajos desarrollados en el Centro Nacional de Investigación y Desarrollo Tecnológico, el M.C. Montiel (2016) propuso un esquema de detección y diagnóstico de fallas fuera de línea basado en señales usando una RNA (red neuronal artificial) utilizada para la clasificación de fallas aplicado en un banco de pruebas de un sistema de inyección electrónica EFI (Electronic Fuel Injection, por sus siglas en inglés). El autor realizó una simulación del sistema EFI y lo comparó con información real medida arrojando similitud, además calculó y simuló los tiempos de inyección, todo esto con el fin de validar el modelo matemático que él propuso.

Cabe mencionar que actualmente los automóviles cuentan con un esquema de diagnóstico en línea de los componentes y sistemas de los automóviles ha incrementado en la industria automotriz, por las siguientes razones:

- El OBD mejora la mantenibilidad y separabilidad de los vehículos.
- El cumplimiento de las leyes federales y estatales, que requieren la disminución

de emisiones de gases de combustión, se facilita con la detección y compensación de fallas incipientes en los sistemas de suministro de combustible y gases de escape.

- El incremento en capacidad de las computadoras y controladores automotrices ha hecho posible la implementación de algoritmos de control y diagnóstico extremadamente sofisticados.

Esta investigación se lleva a cabo debido a que actualmente, los vehículos cuentan con el sistema antes mencionado que en presencia de falla solo avisa al usuario mediante un indicador luminoso que se está presentando una falla, por lo que deben de llevar el vehículo a un técnico especializado en el área para que le introduzca un escáner el cual solo sondeara y dará referencia de los subsistemas involucrados en la falla, por medio de códigos, por lo que basado en la experiencia propia deberá decidir que está fallando precisamente, permitiendo esto la presencia del posible error humano.

Por lo que este tema de investigación es un área de oportunidad para el desarrollo de estrategias de detección y diagnóstico de fallas capaz de detectar en línea las fallas y localizarlas.

1.2. Planteamiento del problema

Los algoritmos de detección y diagnóstico de fallas han tomado un papel muy importante en los sistemas modernos debido a que estos sistemas deben proporcionar al usuario confiabilidad y seguridad, en el caso del sector automotriz no es la excepción debido a que las fallas pueden inducir al incremento en el consumo de combustible, pérdida de eficiencia, afectar al motor por el derrame de fluidos y al incremento en las emisiones contaminantes al no consumir debidamente el combustible.

En un automóvil la proporción de combustible inyectado está relacionado con la eficiencia de la combustión y la combustión se relacionada con el desempeño y la

emisión de gases contaminantes, por lo que es importante mantener supervisado el sistema de inyección de combustible, debido a que en la actualidad las normas en el ámbito de emisiones contaminantes a la atmósfera y calidad de los productos son cada vez más rigurosas, teniendo como consigna retirar algunos días de las calles a los vehículos que excedan cierta cantidad de emisiones, por lo que una falla en el sistema de inyección degradaría el rendimiento del motor de combustión interna generando más gases contaminantes.

1.3. Objetivos

Objetivo general

Diseñar e implementar un esquema de detección y diagnóstico de fallas, que sea capaz de detectar y aislar fallas abruptas presentes en los inyectores de un sistema de inyección electrónica de combustible de un motor de combustión interna.

Objetivos específicos

- Diseñar un esquema para la extracción de características de la señal de presión para el desarrollo de un sistema de detección y diagnóstico de fallas aplicado a un sistema de inyección electrónica.
- Desarrollar a nivel de simulación el esquema de detección y diagnóstico de fallas aplicado a un sistema de inyección electrónica.
- Implementar el esquema de detección y diagnóstico de fallas en el sistema de inyección electrónica de combustible de un motor de combustión interna.

1.4. Metas

- Obtener una metodología de extracción de características basada en la Transformada Stockwell para desarrollar un esquema de detección y diagnóstico de fallas aplicado a un sistema de inyección electrónica.

- Obtener a nivel simulación resultados del esquema de detección y diagnóstico de fallas para un sistema de inyección electrónica.
- Tener el esquema de detección y diagnóstico de fallas para el sistema de inyección electrónica en la tarjeta MyRio-1900.

1.5. Justificación

Al implementar un sistema FDD aplicado a los inyectores de un motor de combustión interna se establece el momento y el origen de la falla.

En la actualidad no se reporta en la literatura un esquema de detección y diagnóstico de fallas basado en Extreme Machine Learning de doble dimensión aplicada a el sistema de inyección de un motor de combustión interna.

Por lo que este tema de investigación es un área de oportunidad para el desarrollo de estrategias basadas en modelo entrada salida que sean capaz de detectar en línea las fallas y localizarlas.

1.6. Alcance

Dentro de este tema de tesis se desarrolla un esquema de detección y diagnóstico de fallas el cual se ejecuta cuando el sistema se encuentra a 860 RPM lo que equivale a que el vehículo se encuentre en ralentí, dicho esquema será capaz de cumplir con las siguientes características:

- Con el esquema FDD se podrá realizar en línea la clasificación correcta de fallas en inyectores.
- El esquema FDD podrá reconocer fallas abruptas en cada uno de los inyectores del sistema.

- Este esquema será validado en el sistema electrónico de inyección que usa un vehículo NISSAN Tsuru con motor de 1.6 litros.

1.7. Hipótesis

Con la implementación de un esquema de extracción de características basado en la transformada Stockwell será posible diseñar un esquema de detección y diagnóstico de fallas para los inyectores de un sistema de inyección electrónica de combustible.

1.8. Método de solución

El método de solución se lleva a cabo como se muestra en la Figura 4.1.

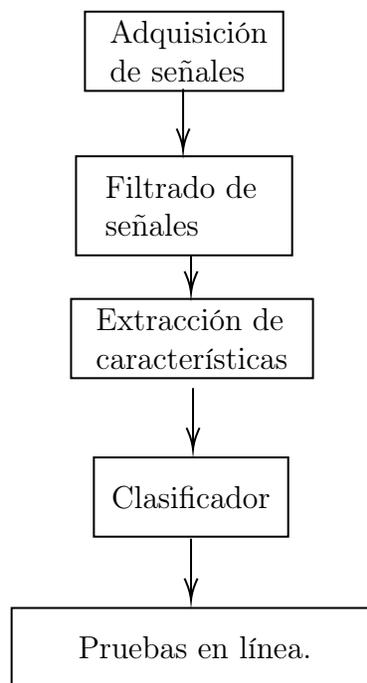


Figura 1.1: Algoritmo de solución

A continuación, se describen cada una de las etapas.

1. Adquisición de señales: en esta etapa se utilizó el sensor MPX570DP que se muestra en la Figura 4.2 se extraen las señales, esto con ayuda de la tarjeta

MyRio 1900 basada en el software LabVIEW, mismo donde se generó un programa para detectar la señal obtenida del sistema en los diferentes escenarios propuestos (Riel de inyección sin falla, falla en inyector 1, falla en inyector 2, falla en inyector 3 y falla en inyector 4).

2. Filtrado de señales: para esta etapa se filtró la señal con la transformada de Wavelet y se recupera la misma con la transformada inversa Wavelet, esto con el fin de eliminar información innecesaria.
3. Extracción de características: en dicha etapa se realiza la extracción de las características con la transformada Stockwell, obteniendo una matriz característica.
4. Clasificador: para poder clasificar las fallas y obtener la firma de fallas, se incorpora una red neuronal extrem learning machine.
5. Pruebas en línea: Para esta última etapa se realiza un programa embebido en un FPGA, para poder aplicarlo al sistema en tiempo real.



Figura 1.2: Sensor diferencial de presión MPX5700

1.9. Organización del documento.

Este trabajo de investigación se organiza en 6 capítulos los cuales se describen a continuación.

El capítulo uno contiene la introducción del tema de investigación mostrando el problema a resolver, los objetivos, hipótesis y metas que se pretenden alcanzar en este trabajo y una explicación breve de cómo se pretende atacar el problema.

En el capítulo dos contiene un breve resumen de las investigaciones relacionadas con este tema de investigación además se agrega el marco teórico siendo estos los fundamentos de esta investigación.

Se continua con el capítulo tres donde se describe el caso de estudio, siendo así que se menciona la importancia del sistema de inyección en el motor de combustión interna y se describe todo su funcionamiento, así como los eventos que se presentan en la detección y diagnóstico de fallas.

Por su parte en el capítulo cuatro se describe el diseño del esquema FDD propuesto en el sistema embebido.

Por otro lado, en el capítulo cinco se implementa y se muestra los resultados obtenidos del esquema FDD aplicados al sistema de inyección de un motor de combustión interna.

En el último capítulo, se concluye el trabajo de investigación además se agregan los trabajos futuros analizando las formas de mejorar en la solución del problema planteado.

Capítulo 2

Estado del arte y marco teórico

2.1. Estado del arte

En esta sección se presenta de forma breve y puntual algunas de las investigaciones que se han realizado para la detección y diagnóstico de fallas en sistemas EFI, así como el uso de ELM para la detección de fallas en diversos sistemas.

2.1.1. Detección y diagnóstico de fallas

En el trabajo que presentó Guo et al. (2021) investigaron la estructura tensorial y las características de un conjunto de datos multicanal para después proponer un método novedoso de diagnóstico de fallas introduciendo el algoritmo de aprendizaje subespacial multilineal en tecnologías de aprendizaje profundo.

En el trabajo de Verde (2013) estableció diversas definiciones relacionadas con la detección y el diagnóstico de fallas, en la que explica los diversos métodos que se pueden aplicar para dicha tarea.

En la investigación que realizó Medrano Hurtado et al. (2013) describió las diferentes fallas mas comunes que se presentan, las formas características de las señales que genera cada falla y los métodos de diagnóstico que se adecuan dependiendo del

subsistema que presenta fallas.

2.1.2. Detección y diagnóstico de fallas basado en ELM

El algoritmo ELM (Extreme Learning Machine), por sus siglas en inglés Máquina de aprendizaje de extremo a extremo.

La investigación que presentaron Yu et al. (2021) propusieron un modelo de diagnóstico de fallas inteligente y eficiente con la finalidad de ofrecer de manera oportuna y precisa en tiempo real. El modelo se basa principalmente en un algoritmo optimizador mejorado modelo de máquina de aprendizaje extremo de kernel optimizado (KELM).

En el trabajo presentado por Ding et al. (2015) presenta el uso de ELM, dicho algoritmo comparación a las redes neuronales de alimentación directa son más rápidas en su aprendizaje debido a que las ELM no utilizan el gradiente como medio de aprendizaje, dicho trabajo describe el principio y el algoritmo de ELM. Luego, pone énfasis en los métodos mejorados o las variantes típicas de ELM, especialmente en ELM incremental, ELM de poda, ELM minimizado de errores, ELM de dos etapas.

En el trabajo de Han et al. (2014) propusieron utilizar redes neuronales profundas (DNN) para extraer características de alto nivel de datos sin procesar. Primero produce una distribución de probabilidad usando DNNs. Luego construyeron características de nivel de emisión a partir de distribuciones de probabilidad a nivel de segmento. Estas características de nivel de expresión se incorporan luego a una máquina de aprendizaje extrema (ELM), una red neuronal especial simple y eficiente de una sola capa oculta, permitiendo identificar correctamente.

Horata et al. (2013) por su parte propusieron el método de Descomposición Ortogonal Extendida Completa (ECOD) para resolver el problema computacional en el cálculo de ponderaciones ELM a través del algoritmo ECODLS. En el trabajo también

se proponen otros tres algoritmos, método de mínimos cuadrados repetidos ponderados (IRWLS-ELM), ELM basado en los cuadrados menos recortados multivariantes (MLTS-ELM) y ELM basado en los MLTS ponderados de un solo paso (RMLTS-ELM) para resolver el problema de robustez atípica. Sin embargo, también encuentran el problema de computacional demandando muchos recursos. Por lo tanto, el algoritmo ECOD a través de ECODLS también se usa con éxito en los tres algoritmos propuestos.

Por otra parte Huang et al. (2012) mostraron en su trabajo de investigación como el ELM proporciona una plataforma de aprendizaje unificada con un tipo generalizado de asignaciones de características y se puede aplicar directamente en situaciones de clasificación multiclase y de regresión; además de que el punto de vista del método de optimización, el ELM tiene restricciones de optimización más leves en comparación con el LS-SVM y PSVM; por otra parte el uso LS-SVM y PSVM, logran soluciones sub-óptimas y requieren una mayor complejidad computacional; por último, el ELM puede aproximar cualquier función continua de destino y clasificar cualquier región desunida.

2.1.3. Detección y diagnóstico de fallas aplicado a sistemas de inyección electrónica

A continuación, se muestra una breve descripción de algunas investigaciones que se han orientado específicamente al sistema de inyección electrónica mismo tema del que se trata este trabajo.

En el trabajo de investigación presentado por Gao et al. (2021) se analizó la estabilidad de inyección, basándose de forma principal en la varianza de datos, determinando que el momento de mayor estabilidad se encuentra en el estado de ralentí, esto se debe a que en presencia de aceleración, dependiendo de la exigencia de RPM

(revoluciones por minuto) el sistema se vuelve más rápido por lo que al analizar el sistema a diferentes velocidades permitiría la existencia de mayor error de detección en las fallas.

