



APLICACIÓN DE UNA RED NEURONAL FEED-FORWARD BACKPROPAGATION PARA EL DIAGNÓSTICO DE FALLAS MECÁNICAS EN MOTORES DE ENCENDIDO PROVOCADO

APPLICATION OF FEED-FORWARD BACKPROPAGATION NEURAL NETWORK FOR THE DIAGNOSIS OF MECHANICAL FAILURES IN ENGINES PROVOKED IGNITION

Wilmer Contreras Urgilés^{1,*}, José Maldonado Ortega¹, Rogelio León Japa¹

Resumen

En la presente investigación se explica la metodología para la creación de un sistema de diagnóstico aplicado a la detección de fallas mecánicas en vehículos con motores a gasolina mediante redes neuronales artificiales, el sistema se basa en el estudio de la fase de admisión del ciclo Otto, el cual es registrado a través de la implementación física de un sensor MAP (*Manifold Absolute Pressure*). Se emplea un estricto protocolo de muestreo y su correspondiente análisis estadístico. Los valores estadísticos de la señal del sensor MAP: área, energía, entropía, máximo, media, mínimo, potencia y RMS se seleccionaron en función al mayor aporte de información y diferencia significativa. Los datos se obtuvieron con la aplicación de 3 métodos estadísticos (ANOVA, matriz de correlación y Random Forest) para tener una base de datos que permita el entrenamiento de una red neuronal *feed-forward backpropagation*, con la cual se obtiene un error de clasificación de $1.89e^{-11}$. La validación del sistema de diagnóstico se llevó a cabo mediante la provocación de fallas supervisadas en diferentes motores de encendido provocado.

Palabras clave: diagnóstico, fallos mecánicos, red feed-forward backpropagation, ANOVA, matriz de correlación, Random Forest.

Abstract

This research explains the methodology for the creation of a diagnostic system applied to the detection of mechanical failures in vehicles with gasoline engines through artificial neural networks, the system is based on the study of the phase of Admission of the Otto cycle, which is recorded through the physical implementation of a MAP sensor (*Manifold Absolute Pressure*). A strict sampling protocol and its corresponding statistical analysis are applied. The statistical values of the MAP sensor signal as: area, energy, entropy, maximum, mean, minimum, power and RMS, were selected according to the greater input of information and significant difference. The data were obtained with the application of 3 statistical methods (ANOVA, correlation matrix and Random Forest) to obtain a database that allows the training of a neural network feed-forward backpropagation, with which you get an error of Classification of $1.89e^{-11}$. The validation of the diagnostic system was carried out by the generating supervised failures in different engines with provoked ignition.

Keywords: diagnosis, mechanical failures, network feed-forward backpropagation, ANOVA, correlation matrix, Random Forest.

^{1,*}Grupo de Investigación de Ingeniería del Transporte (GIIT), Carrera de Ingeniería Mecánica Automotriz, Universidad Politécnica Salesiana, Cuenca – Ecuador Autor para correspondencia ✉: rcontreras@ups.edu.ec

<http://orcid.org/0000-0003-2300-9457>, <http://orcid.org/0000-0002-3846-2599>,

<http://orcid.org/0000-0003-2142-3769>

Recibido: 21-08-2018, aprobado tras revisión: 09-11-2018

Forma sugerida de citación: Contreras Urgilés, W.; Maldonado Ortega, J. y León Japa, R. (2019). «Aplicación de una red neuronal feed-forward backpropagation para el diagnóstico de fallas mecánicas en motores de encendido provocado». INGENIUS. N.º 21, (enero-junio). pp. 32-40. DOI: <https://doi.org/10.17163/ings.n21.2019.03>.

1. Introducción

En la actualidad en el área del transporte automotor los operarios y técnicos utilizan diagramas rudimentarios para el diagnóstico y reparación de motores de encendido provocado (MEP), lo que implica, subjetividad en el diagnóstico, desventajas en el tiempo de detección de fallas, falta de asertividad, y como consecuencia, se tienen altos costos de mantenimiento.

Por todo lo antes expuesto, es necesario aplicar nuevas metodologías y técnicas especializadas para conseguir diagnósticos en tiempos cortos que optimicen recursos para la detección de fallos en motores de vehículos a gasolina [1].

La complejidad de análisis e interpretación de parámetros de operación que intervienen en el MEP hace necesario el uso de redes neuronales y matemática computacional para un eficiente diagnóstico de fallos mecánicos en motores de ciclo Otto. La investigación de Howlett [2] muestra que mediante el análisis de la señal de la bujía con redes neuronales artificiales se puede monitorear el MEP para un diagnóstico o control de fallas.

De igual forma, Antory [3] indica que es posible determinar con precisión diferentes tipos de fallas comunes en un motor diésel para automóviles mediante un modelo de diagnóstico que utiliza una variante de redes neuronales auto asociativas (AANN).

Estrategias paralelas a las redes neuronales son aplicables para el diagnóstico de fallos en el campo automotor. Chen y Zhao [4] aplican una variante paralela de las RNA conocidas como redes de base radial RBF, esta técnica es utilizada para el diagnóstico de fallas del sistema de combustible en el motor.

Se pueden aplicar estrategias paralelas para entrenar una RNA, por ejemplo, el entrenamiento de la red Elman modificada aplicada para el diagnóstico de fallas del motor. Dicho método es muy efectivo y puede obtener un buen resultado de diagnóstico, debido a que es una red recurrente y tiene una relación dinámica de entrada y salida [5], asimismo Lian *et al.* [6] presentan un método de diagnóstico para detección de fallas en motores de encendido provocado basado en la aplicación de lógica difusa y redes neuronales. Shah *et al.* [7] proponen un sistema de reconocimiento de fallas para motores de combustión interna, con aplicación de la transformada de *wavelet* discreta (DWT) y la técnica de redes neuronales de base radial (RBFN).

Cay [8] desarrolló un modelo de RNA basado en el algoritmo de retro propagación para un MEP con el objetivo de predecir el consumo de combustible específico del freno, la potencia efectiva y la temperatura de escape del motor. Cay *et al.* [9] presentaron un modelo de RNA capaz de predecir el rendimiento del MEP y las emisiones de escape en un motor que funcionaba con metanol y gasolina.

Las redes