Por otra parte, Zhao et al. (2021) se realizó una investigación experimental y teórica del aumento de temperatura del combustible en la boquilla de un inyector del riel de inyección. Los resultados obtenidos mostraron que la temperatura del combustible en la boquilla aumentaba rápidamente con un aumento en el tiempo de trabajo del inyector hasta llegar a estabilizarse. Una vez estabilizada, el aumento de temperatura dependía de la caída de presión de inyección. El aumento en la temperatura del combustible cuando se encuentra en la boquilla no solo se relacionó con la caída de presión, también se vio afectado por el ciclo de trabajo del pulso de inyección, reflejando la duración relativa de la inyección.

La investigación que realizaron Dhanji and Zhao (2020) muestran el comportamiento de un inyector activado por solenoide para el óptimo uso del mismo y la reducción de la contaminación.

El trabajo presentado por Namigtle-Jiménez et al. (2020) muestra la comparación de tres metodologías de aprendizaje para el aislamiento de fallas, considerando cinco escenarios en los cuales podrían estar los inyectores, en este caso se utilizó el algoritmo EML solo con el análisis de la transformada rápida de Fourier y considerando un vector de entrada.

El aporte presentado por Taghizadeh-Alisaraei and Mahdavian (2019) analizan el cambio de vibración presentado en motores con efectos de mala combustión a partir de la prueba de Welch, la Transformada rápida de Fourier, la Distribución de Wigner-Ville y la Distribución de Choi-Williams detectan los cambios generados por el motor bajo carga.

Ostrica and Jurcik (2014) mencionaron que la evaluación de la condición del sistema de inyección puede llevarse a cabo revisando la corriente y el voltaje de los inyectores durante su funcionamiento. Además aseguran que esta información puede aplicarse al OBD de los automóviles, dando la ventaja en su utilidad de poder ser aplicado a la estructura actual de detección y diagnóstico de falla de los automóviles.

Por parte, Liu et al. (2011) presentaron un esquema de detección y diagnóstico de fallas en el sistema de inyección a partir de la señal de vibración de la cabeza de los cilindros de un motor diésel, teniendo como objetivo únicamente monitorear el sistema.

Zhang et al. (2008) emplearon una red neuronal artificial en el diagnóstico de fallas de un sistema de inyección de combustible de un motor diésel. Para ello, tomaron características de señales de vibración y se construyó a partir de éstas una red neuronal, siendo esta parte del esquema de diagnóstico de fallas del sistema de inyección de combustible del motor diésel. Los autores proponen una caracterización de las señales a partir del valor promedio, valor cuadrático medio, valor promedio pico a pico, varianza y del análisis espectral para posteriormente con esto hacer uso de métodos de clasificación.

En el trabajo presentado, Manders et al. (2000) se analizó un método para detección y aislamiento de fallas en sistemas dinámicos continuos. Un aspecto clave de este enfoque es el acoplamiento de un motor de diagnóstico cualitativo y un sistema de monitorización que calcula valores de características simbólicas a través de una transformación de señal a símbolo en los datos de medición muestreados continuamente.

En la investigación presentada por Krishnaswami et al. (1995) se presentó la aplicación de un esquema de generación residual de ecuación de paridad no lineal que utiliza modelos dinámicos directos e inversos de sistemas no lineales, para el diagnóstico de fallas de sensores y actuadores en un motor de combustión interna, dividiendo

en dos etapas el proyecto, primero caracteriza el sistema y después lo analizan a altas presiones.

2.2. Marco Teórico.

En esta sección se da una explicación de las técnicas que se utilizaron para el desarrollo de este tema de tesis, con la finalidad de hacer más clara la lectura de la misma.

Primero se describirá el concepto de diagnóstico de fallas, posteriormente se abordaran algunas técnicas de procesamiento de señales para realizar la extracción de características de cada una de las señales y por último se describe el método para la clasificación de fallas.

2.2.1. Diagnóstico de fallas

Uno de los principales objetivos que existen en la creación de esquemas de detección y diagnóstico de fallas es la seguridad, esto se debe a que al presentar falla un subsistema y no ser diagnosticado y aislado a tiempo podría desencadenar daños más graves en el sistema.

Falla: es una desviación de alguna propiedad característica en un sistema de sus condiciones nominales y estándar de operación. Dichas fallas pueden ser abruptas, incipientes e intermitentes.

Fallas abruptas: regularmente se presentan con un cambio repentino, en ésta se desconoce el tiempo de duración de la misma.

Fallas incipientes: estos cambios se presentan de forma paulatina respecto al tiempo, lo que se podría considerar como desgastes o taponamientos.

Fallas intermitentes: estas últimas no tiene una evolución y aparecen regularmente de forma aleatoria, se presentan como pulsaciones de amplitud y longitud desconocida.

Avería: esta interrupción se presenta con duración permanente indicando que el sistema ya no puede desempeñar la o las tareas para el cual ha sido diseñado bajo condiciones normales.

Disfunción: en este caso el sistema pierde de forma esporádica la capacidad de llevar a cabo las funciones que le fueron asignadas durante su diseño.

La posibilidad de que un sistema pueda fallar en cualquier instante de tiempo genera la necesidad de diseñar estrategias que permitan, detectar, identificar e incluso cuantificar el tamaño de las fallas, ver Figura 2.1. Por lo que este trabajo de tesis se enfocará al diseño de una estrategia para el diagnóstico de fallas en los inyectores de un riel de inyección electrónico como se muestra a continuación.

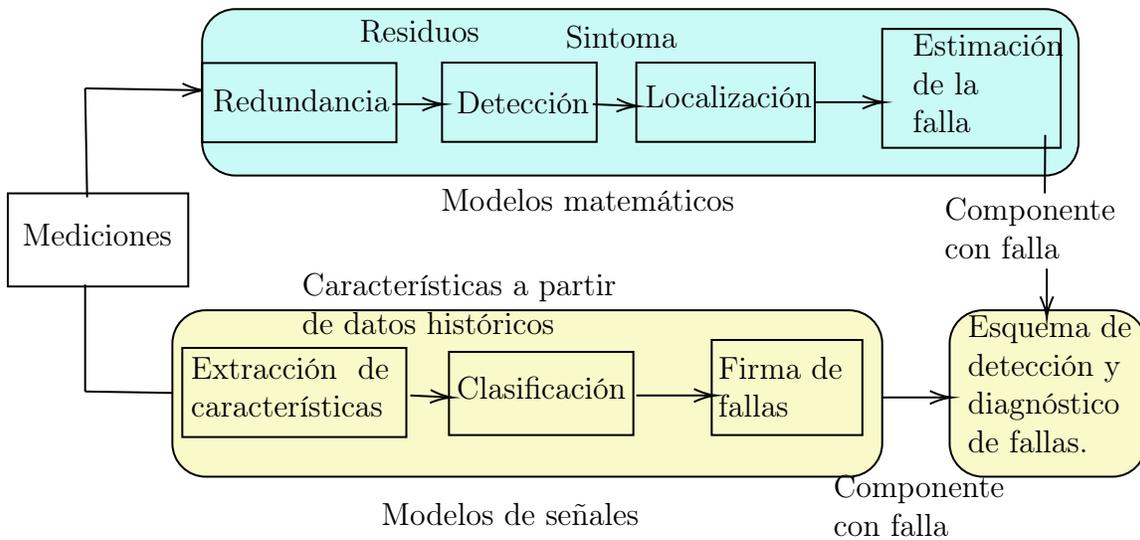


Figura 2.1: Metodología de detección y diagnóstico de fallas, basado en modelos matemáticos y señales.

En este trabajo de investigación se utilizó la metodología de modelos de señales a continuación se explica cada una de sus partes.

- Mediciones: Estas se realizaron con un sensor de presión conectado a una tarjeta MyRio que permite realizar el análisis de señales, posteriormente para las características a partir de datos históricos, se realiza la extracción de características, clasificación y firma de fallas.
- Extracción de características: este paso se realizó con el uso de la transformada Stockwell, permitiendo obtener una matriz característica.
- Clasificación: se realizó utilizando una red neuronal basada en el algoritmo ELM.
- Firma de fallas: se obtiene a la salida de la red neuronal considerando el valor mas cercano a la unidad, obteniendo así el componente con falla para el esquema de detección y diagnóstico de falla..
- Esquema de detección y diagnóstico de fallas: la falla se diagnostica a partir de los leds que tiene incluida la tarjeta FPGA.

2.2.2. Análisis de señales

Transformada de Wavelet

Esta transformada es eficiente para el análisis local de señales no estacionarias y de rápida transitoriedad y, al igual que la transformada de Fourier con ventana, mapea la señal en una representación de tiempo-escala. La diferencia está en que la transformada Wavelet provee análisis de multiresolución con ventanas dilatadas. El análisis de las frecuencias de mayor rango se realiza usando ventanas angostas y el análisis de las frecuencias de menor rango se hace utilizando ventanas anchas.

El objetivo del análisis multiresolución es expandir una señal en una base de funciones cuyas propiedades tiempo-frecuencia se adapten a la estructura local de la señal. La transformada Wavelet permite obtener el desarrollo de una señal en una base ortonormal de funciones wavelets, las cuales tienen propiedades de localización en tiempo y frecuencia similares a la transformada de Fourier con ventana Pradhan

and Mansinha (2020).

Las Wavelets, son generadas partiendo de una función Wavelet madre, utilizando traslaciones y dilataciones. Permitiendo así reconstruir la señal real a través de la transformada Wavelet inversa.

Esta transformada no es solamente local en tiempo, también lo es en frecuencia. Dentro de los diversos usos de esta herramienta en el presente trabajo se enfocará solo para la compresión y el procesar las imágenes y reconocimiento de patrones.

En (2.1) se muestra a las wavelets creadas partiendo de la wavelet madre $\Psi(t)$ por las traslaciones y las dilataciones discretas

$$\Psi_{i,k}(t) = 2^{-\frac{i}{2}} \Psi(2^{-i}t - k). \quad (2.1)$$

Una vez que la transformada de Fourier $\Psi(w)$ que proviene de la wavelet madre satisface la condición de ortogonalidad, las traslaciones discretas de la wavelet madre $\Psi(2^{-i}t - k)$ generan una base ortonormal para cada una de la escala 2^i en (2.2).

$$(\phi_{i,k}, \Psi_{i,n}) = 2^{-i} \int \phi_i(t - k) \Psi_i(t - n) dt = 0. \quad (2.2)$$

para todo k y $n \in Z$.

El análisis multiresolución realiza la expansión de una señal para obtener una base de funciones de sus propiedades tiempo-frecuencia se adecúen a la estructura local de la señal. Esta transformada permite al usuario obtener el desarrollo de una señal dando una base ortonormal de funciones wavelets, estas tienen propiedades de localización en tiempo y frecuencia, en trabajos como, Grispino et al. (2013), Monteiro et al. (2018), H. Barizão et al. (2020) el uso de esta herramienta ofrece una mejor lectura de los datos.

Transformada de Stockwell

Para extraer las características de las señales se utilizó la transformada Stockwell misma que en el trabajo que presentaron Čurović et al. (2021) obtuvieron resultados adecuados. Esta transformada es una modificación de la transformada de Fourier con ventana, utilizando una ventana variable según la distribución de la frecuencia analizada como se muestra en (2.3).

$$\begin{aligned}
 S(\tau, f) &= \int_{-\infty}^{+\infty} S(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{f^2(\tau-t)^2}{2}} e^{-i2\pi ft} dt, \\
 S(\tau, f) &= \int_{-\infty}^{+\infty} S(t) w(\tau-t) e^{-i2\pi ft} dt, \\
 w(\tau-t) &= \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(\tau-t)^2}{2\sigma^2}}, \\
 \int \sigma &= \frac{1}{|f|}.
 \end{aligned} \tag{2.3}$$

la matriz de Stockwell es obtenida como en

(2.4).

$$\int s(kt, \frac{n}{NT}) = \begin{bmatrix} S(0, 0) & S(T, 0) & \cdots & S(kT, 0) \\ S(0, \frac{1}{NT}) & S(T, \frac{1}{NT}) & \cdots & S(kT, \frac{1}{NT}) \\ \vdots & \vdots & \ddots & \vdots \\ S(0, \frac{n}{NT}) & S(T, \frac{n}{NT}) & \cdots & S(kT, \frac{n}{NT}) \end{bmatrix} \tag{2.4}$$

donde T es el intervalo de tiempo entre dos muestras consecutivas, N la longitud de la señal analizada y $(k, n) = 0, 1, \dots, N - 1$.

2.2.3. Extreme Learning Machine (ELM)

Las máquinas de aprendizaje extremo (Extreme Learning Machine) por sus siglas en inglés son redes neuronales avanzadas para clasificación, regresión, agrupamiento, aproximación dispersa, compresión y aprendizaje de características con una sola capa o múltiples capas de nodos ocultos.

Dada una sola capa oculta de ELM suponiendo que la función de salida del $i - th$ el nodo oculto es $h_i(X) = G(a_i, b_i, x)$ donde a_i y b_i son los parámetros ocultos del $i - th$ nodo oculto.

Dado N muestras de entrenamiento, la matriz de salida de la capa oculta, H de ELM se da como en (2.5).

$$H = \begin{bmatrix} h(x1) \\ \vdots \\ h(xN) \end{bmatrix} = \begin{bmatrix} G(a1, b1, x1) & \cdots & G(aL, bL, x1) \\ \vdots & \vdots & \vdots \\ G(a1, b1, xN) & \cdots & G(aL, bL, xN) \end{bmatrix} \quad (2.5)$$

y T es la matriz objetivo de datos de entrenamiento dada en (2.6).

$$T = \begin{bmatrix} t1 \\ \vdots \\ tN \end{bmatrix} \quad (2.6)$$

En este trabajo se utiliza para la clasificación, dada una función de activación por partes $f(x)$ luego del mapeo aleatorio de capas ocultas $h(x)$ puede separar regiones no juntas arbitrarias de cualquier forma. Sin embargo, la entrada a utilizarse será de doble dimensión, por lo que se debe, calcular la matriz de salida de la capa oculta como en (2.7).

$$H_{ij} = g(U_i^T A_j v_i + b_i) \quad (2.7)$$

donde H_{ij} es la salida de $i - th$ nodo oculto de la entrada $j - th$. Por lo tanto, cada nodo oculto obtiene la información de la matriz A_j a través de diferentes pesos aleatorios U_i, V_i y b_i .

Esto se resuelve considerando (2.8).

$$\beta^* = H^\dagger y \tag{2.8}$$

donde H^\dagger es el inverso generalizado Moore-Penrose de la matriz de H .

Capítulo 3

Caso de estudio

En este tema de tesis se trabajó con el sistema de inyección electrónica de combustible de un motor a gasolina. Dicho sistema se observa en la Figura 3.1.

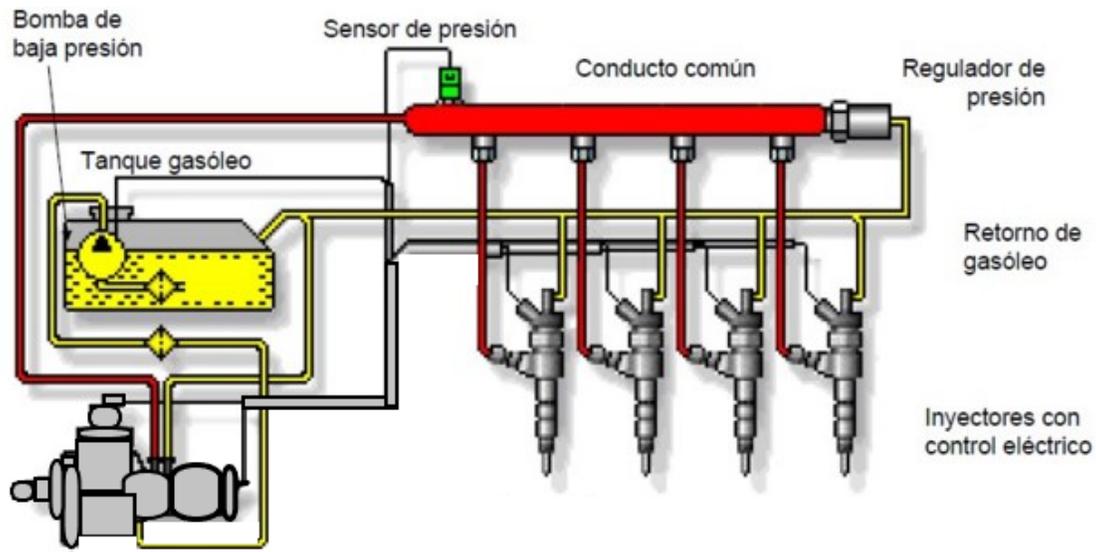


Figura 3.1: Sistema de inyección electrónica

El sistema es un riel de inyectores de un motor de combustión interna de inyección

directa, multipunto y secuencial.

La principal función del sistema es liberar la cantidad de combustible exacta en el tiempo correcto, con la finalidad de lograr una correcta relación estequiométrica y así mismo una combustión necesaria, asegurando el buen desempeño del motor.

Dicho sistema será controlado por el sistema embebido NI-MyRIO como la que se muestra en la Figura 3.2. Este dispositivo cuenta con un FPGA Xilinx Z-7010 configurado en una primera parte para la manipulación de entradas y salidas del tipo digitales y analógicas. En una segunda parte funciona como un procesador Xilinx LabVIEW Real Time de dos núcleos que opera a 667Mhz. El procesador y el FPGA operan en sincronía con una comunicación bilateral.

La tarjeta está basada en la plataforma LabVIEW, lo que requiere programación visual.

Dentro de la misma tarjeta una vez realizado el sistema embebido para la prueba en línea, los leds con los que cuenta la tarjeta servirán como señal indicadora de cuál inyector está fallando, cabe mencionar que las pruebas se realizan solo para una falla, no se considera la presencia de más de una falla, de tal forma que el led 0 corresponde a la falla en inyector 1, led 1 a falla en inyector 2, led 2 falla en inyector 3 y led 3 falla en inyector 4, una vez que el sistema detecte la falla el led correspondiente se encenderá.

Cabe mencionar que el sistema de detección y diagnóstico de fallas una vez iniciado solo toma 2000 datos los cuales utiliza para diagnosticar si la falla se encuentra presente, el motivo de utilizar 2000 datos es debido a que experimentalmente con esa cantidad de datos se tuvo una satisfactoria clasificación.

El sistema que se utiliza para llevar a cabo las pruebas se encuentra constituido



Figura 3.2: Tarjeta NI myRIO

por:

- Un riel de inyectores: está constituido por los cuatro inyectores, los cuales tienen una secuencia de encendido 4-3-2-1 y un sensor de vacío mismo que en el sistema sirve para compensar la pérdida de presión dentro del riel.
- El sensor de vacío: la utilidad de este dispositivo es compensar las pérdidas de presión lo que lo vuelve un elemento muy importante del sistema por lo que se conectó a una pistola de presión para compensar el vacío del motor, para poder considerarlo ideal, ya que de variar el vacío producido en este automáticamente la presión en el riel de inyección se ve afectada.
- Un medidor de presión mecánico, que garantiza que las mediciones realizadas sean correctas y de no ser correctas poder verificar que elemento está mal conectado o calibrado.

- Juego de cuatro relevadores, estos están conectados a la salida de la tarjeta MyRio la cual da la señal de encendido de cada uno de los inyectores, esto se debe a que la tarjeta no cuenta con la alimentación suficiente en sus salidas para activar el estado nominal de los inyectores.
- Una fuente de alimentación con diferentes valores a la salida, esto con la finalidad de poder alimentar a los inyectores, la bomba de gasolina, los relevadores y la tarjeta donde se encuentra el sistema embebido.
- Filtro de gasolina a este se le da mantenimiento preventivo recurrentemente debido a que se considera ideal y de no estar en óptimas condiciones podría afectar la detección.
- Bomba de gasolina, esta se encuentra dentro del recipiente de gasolina mismo que no debe estar por debajo del 40% de su capacidad con el fin de asegurar que la bomba se encuentre en los parámetros normales de presión para poder considerarlo como elemento ideal.
- Recipiente con gasolina, este generalmente se encuentra por encima del 50% de su capacidad, con el fin de no afectar a los elementos que dependen de este.
- La computadora que se utiliza para las pruebas fuera de línea cuenta con: 12 GB de RAM, 1000 GB en disco duro, procesador Intel i7 a 2.0 GHz con software Windows 10 student, LabVIEW 2017 así como sus complementos y Matlab R2017a.

Capítulo 4

Diseño del FDD

En el diseño del esquema de detección y diagnóstico de fallas, FDD (fault detection diagnosis) por sus siglas en inglés, primero se extraen los datos de presión del sistema y se analizan con el uso del software MatLab, en forma esquemática quedaría como se muestra en la Figura 4.1.

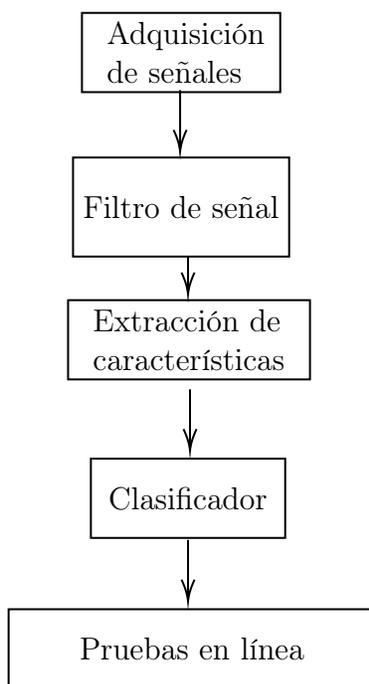


Figura 4.1: Algoritmo de solución

4.1. Adquisición de señales

En la adquisición de las señales se utiliza el sensor MPX5700dp conectado a la tarjeta MyRio que mediante el programa que se muestra en la Figura 4.2, se adquieren señales las cuales presentan bastante ruido como se muestra en la Figura 4.3.

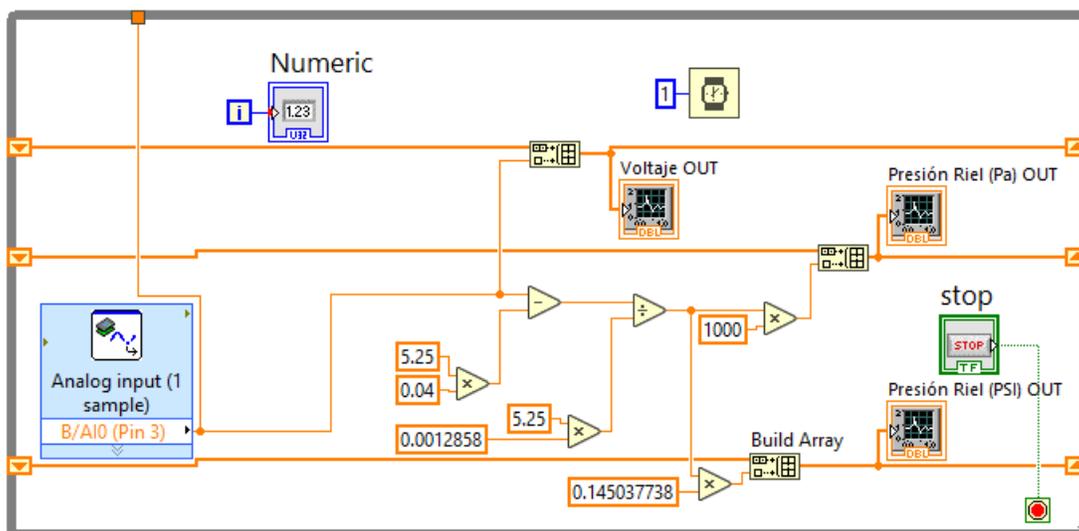


Figura 4.2: Programa en LabView

Estas señales obtenidas presentan poco legibilidad, por lo que se debe de utilizar otras metodologías que puedan representar de mejor forma cada una de las situaciones.

4.1.1. Filtro de señal

Usando la transformada de wavelet y su inversa se puede realizar un filtro, esto se puede realizar reconstruyendo solo las frecuencias entre las que trabaja el sistema, en este caso la lectura es de 1000 muestras por segundo, su rango de trabajo se encuentra entre $[7.8125 - 500]$ sintonizando se encuentra una mejor representación en los rangos de frecuencia de $[10 - 80]$ de ello se obtiene una mejor señal como se muestra en la Figura 4.4, la importancia de este filtro se debe a que si no se realiza este tratamiento a las señales los tratamientos posteriores no tienen buena respuesta, además de que dicho resultado otorga una visión más clara de cómo se comporta el sistema, ya que permite observar las caídas de presión continuas que corresponden a

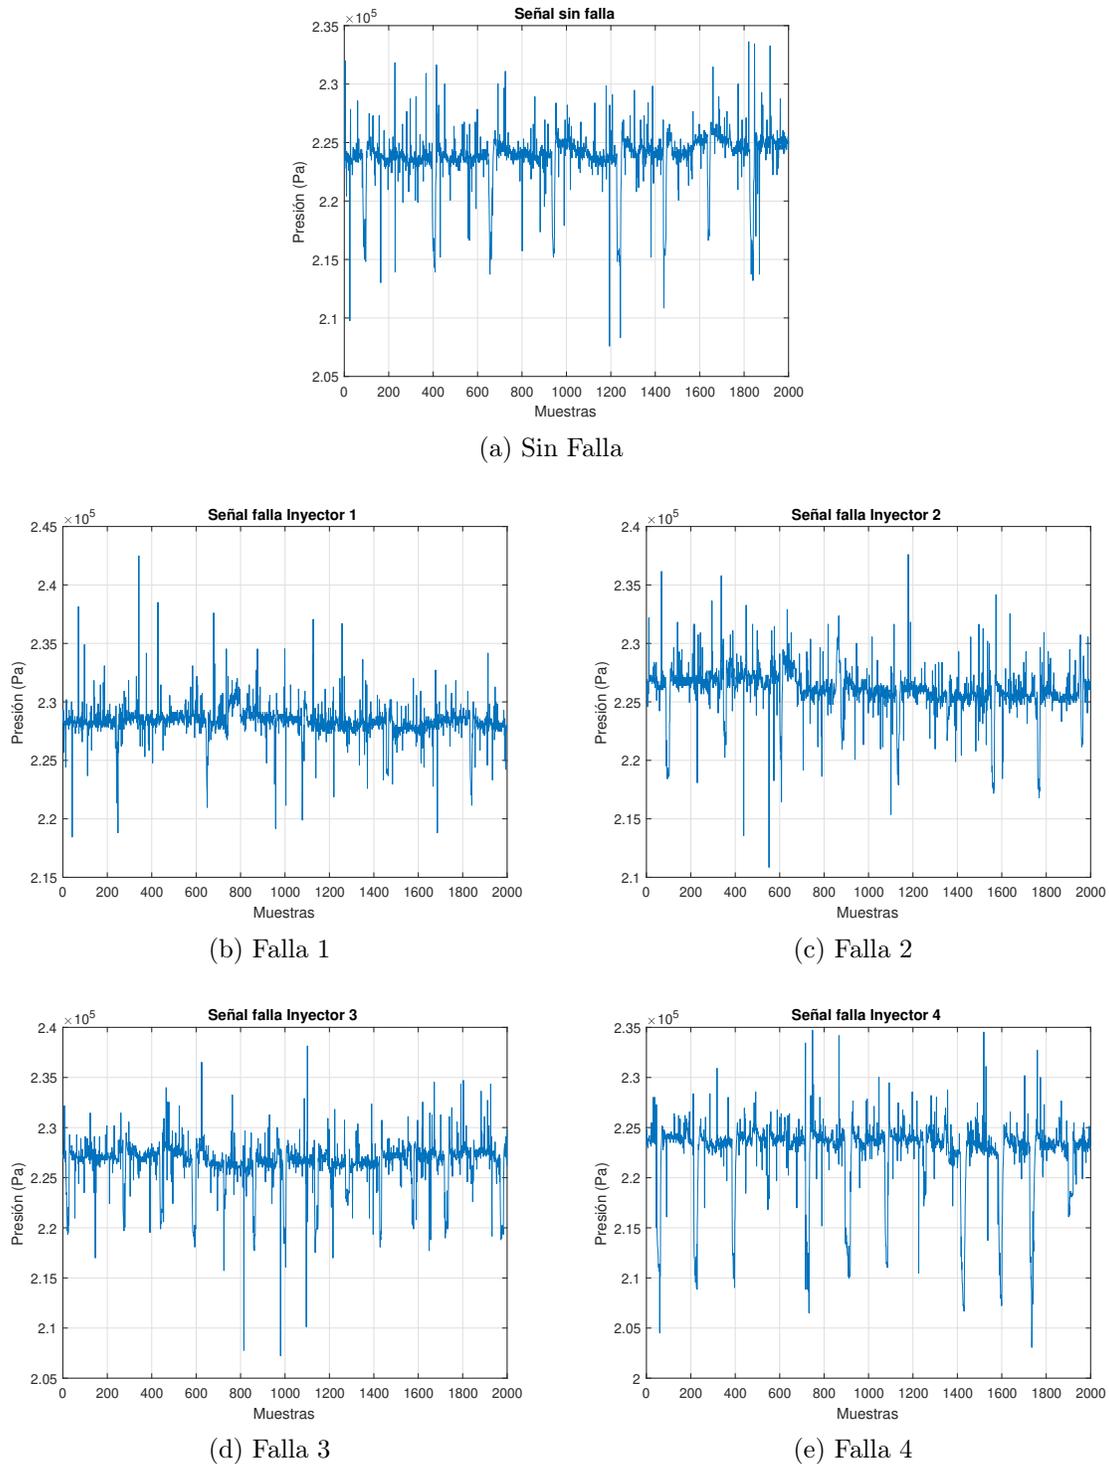
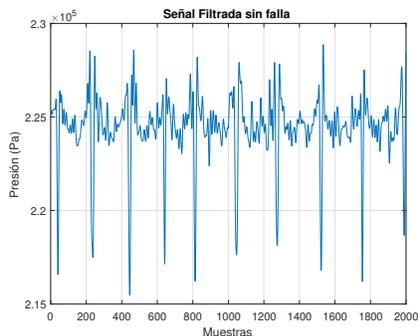


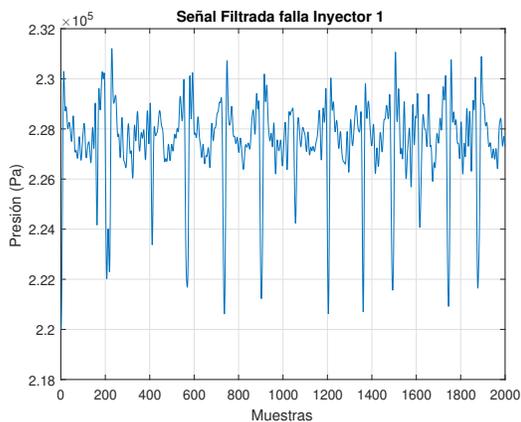
Figura 4.3: Adquisición de señales, mismas que no permiten distinguir la falla, por el exceso de ruido.

la salida de gasolina del inyector a diferencia de cuando se presenta una falla, en la

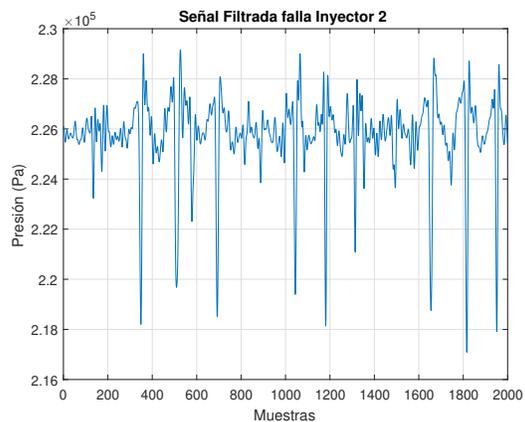
cual se muestra que no hay registró de caídas de presión.



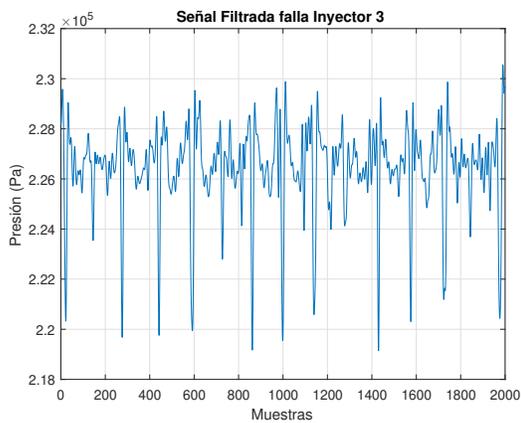
(a) Sin Falla



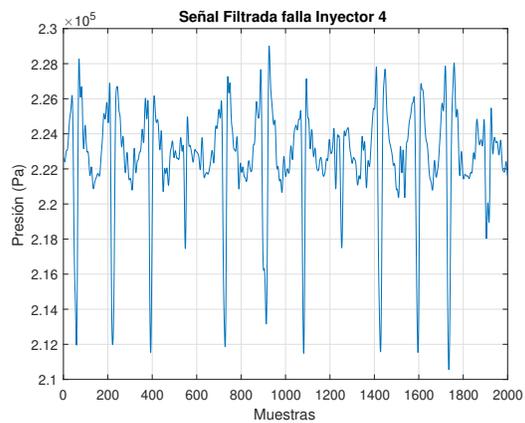
(b) Falla 1



(c) Falla 2



(d) Falla 3



(e) Falla 4

Figura 4.4: Señal filtrada, donde se aprecia la falla en las partes donde la caída de presión no es continua.

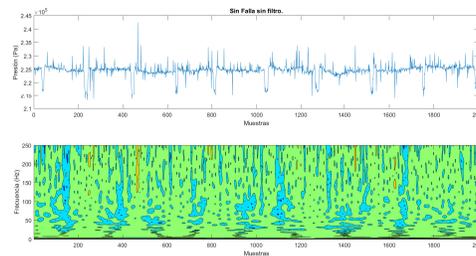
4.1.2. Extracción de características

En el trabajo presentado por Ola et al. (2018) utilizaron la transformada de Stockwell para la extracción de características obteniendo buen desempeño para la clasificación de fallas, en el que se utilizaron la extracción de medias ponderadas, en la presente investigación se extrae la matriz S la que incluye características particulares del evento presentado. Dicha matriz es introducida a una red neuronal para su posterior clasificación y toma de decisiones de las fallas. En la Figura 4.5 se muestra la importancia del uso de un previo tratamiento, esto debido a que al ser sometida la señal a la transformada Stockwell muestra poca percepción de diferencias en los diferentes eventos presentados en el sistema y en la Figura 4.6 se muestra un mejor cambio aparente al ser previamente tratada y posteriormente sometida a la Transformada Stockwell para la extracción exitosa de la matriz de Stockwell, misma que servirá como elemento característico de la señal.

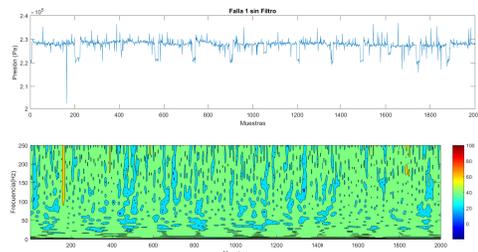
De la matriz de Stockwell generado que es de $M_s = [1001 \times 2000]$ se utiliza solo la matriz cuadrada $M_{sc} = [1000 \times 1000]$ para el entrenamiento y el resto para la validación, se realiza una matriz cuadrada para poder introducir los datos a la red neuronal.

4.1.3. 2D Extreme Learning Machine

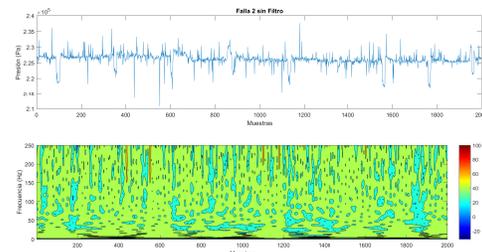
Para este trabajo no se puede utilizar la metodología convencional, por lo que se deberá utilizar la red Two-Dimensional Extreme Learning Machine siendo la única diferencia que a la entrada tiene una matriz y no un vector, la ventaja que tenemos al utilizar esta metodología se encuentra en que los pesos que se encuentran en los nodos ocultos y los sesgos se asignan aleatoriamente y no es necesario ajustarlos ya que su respaldo matemático lo permite, el algoritmo de clasificación se determina como se muestra en la Figura 4.7 las salidas de las neuronas están dentro de un rango de $1a - 1$ por lo cual se utiliza un algoritmo on-off para la toma de decisión sobre donde se encuentra la falla y mandar la señal correcta, dicho algoritmo realiza las tareas de



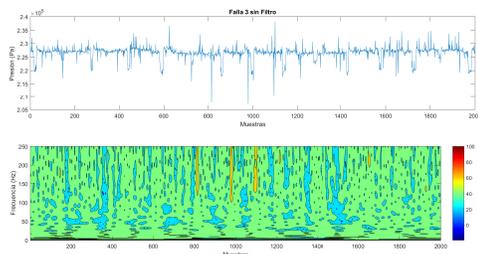
(a) Sin Falla



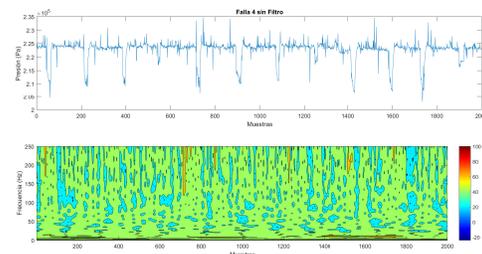
(b) Falla 1



(c) Falla 2



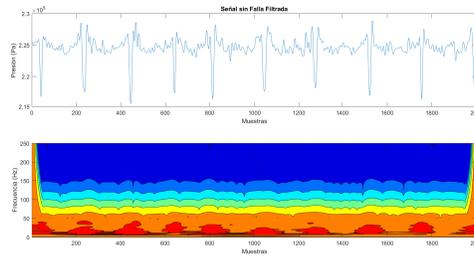
(d) Falla 3



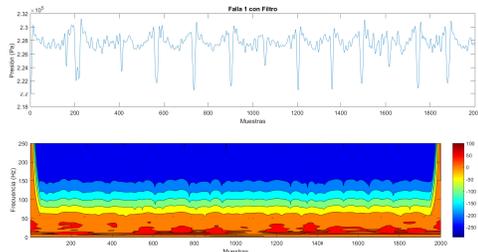
(e) Falla 4

Figura 4.5: Señales sin filtro, donde no se aprecia la falla

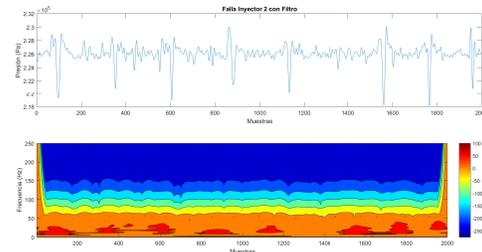
la siguiente forma: considerando s_1 como salida 1, s_2 como salida 2, s_3 como salida 3, s_4 como salida 4, s_5 como salida 5. La salida 1 $s_1 > s_2$ así como $s_1 > s_3$, $s_1 > s_4$ y $s_1 > s_5$ si esto se cumple la tarea se termina y no se enciende ningún led, ya que no existe falla. Si no, se considera la salida 2 $s_2 > s_1$, $s_2 > s_3$, $s_2 > s_4$ y $s_2 > s_5$ si esto se cumple se manda la señal a encender el led 0 correspondiente a la falla 1. Si no, se considera la salida 3 $s_3 > s_1$, $s_3 > s_2$, $s_3 > s_4$ y $s_3 > s_5$, de cumplir ello se manda a encender el led 1 correspondiente a la falla 2 y así consecutivamente con las otras dos salidas restantes, si no, se detecta con anterioridad, es importante mencionar que este sistema solo mapea la falla una sola vez, al inicio de cada arranque del motor, por lo que se debería iniciar nuevamente el sistema para volver a aplicar el esquema



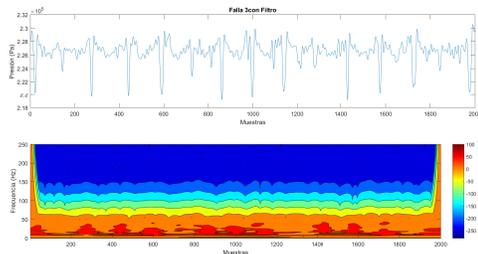
(a) Sin Falla



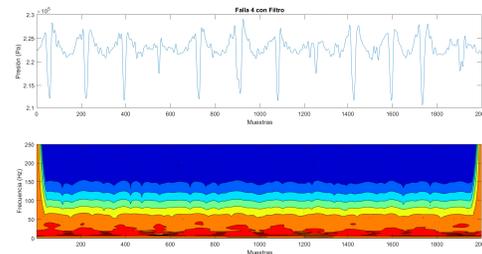
(b) Falla 1



(c) Falla 2



(d) Falla 3



(e) Falla 4

Figura 4.6: Señales con filtro, se puede ver la falla en la falta de los puntos rojos.

de detección y diagnóstico de fallas.

La estructura de la red neuronal se puede representar como se muestra en la Figura 4.8, donde se aprecia que solo cuenta con una capa oculta y las salidas corresponden a los eventos considerados en este trabajo, siendo así las entradas correspondientes a las diversas clases las cuales se introducen en forma de matriz.

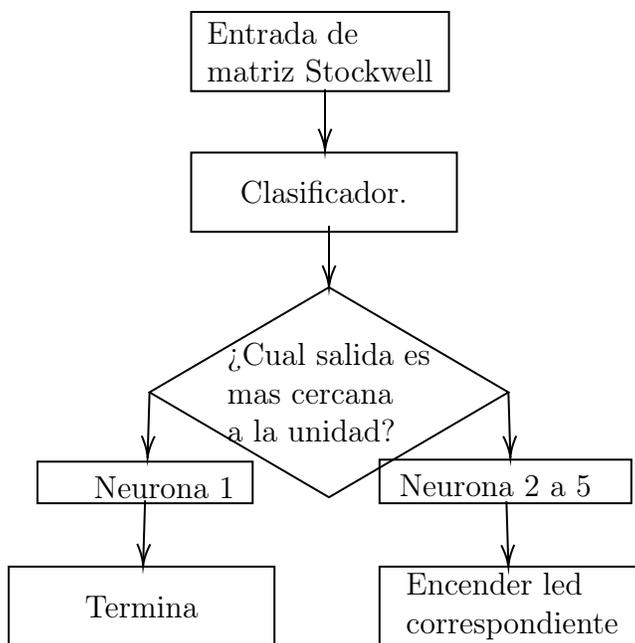


Figura 4.7: Algoritmo del esquema de detección y diagnóstico de fallas.

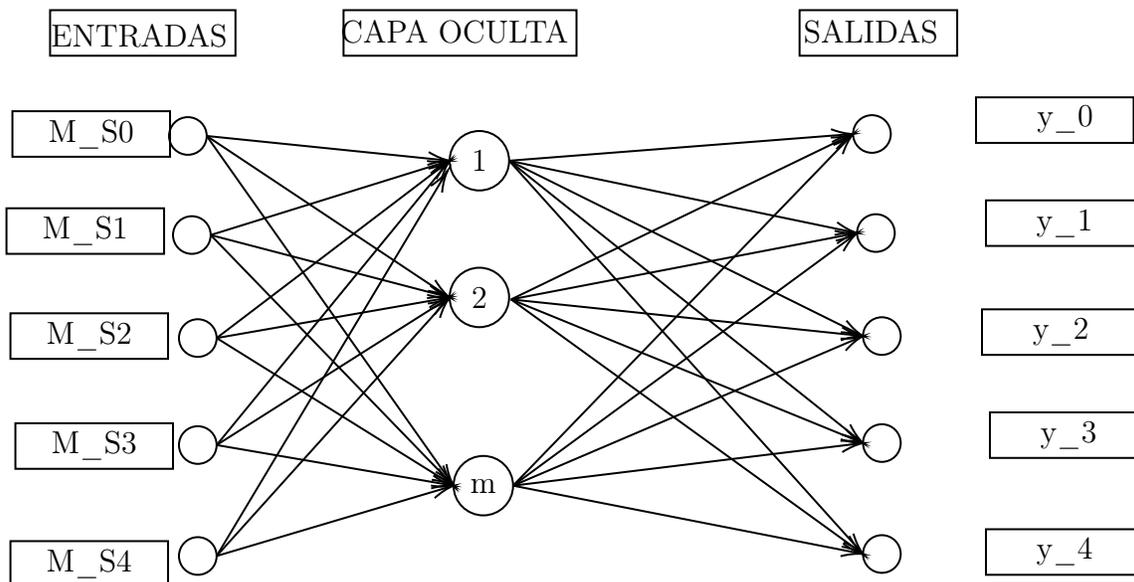


Figura 4.8: Arquitectura de la red neuronal.

4.2. Pruebas fuera de línea

Los resultados presentados en la Tabla 4.1 corresponden a la validación fuera de línea del esquema de detección y diagnóstico desarrollado dichos valores corresponden a la media aritmética de las 20 veces que se corroboró.

Falla	Transformada Stockwell	Red Neuronal	Tiempo	Porcentaje de eficiencia
0	0.130130 s	44.3609 s	44.491030 s	95 %
1	0.18070 s	39.69825 s	39.87895 s	100 %
2	0.0985 s	45.26523 s	45.36373 s	98 %
3	0.2358 s	41.3658 s	41.6016 s	98 %
4	0.1638 s	40.2036 s	40.3674 s	90 %

Tabla 4.1: Tabla de pruebas a nivel simulación

En la Tabla 4.1 se presentan los resultados de veinte pruebas para cada caso en el que el tiempo y el porcentaje de eficiencia fue promediado. Con base en esta tabla se puede observar que el porcentaje promedio para la detección de fallas es de 96.2%, además de que el tiempo promedio que se requiere para realizar las simulaciones es de 42,34s en la Figura 4.9 se muestra el sistema y la aplicación fuera de línea.



Figura 4.9: Prueba fuera de línea

Capítulo 5

Implementación y resultados

Para realizar la implementación se utilizó la tarjeta My-RIO, esto debido a que permite realizar un programa embebido en la tarjeta para que funcione de forma autónoma, evitando así el uso de la computadora y solo requiere ser alimentada correctamente, para la parte de los resultados se muestra la detección correcta de las fallas en los inyectores.

5.1. Sistema embebido

Para el desarrollo del sistema embebido se utilizó el módulo LabVIEW FPGA entorno en el que se adquirieron las señales, con los programas previamente realizados (VI), solo se convierte el VI a entorno FPGA. Esto se realizó en la versión 2017.

5.2. Resultados

Para las pruebas en línea se consideró un intervalo de cinco minutos por evento, esto con la finalidad de observar si existía una detección errónea de la falla.

Se consideran cinco eventos:

1. Sistema sin fallas.

2. Falla en inyector 1.
3. Falla en inyector 2.
4. Falla en inyector 3.
5. Falla en inyector 4.

Considerando que el riel cuenta con cuatro inyectores y la tarjeta NI myRIO cuenta con cuatro leds, mismos que están enumerados del cero al tres se realizan las siguientes consideraciones:

1. Sistema sin fallas no se enciende ningún led.
2. Falla en inyector 1 se enciende led 0.
3. Falla en inyector 2 se enciende led 1.
4. Falla en inyector 3 se enciende led 2.
5. Falla en inyector 4 se enciende led 3.

Sistema sin falla: para este evento se esperaron cinco minutos para determinar que efectivamente el esquema de detección no había detectado ninguna falla teniendo una aproximación del 100 %.

Falla en el inyector 1: se obtuvo una respuesta promedio en un tiempo de tres minutos con quince segundos y se esperaban los cinco minutos para verificar que no detectara en forma errónea, el esquema tuvo una aproximación del 96 %.

Falla en el inyector 2: como se muestra en la Figura 5.1 el led se enciende correctamente, trabajando con un tiempo promedio de detección de dos minutos con 55 segundos al igual se da el lapso de cinco minutos para verificar el desempeño del esquema, mismo que tuvo una aproximación del 95 %.



Figura 5.1: Aislamiento en falla del inyector 2

Falla en el inyector 3, como se muestra en la Figura 5.2 el led correspondiente se encuentra correctamente encendido, en promedio el esquema tardo un minuto con 35 segundos para la correcta detección, el desempeño del esquema contó con una aproximación del 98 %.

Falla en el inyector 4, como se muestra en la Figura 5.3 el led correspondiente se activa en forma correcta con un tiempo promedio de detección de cuatro minutos con seis segundos, el desempeño del esquema que tuvo al detectar la falla correcta fue del 90 %.

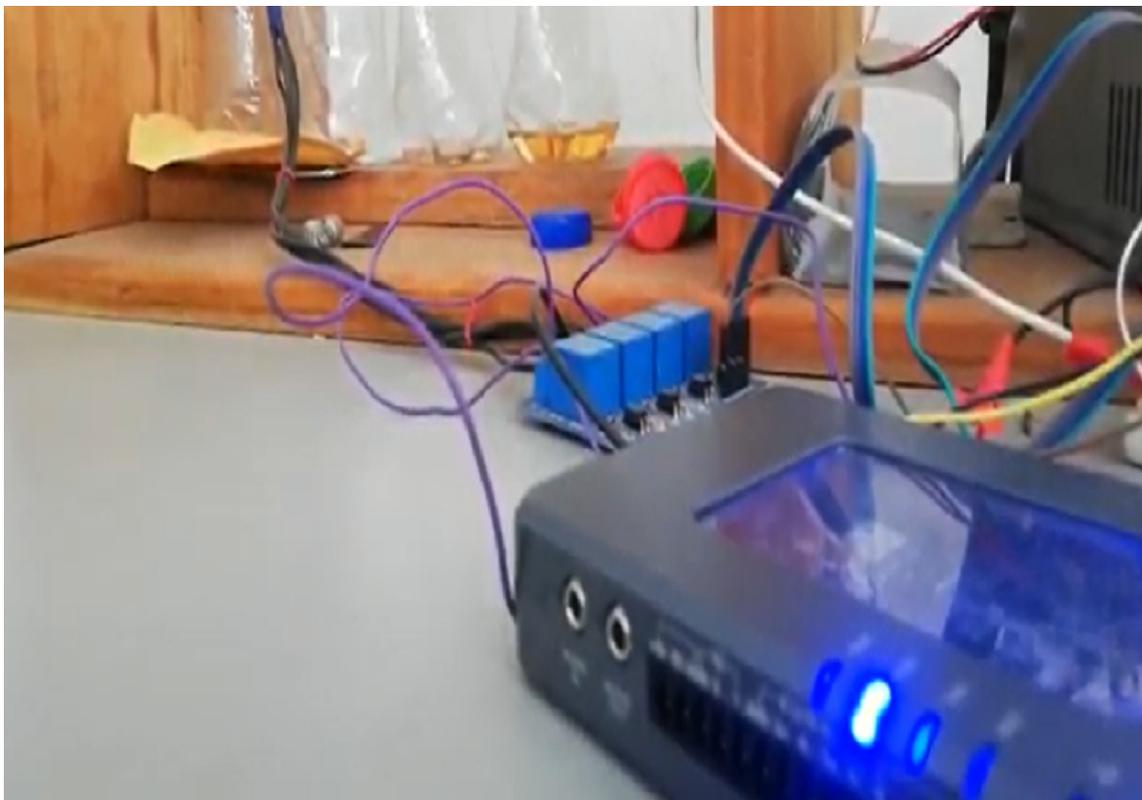


Figura 5.2: Aislamiento en falla del inyector 3

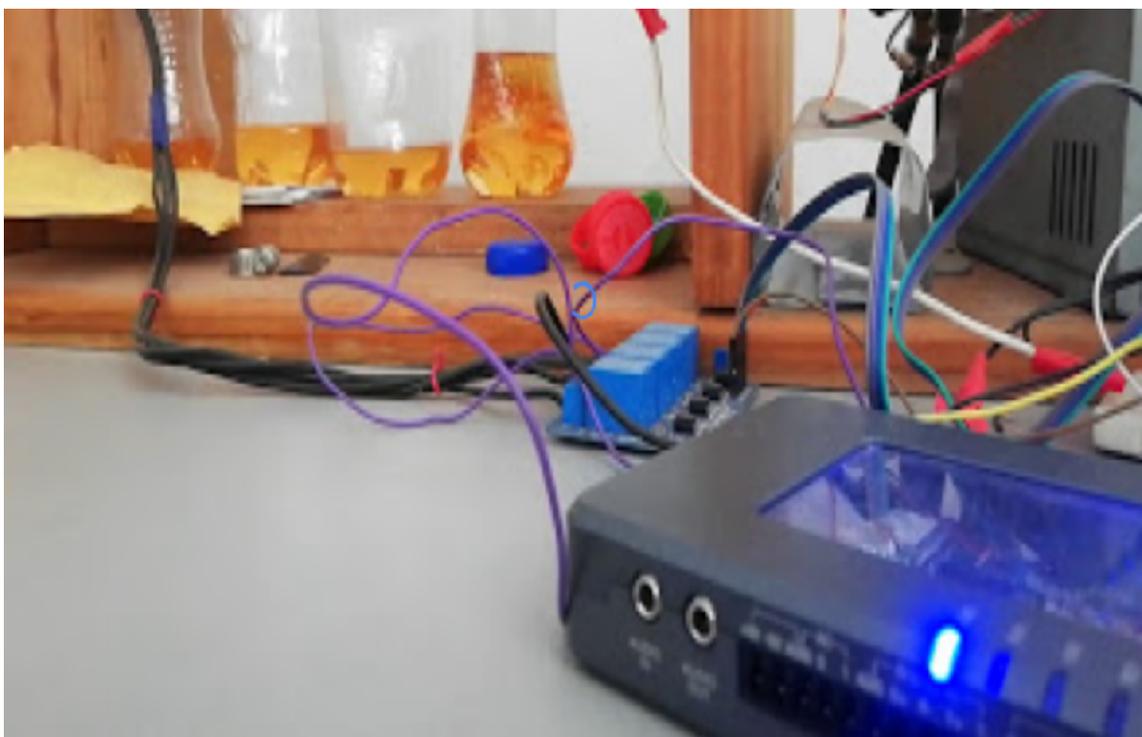


Figura 5.3: Aislamiento en falla del inyector 4

Capítulo 6

Conclusión y trabajos futuros

6.1. Conclusión

El trabajo presentado da como principal aporte el uso de la transformada Stockwell con la red neuronal Extreme Learning Machine de doble dimensión además de que se realizó la aplicación del algoritmo a un sistema real.

Como complemento también fue la aplicación de la transformada Wavelet para el mismo sistema, siendo esta complementaria para su posterior análisis.

Además, de que el sistema se hizo más compacto, esto gracias al embebido de la tarjeta MyRio®.

Aunque los tiempos fueron mayores relativamente a algunas investigaciones anteriores el trabajo logro una eficiencia en línea del 95 % siendo un desempeño que logro las expectativas de la investigación.

En el Anexo A se muestra el artículo de divulgación científica que se presentó en la sexta jornada de ciencia aplicada.

6.2. Trabajos futuros

Por otra parte, el programa se puede optimizar, esto daría pauta a un probable mejor desempeño del sistema. Esto sería restringiendo la matriz de Stockwell ya que los valores significativos se encuentran en el rango de $[1Hz - 50Hz]$, por lo que al depurar esa carga innecesaria se podría disminuir la cantidad de neuronas utilizadas, tanto a nivel simulación como en la aplicación al sistema real.

También se podrían depurar los programas para el filtro y la extracción de características.

Por último, diseñar una tarjeta especializada para este tipo de problema esto daría la ventaja de ser rápida la detección y diagnóstico de las fallas al no tener salidas y entradas extras que no son utilizadas.

Bibliografía

- Albarracín, Ángel y Huiñisaca, J. (2015). *Director : Néstor Rivera*. PhD thesis.
- Alippi, C., Russis, C. D., and Piuri, V. (2003). A neural-network based control solution to air-fuel ratio control for automotive fuel-injection systems. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, 33(2):259–268.
- Čurović, L., Murovec, J., Novaković, T., Prislán, R., and Prezelj, J. (2021). Stockwell transform for estimating decay time at low frequencies. *Journal of Sound and Vibration*.
- Dhanji, M. and Zhao, H. (2020). Investigations of Split Injection Properties on the Spray Characteristics Using a Solenoid High-pressure Injector. *International J of Engine Research*, 02(11).
- Ding, S., Zhao, H., Zhang, Y., Xu, X., and Nie, R. (2015). Extreme learning machine: algorithm, theory and applications. *Artificial Intelligence Review*.
- Filipczyk, J. (2013). Causes of automotive turbocharger faults. *Transport Problems*, 8(2):5–10.
- Gao, Z., Li, G., and Li, H. (2021). Experiment investigation of injection parameters effects on injection stability of a high pressure common rail system. 104(3):1–16.
- Gertler, J. J., Costin, M., Fang, X., Hira, R., Kowalczyk, Z., and Luo, Q. (1993). Model-based on-board fault detection and diagnosis for automotive engines. *Control Engineering Practice*, 1(1):3–17.

- Grispino, A. S., Petracca, G. O., and Dominguez, A. E. (2013). Comparative analysis of wavelet and EMD in the filtering of radar signal affected by brown noise. *IEEE Latin America Transactions*, 11(1):81–85.
- Guo, Y., Zhou, Y., and Zhang, Z. (2021). Fault diagnosis of multi-channel data by the CNN with the multilinear principal component analysis. *Measurement: Journal of the International Measurement Confederation*.
- H. Barizão, A., H. Yoshizumi, V., H. Spatti, D., E. Dajer, M., and A. Flauzino, R. (2020). Estimación Inteligente do Grau Geral de Desvio Vocal Utilizando Transformada Wavelet Packet.
- Han, K., Yu, D., and Tashev, I. (2014). Speech emotion recognition using deep neural network and extreme learning machine. In *Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH*.
- Horata, P., Chiewchanwattana, S., and Sunat, K. (2013). Robust extreme learning machine. *Neurocomputing*.
- Huang, G. B., Zhou, H., Ding, X., and Zhang, R. (2012). Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*.
- Krishnaswami, V., Luh, G., and Rizzoni, G. (1995). Nonlinear parity equation based residual generation for diagnosis of automotive engine faults. *Control Engineering Practice*, 3(10):1385–1392.
- Liu, J., Shi, Y., Zhang, X., Xu, S., and Dong, L. (2011). Fuel injection system fault diagnosis based on cylinder head vibration signal. *Procedia Engineering*, 16:218–223.
- Mahmoud Mufeed, J. J. (2003). *Active fault tolerant control systems: stochastic analysis and synthesis*. Springer.

- Manders, E. J., Biswas, G., Mosterman, P. J., Barford, L. A., and Barnett, R. J. (2000). Signal interpretation for monitoring and diagnosis, a cooling system testbed. *IEEE Transactions on Instrumentation and Measurement*, 49(3):503–508.
- Medrano Hurtado, Z. Y., Pérez Tello, C., de Armas Teyra, M. A., and Amaro Hernández, C. (2013). a Survey on Location, Detection and Fault Diagnosis in Electrical Machines. *Ciencia e Ingeniería Neogranadina*.
- Monteiro, D. D. A., Zvietcovich, W. G., and Braga, M. F. (2018). Detection and classification of power quality disturbances with wavelet transform, decision tree algorithm and support vector machines. *SBSE 2018 - 7th Brazilian Electrical Systems Symposium*.
- Montiel, D. (2016). Detección y Diagnóstico de Fallas en Sistema de Inyección de Combustible de un Motor de Combustión Interna.
- Namigtle, A. (2018). Diagnóstico de fallas en línea en el sistema EFI de un motor de combustión interna basado en redes neuronales artificiales.
- Namigtle-Jiménez, A., Escobar-Jiménez, R. F., Gómez-Aguilar, J. F., García-Beltrán, C. D., and Téllez-Anguiano, A. C. (2020). Online ANN-based fault diagnosis implementation using an FPGA: Application in the EFI system of a vehicle. *ISA Transactions*.
- Ola, S. R., Saraswat, A., Goyal, S. K., Jhajharia, S. K., and Mahela, O. P. (2018). A technique using stockwell transform based median for detection of power system faults. In *8th IEEE Power India International Conference, PIICON 2018*.
- Ostrica, L. and Jurcik, J. (2014). Detection of faults gasoline injection system for new OBD systems. *10th International Conference, ELEKTRO 2014 - Proceedings*.
- Pradhan, P. M. and Mansinha, L. (2020). Compact S-transform for analysing local spectrum. *IET Signal Processing*.

- Taghizadeh-Alisaraei, A. and Mahdavian, A. (2019). Fault detection of injectors in diesel engines using vibration time-frequency analysis. *Applied Acoustics*.
- Verde, C. (2013). *Monitoreo y Diagnóstico Automático de fallas en sistemas dinámicos*. Trillas.
- Yu, H., Yuan, K., Li, W., Zhao, N., Chen, W., Huang, C., Chen, H., and Wang, M. (2021). Improved Butterfly Optimizer-Configured Extreme Learning Machine for Fault Diagnosis. *Complexity*.
- Zhang, B., Yan, J., and Tian, C. (2008). Study on Fault Diagnosis System of Diesel Engine Fuel Injection System Based on BP Neural Network. *2008 ISECS International Colloquium on Computing, Communication, Control, and Management*, 2:108–112.
- Zhao, J., Lu, X., and Grekhov, L. (2021). Experimental study on the fuel heating at the nozzle of the high pressure common-rail injector. *Fuel*, 283:119281.

Apéndice A

Producto académico

Detección y diagnóstico de fallas basado en señales en un sistema de inyección electrónica de combustible.

J.J. López-Díaz * R. F. Escobar-Jiménez **
F.L. Torres-Ortiz *** J. F. Gómez-Aguilar ****
V.M. Alvarado-Martínez †

* Posgrado del Tecnológico Nacional de México / CENIDET. Int. Internado Palmira S/N, Palmira C.P.62490, Cuernavaca, Morelos, Mexico

** Tecnológico Nacional de México / CENIDET. Int. Internado Palmira S/N, Palmira C.P.62490, Cuernavaca, Morelos, México

*** Catedrático CONACYT, Universidad Nacional Autónoma de México. Ciudad Universitaria, Coyoacán, Edificio 1, Escolar 3000, Ciudad de México, D.F.

**** Catedrático CONACYT, Centro Nacional de Investigación y Desarrollo Tecnológico. Tecnológico Nacional de México. Internado Palmira S/N, Palmira C.P. 62490, Cuernavaca, Morelos, México

† Tecnológico Nacional de México / CENIDET. Int. Internado Palmira S/N, Palmira C.P.62490, Cuernavaca, Morelos, México

Abstract: Este trabajo muestra el uso de la Transformada Wavelet en combinación de la transformada Stockwell para el desarrollo de un esquema de detección y diagnóstico de fallas en un sistema de inyección electrónica (EFI) aprovechando de sus propiedades como lo es la representación de tiempo-escala por parte de las Wavelets y la transformada de Stockwell que es una modificación de la transformada de Fourier con ventana, utiliza una ventana variable según la distribución de la frecuencia analizada. Al combinar ambas transformadas y aplicarlas a una máquina de aprendizaje extremo (Extreme Learning Machine) por sus siglas en inglés, para clasificación y aprendizaje de las fallas en los diferentes inyectores del EFI.

Keywords: Transformada Wavelet, Transformada Stockwell, Extreme Learning Machine, EFI, FDD.

1. INTRODUCCIÓN

Un motor de combustión interna es una máquina que transforma energía química a energía mecánica de un combustible debido a una explosión. Esta explosión se genera por medio de una chispa dentro de una cámara de combustión. Para que esta explosión se lleve a cabo de manera eficiente debe existir una relación estequiométrica en este caso para el aire y el combustible; para el caso de la gasolina se debe tener una relación estequiométrica de 14.7 kilogramos de aire por 1 kilogramo de combustible Alippi et al. (2003). En un automóvil, la mezcla homogénea entre aire y gasolina depende del sistema de inyección.

Dicho sistema tiende a fallar debido a sobre calentamientos en otras partes del motor, fallas en la regulación de alimentación, impurezas en gasolina, separación de los cables de alimentación y su propio desgaste, lo que provoca taponamientos y desconexión en algunos casos derivando en un desempeño incorrecto del automóvil. En el trabajo presentado por Filipczyk (2013) se realizó una investigación sobre las fallas más comunes en los motores de combustión interna. Dicha investigación la llevo a cabo

en el departamento de mantenimiento de motores automotrices de la Facultad de Transporte de la Universidad Politécnica de Silesia en Polonia. En dicha investigación se recopiló información de 628 motores a partir del año 2000 hasta el 2012. El resultado de esta recopilación permitió determinar la existencia de al menos 16 fallas comunes, y además las colocó según el porcentaje de ocurrencia; de las cuales destacó en primer lugar el sistema de control eléctrico y de ignición, en segundo lugar, el sistema de enfriamiento y en tercer lugar el sistema de inyección de combustible.

En la literatura se encuentra gran diversidad de estudios sobre el EFI, tal es el caso de Gao et al. (2021) en el cual estudió la estabilidad de inyección, basado principalmente en la varianza de datos, del cual determinó que el momento de mayor estabilidad es en el estado de ralentí, por otra parte Zhao et al. (2021) investigó sobre la caída de presión del riel de inyección debido al calentamiento del combustible y en consecuencia el calentamiento del inyector, la investigación de Dhanji and Zhao (2020) realizó un análisis del comportamiento de un inyector activado por solenoide para la administración correcta de combustible

y la disminución de contaminación, finalmente Aleiferis and Papadopoulou (2021) analizó los asentamientos de combustible y la consecuencia del mismo.

En el trabajo que presentó Namigtle-Jiménez et al. (2020) se desarrolló un esquema de detección y diagnóstico de fallas basándose en un red neuronal artificial en línea, mientras que Taghizadeh-Alisarai and Mahdavian (2019) se basaron en vibraciones y utilizaron la prueba de Welch, Transformada de Fourier a Corto Plazo, Distribución de Wigner-Ville y Distribución de Choi-Williams obtuvieron las vibraciones generadas para los casos planteados, en Wang et al. (2018) mostraron los 4 principales métodos para la detección de fallas en rieles de inyección para motores Diesel, en el caso de Xie et al. (2018) partieron de los sensores del automóvil y las emisiones, determinaron diversas fallas en el motor, en Nadeer et al. (2018) se desarrolló un modelo, de espacio de estado híbrido no lineal del sistema completo de motor de gasolina de combustión interna desde el acelerador hasta el silenciador en el cual aplicaron ecuaciones para de balance de masa y la energía, en el trabajo que presentó Sean (2018) se desarrolló un nuevo sensor inalámbrico que se realizó específicamente para su uso en FDD para ICE el cual a pesar de presentar un desempeño del cien por ciento también comenta que el costo de producción es bastante elevado.

En este trabajo de investigación, el objetivo es detectar y aislar uno de los cuatro inyectores que pudieran fallar. Considerando que la bomba de gasolina puede fallar, así como el filtro puede estar tapado, además de que el sistema puede auto regula su presión la diferencia de presión solo se puede observar en estado ralenti.

Las aportaciones que se presentan en este trabajo son:

- El diseño de un esquema FDD basado en señales de presión del riel de inyección,
- Visualización de fallas mediante el uso de las transformadas.
- El esquema FDD es capaz de detectar y aislar el inyector que presente anomalías.
- El sistema de discriminación se basa en ELM de dos dimensiones.
- El esquema FDD fue validado en línea en un sistema EFI de un motor de cuatro cilindros con el uso de un sistema embebido.

2. METODOLOGÍA

En esta sección se explica primero los materiales y métodos utilizados para después relacionarlos con el uso que se le dio al sistema empleado.

2.1 Materiales y Métodos

El material para la adquisición de las señales es el siguiente:

- Un riel de inyectores: el cual está constituido por los cuatro inyectores y un sensor de vacío.

- El sensor de vacío se encuentra conectado a una pistola de presión la cual realiza la función del vacío del motor.
- Un medidor de presión mecánico, el cual sirve para garantizar que la medida sea correcta.
- Juego de cuatro relevadores, estos están conectados a la salida de la tarjeta MyRio®, debido a que la tarjeta no cuenta con la salida suficiente para activar en sistema nominal a los inyectores.
- Una fuente de alimentación para los inyectores, la bomba de gasolina, y los relevadores.
- Filtro de gasolina a este se le hace limpieza cotidiana debido a que se considera ideal.
- Bomba de gasolina, esta se encuentra dentro de los parámetros normales de presión por lo que también se le considera ideal.
- Recipiente con gasolina, este generalmente se encuentra por debajo de la mitad de llenado, pero logra cubrir completamente la bomba de gasolina.
- La computadora que se utiliza para las pruebas fuera de línea cuenta con: 12 GB de RAM, 1024 GB en el disco duro, un procesador Intel i7® a 2.0 GHz con uso de software Windows 10 student®, LabVIEW® 2017 así como sus complementos y Matlab® R2017a.

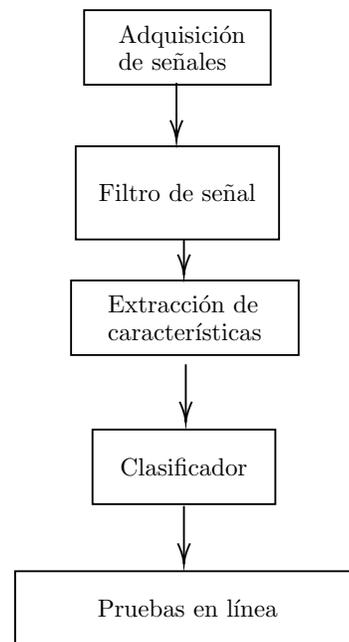


Fig. 1. Algoritmo de solución

El algoritmo de solución se muestra en 1.

Adquisición de señales. Para la adquisición de señales se utilizó el sensor MPX5700dp conectado a la tarjeta MyRio®. El cual mediante un programa de adquisición recupera las señales para cada uno de los eventos, cabe destacar que las señales obtenidas presentan bastante ruido.

Filtro de señal Para el filtro se utiliza la transformada Wavelets, dicha Transformada es altamente eficiente para

realizar análisis local de señales no estacionarias y además de rápida transitoriedad.

Las Wavelets, son generadas partiendo de una función Wavelet madre, utilizando traslaciones y dilataciones. Permitiendo así reconstruir la señal real a través de la Transformada Wavelet inversa.

Esta Transformada no es solamente local en tiempo, también lo es en frecuencia. Dentro de los diversos usos de esta herramienta en el presente trabajo se enfocará solo para la compresión y el procesar las imágenes y reconocimiento de patrones.

En la ecuación (1) se muestra a las wavelets creadas partiendo de la wavelet madre $\Psi(t)$ por las traslaciones y las dilataciones discretas

$$\Psi_{i,k}(t) = 2^{-\frac{i}{2}} \Psi(2^{-i}t - k) \quad (1)$$

Una vez que la transformada de Fourier $\Psi(w)$ que proviene de la wavelet madre satisface la condición de ortogonalidad, las traslaciones discretas de las wavelet madre $\Psi(2^{-i}t - k)$ generan una base ortonormal para cada una de la escala 2^i en (2).

$$(\phi_{i,k}, \Psi_{i,n}) = 2^{-i} \int \phi_i(t - k) \Psi_i(t - n) dt = 0 \quad (2)$$

para todo k y $n \in \mathbb{Z}$.

El análisis multiresolución realiza la expansión de una señal para obtener una base de funciones de las cuales sus propiedades tiempo-frecuencia se adecúan a la estructura local de la señal. Esta Transformada permite al usuario obtener el desarrollo de una señal dando una base ortonormal de funciones wavelets, estas tienen propiedades de localización en tiempo y frecuencia, en trabajos como, Grispino et al. (2013), Monteiro et al. (2018), H. Barizão et al. (2020) el uso de esta herramienta ofrece una mejor lectura de los datos.

En este caso particular se realizó un filtro de 1000 muestras por segundo, debido a son 164 muestras por ciclo y el utilizar 6 permite detectar las anomalías presentadas, su rango de trabajo se encuentra entre [7.8125 - 500] resintonizando se encuentra una mejor representación en los rangos de frecuencia de [10 - 80] de ello se obtienen una mejor señal. En la cual se pueden observar las caídas de presión continuas que corresponden a la salida de gasolina del inyector a diferencia de cuando se presenta una falla, en la cual se muestran des continuidades.

Extracción de características Para extraer las características se utilizó la Transformada Stockwell misma que en el trabajo que presentaron Čurović et al. (2021), Lala and Karmakar (2021) dio resultados adecuados. Esta transformada es una modificación de la transformada de Fourier con ventana, utilizando una ventana variable según la distribución de la frecuencia analizada como se muestra en (3).

$$S(\tau, f) = \int_{-\infty}^{+\infty} S(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{f^2(\tau-t)^2}{2}} e^{-i2\pi ft} dt$$

$$S(\tau, f) = \int_{-\infty}^{+\infty} S(t) w(\tau - t) e^{-i2\pi ft} dt$$

$$w(\tau - t) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(\tau-t)^2}{2\sigma^2}}$$

$$\int \sigma = \frac{1}{|f|} \quad (3)$$

la matriz de Stockwell es obtenida como en (4).

$$\int s(kt, \frac{n}{NT}) = \begin{bmatrix} S(0,0) & S(T,0) & \dots & S(kT,0) \\ S(0, \frac{1}{NT}) & S(T, \frac{1}{NT}) & \dots & S(kT, \frac{1}{NT}) \\ \vdots & \vdots & \ddots & \vdots \\ S(0, \frac{n}{NT}) & S(T, \frac{n}{NT}) & \dots & S(kT, \frac{n}{NT}) \end{bmatrix} \quad (4)$$

Donde T es el intervalo de tiempo entre dos muestras consecutivas, N la longitud de la señal analizada y $(k, n) = 0, 1, \dots, N - 1$.

Clasificador Las máquinas de aprendizaje extremo (Extreme Learning Machine) por sus siglas en inglés son redes neuronales avanzadas para clasificación, regresión, agrupamiento, aproximación dispersa, compresión y aprendizaje de características con una sola capa o múltiples capas de nodos ocultos.

Dada una sola capa oculta de ELM suponiendo que la función de salida del $i - th$ el nodo oculto es $h_i(X) = G(a_i, b_i, x)$ donde a_i y b_i son los parámetros ocultos del $i - th$ nodo oculto.

Dado N muestras de entrenamiento, la matriz de salida de la capa oculta, H de ELM se da como en (5) .

$$H = \begin{bmatrix} h(x1) \\ \vdots \\ h(xN) \end{bmatrix} = \begin{bmatrix} G(a1, b1, x1) & \dots & G(aL, bL, x1) \\ \vdots & \vdots & \vdots \\ G(a1, b1, xN) & \dots & G(aL, bL, xN) \end{bmatrix} \quad (5)$$

y T es la matriz objetivo de datos de entrenamiento en (6).

$$T = \begin{bmatrix} t1 \\ \vdots \\ tN \end{bmatrix} \quad (6)$$

En este trabajo se utiliza para la clasificación por lo cual, dada una función de activación por partes $f(x)$ luego del mapeo aleatorio de capas ocultas $h(x)$ puede separar regiones no juntas arbitrarias de cualquier forma. Sin embargo, la entrada a utilizarse será de doble dimensión, por lo cual se debe, calcular la matriz de salida de la capa oculta como en (7).

$$H_{ij} = g(U_i^T A_j v_i + b_i) \quad (7)$$

donde H_{ij} es la salida de i -th nodo oculto de la entrada j -th. Por lo tanto, cada nodo oculto obtiene la información de la matriz A_j manteniendo varios a través de diferentes pesos aleatorios U_i, V_i y b_i .

Esto se resuelve considerando (8).

$$\beta^* = H^\dagger y \quad (8)$$

donde H^\dagger es el inverso generalizado Moore-Penrose de la matriz de H .

2.2 Procedimiento Experimental

El método de solución está dividido en dos partes, en la primera, una vez extraídos los datos de presión del sistema se analizan por medio del software de Matlab[®], para posteriormente realizar el programa en LabVIEW[®] y realizar las pruebas pertinentes en línea.

Adquisición de señales En la adquisición de las señales se utiliza el sensor MPX5700dp conectado en la tarjeta MyRio[®] el cual mediante el uso del programa que se presenta en 2 se extraen los datos guardándolos en un script.

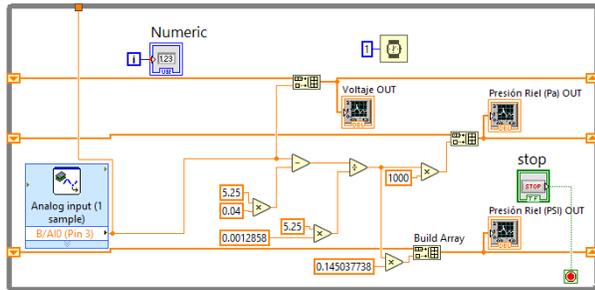


Fig. 2. Programa en LabView[®]

Filtro de señal Usando la transformada de Wavelet y su inversa se puede realizar un filtro, esto se puede realizar reconstruyendo solo las frecuencias entre las cuales trabaja el sistema, en este caso la lectura es de 1000 muestras por segundo su rango de trabajo se encuentra entre [7.8125 – 500] sintonizando se encuentra una mejor representación en los rangos de frecuencia de [10 – 80] de ello se obtienen

una mejor señal, la importancia de este filtro se debe a que si no se realiza este tratamiento a las señales los tratamientos posteriores no tienen una buena respuesta, además de que se puede observar en 3 donde se notan las caídas de presión continuas que corresponden a la salida de gasolina del inyector a diferencia de cuando se presenta una falla, en la cual se muestran descontinuidades como en 4.

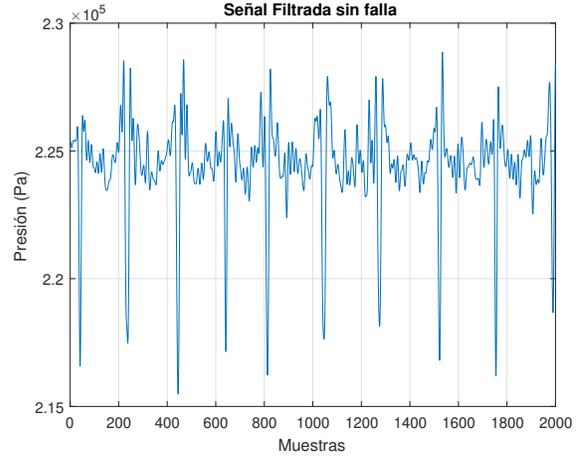


Fig. 3. Sin falla

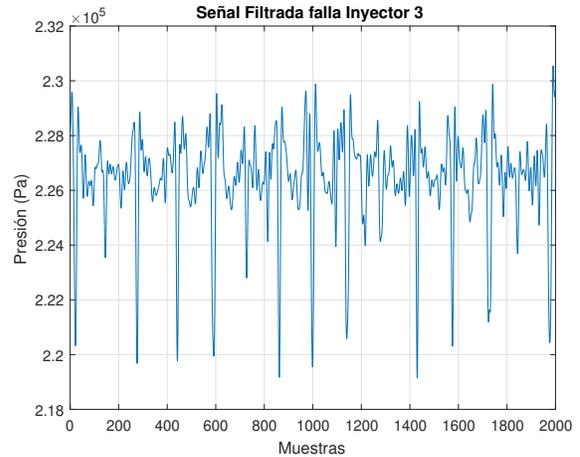


Fig. 4. Falla 3

Extracción de características La transformada de Stockwell para la clasificación de eventos. En este trabajo se utiliza la matriz de Stockwell como entrada de una red neuronal para realizar la clasificación de las fallas. En la figura 5 se presenta la señal con poca percepción que se observa con la transformada de Stockwell y en 6 se muestra la mejora significativa para la extracción exitosa de la matriz de Stockwell, misma que servirá como elemento característico de la señal.

Two-Dimensional Extreme Learning Machine Para este trabajo no se puede utilizar la metodología convencional,

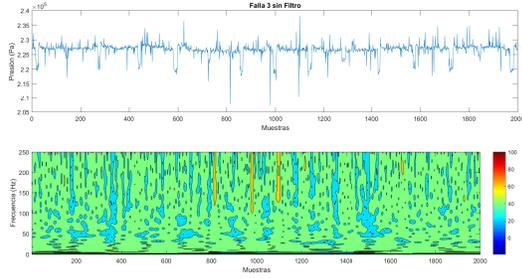


Fig. 5. Falla 3

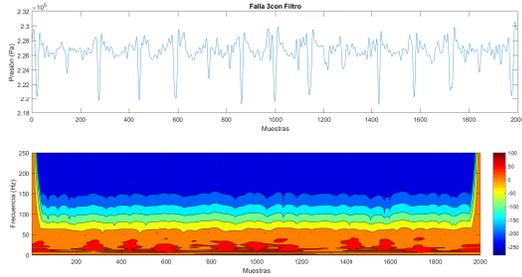


Fig. 6. Falla 3

por lo que se deberá utilizar la red Two-Dimensional Extreme Learning Machine siendo la única diferencia que a la entrada tiene una matriz y no un vector, el algoritmo de clasificación se determina como se muestra en 7, las salidas de las neuronas están dentro de un rango de $1a - 1$, por lo cual, se utiliza un algoritmo on-off para la toma de decisión sobre cuál, es la falla y mandar la correcta señal, dicho algoritmo realiza las tareas de la siguiente forma: considerando la salida 1 $s1 > s2$ así como $s1 > s3$, $s1 > s4$ y $s1 > s5$ si esto se cumple la tarea se termina, si no se considera la salida 2 $s2 > s1$, $s2 > s3$, $s2 > s4$ y $s2 > s5$ si esto se cumple se manda la señal a encender el led 0 correspondiente a la falla 1, si no $s3 > s1$, $s3 > s2$, $s3 > s4$ y $s3 > s5$, de cumplir ello se manda a encender el led 1 correspondiente a la falla 2 y así consecutivamente con las otras dos restantes salidas si no se detecta con anterioridad, cabe destacar que este sistema solo mapea la falla una sola vez, por lo que se debería iniciar nuevamente el sistema para volver a aplicar el esquema de detección y diagnóstico de fallas.

La estructura de la red neuronal se puede representar como se puede observar en 8 la cual muestra que solo cuenta con una capa oculta y las salidas corresponden a los eventos considerados en este trabajo, siendo así las entradas correspondientes a las diversas clases las cuales se introducen en forma de matriz.

3. RESULTADOS

Las primeras pruebas se han realizado en Matlab® fuera de línea en la cual los tiempos transcurridos para cada falla se muestran a continuación en la tabla 1.

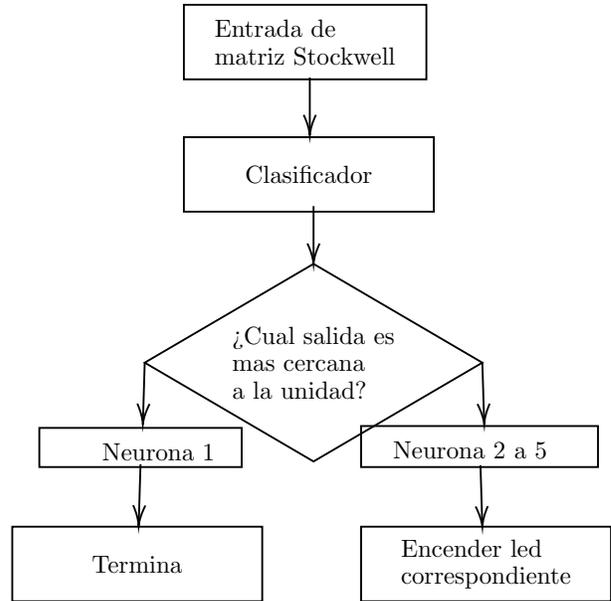


Fig. 7. Algoritmo del esquema de detección y diagnóstico de fallas.

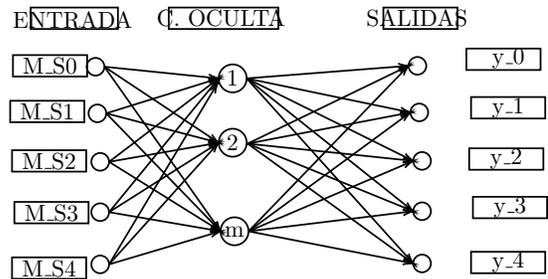


Fig. 8. Arquitectura de la red neuronal.

Falla	Transformada Stockwell	Red Neuronal	Tiempo	Porcentaje de eficiencia
0	0.130130 s	44.3609 s	44.491030 s	95
1	0.18070 s	39.69825 s	39.87895 s	100
2	0.0985 s	45.26523 s	45.36373 s	98
3	0.2358 s	41.3658 s	41.6016 s	98
4	0.1638 s	40.2036 s	40.3674 s	90

Table 1. Tabla de pruebas a nivel simulación

En dicha tabla se muestran los resultados de diez pruebas para cada caso en el cual el tiempo y el porcentaje de eficiencia fue promediado. En base a esta tabla se puede observar que el porcentaje promedio para la detección de fallas es de 96.2%, además de que el tiempo promedio que se requiere para realizar las simulaciones es de 42.34s.

3.1 Pruebas en Línea

Una vez completado el programa dentro del embebido de la tarjeta myRio® se realizaron las pruebas realizando el conteo de tiempo desde un dispositivo externo y verificando si la falla detectada correspondía a la falla generada.

Cabe destacar que en este caso se realizó el ajuste de aumento de neuronas de 700 a 900 esto se debió a que con la primer cantidad la eficiencia se encontraba por abajo de

las expectativas y se aumentó un poco para mejorar y no saturar la tarjeta.

Para el caso en el que no existe falla se esperaron 5 minutos para observar si ocurría algún cambio o detectaba mal una falla, para este caso el resultado fue positivo al 100%.

Para el caso de la falla en el inyector uno el tiempo promedio para detectar la falla fue de 150s con una eficiencia del 95% esto debido a que en una ocasión detecto la falla en inyector equivocado.

En cuanto al inyector 2, el tiempo promedio para detectar la falla fue de 180 s además de que tuvo un desempeño menor que fue de 85%.

Por otra parte el inyector 3, tuvo un tiempo promedio de 120s y un desempeño del 95% esto se debió a que en una ocasión no detecto la falla.

En el ultimo inyector, el tiempo promedio fue de 150s y en este caso la eficiencia también fue del 100%.

En la figura 9 se muestra la visualización de la tarjeta cuando existe una falla, encendiendo el foco correspondiente al inyector que este fallando.

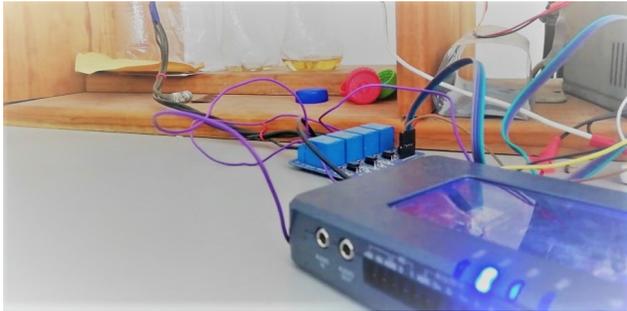


Fig. 9. Falla presente en Inyector 3

4. CONCLUSIONES

El trabajo presentado da como principal aporte el uso de la transformada Stockwell con la red neuronal Extreme Learning Machine de doble dimensión además de que se realizó la aplicación del algoritmo a un sistema real.

Como complemento también fue la aplicación de la transformada Wavelet para el mismo sistema, siendo esta complementaria para su posterior análisis.

Además, de que el sistema se hizo más compacto, esto gracias al embebido de la tarjeta MyRio®.

Aunque los tiempos fueron mayores relativamente a algunas investigaciones anteriores el trabajo logro una eficiencia en línea del 95% siendo un desempeño que logro las

expectativas de la investigación.

Por otra parte, el programa se puede optimizar, esto daría pauta a un probable mejor desempeño del sistema. Esto sería restringiendo la matriz de Stockwell ya que los valores significativos se encuentran en el rango de $[1Hz - 50Hz]$, por lo que al depurar esa carga innecesaria se podría disminuir la cantidad de neuronas utilizadas, tanto a nivel simulación como en la aplicación al sistema real.

REFERENCES

- Aleiferis, P.G. and Papadopoulos, N. (2021). Heat and mass transfer effects in the nozzle of a fuel injector from the start of needle lift to after the end of injection in the presence of fuel dribble and air entrainment. *International Journal of Heat and Mass Transfer*.
- Alippi, C., Russis, C.D., and Piuri, V. (2003). A neural-network based control solution to air-fuel ratio control for automotive fuel-injection systems. 33, 259–268.
- Čurović, L., Murovec, J., Novaković, T., Prisljan, R., and Prezelj, J. (2021). Stockwell transform for estimating decay time at low frequencies. *Journal of Sound and Vibration*.
- Dhanji, M. and Zhao, H. (2020). Investigations of split injection properties on the spray characteristics using a solenoid high-pressure injector. *International J of Engine Research*, 02.
- Filipczyk, J. (2013). Causes of automotive turbocharger faults. *Transport Problems*, 8, 5–10.
- Gao, Z., Li, G., and Li, H. (2021). Experiment investigation of injection parameters effects on injection stability of a high pressure common rail system. 104, 1–16.
- Grispino, A.S., Petracca, G.O., and Dominguez, A.E. (2013). Comparative analysis of wavelet and emd in the filtering of radar signal affected by brown noise. *IEEE Latin America Transactions*, 11, 81–85.
- H. Barizão, A., H. Yoshizumi, V., H. Spatti, D., E. Dajer, M., and A. Flauzino, R. (2020). Estimación inteligente do grau geral de desvio vocal utilizando transformada wavelet packet.
- Lala, H. and Karmakar, S. (2021). A stockwell transform-based approach for the detection and classification of high-impedance arc in leaning tree and sphere gap.
- Monteiro, D.D.A., Zvietcovich, W.G., and Braga, M.F. (2018). Detection and classification of power quality disturbances with wavelet transform, decision tree algorithm and support vector machines. *SBSE 2018 - 7th Brazilian Electrical Systems Symposium*, 1–6.
- Nadeer, E.P., Patra, A., and Mukhopadhyay, S. (2018). Hybrid state space modeling of a spark ignition engine for online fault diagnosis. *Journal of Dynamic Systems, Measurement and Control, Transactions of the ASME*.
- Namigtle-Jiménez, A., Escobar-Jiménez, R.F., Gómez-Aguilar, J.F., García-Beltrán, C.D., and Téllez-Anguiano, A.C. (2020). Online ann-based fault diagnosis implementation using an fpga: Application in the efi system of a vehicle. *ISA Transactions*.
- Sean, H.B. (2018). A wireless sensor for fault detection and diagnosis of internal combustion engines a wireless sensor.

- Taghizadeh-Alisaraci, A. and Mahdavian, A. (2019). Fault detection of injectors in diesel engines using vibration time-frequency analysis. *Applied Acoustics*.
- Wang, Z., Zhao, Y., Yan, J., and Xu, J. (2018). The common fault diagnosis method of diesel engine. 143, 390–392.
- Xie, C., Wang, Y., MacIntyre, J., Sheikh, M., and Elkady, M. (2018). Using sensors data and emissions information to diagnose engine's faults. *International Journal of Computational Intelligence Systems*, 11, 1142–1152.
- Zhao, J., Lu, X., and Grekhov, L. (2021). Experimental study on the fuel heating at the nozzle of the high pressure common-rail injector. *Fuel*, 283, 119281.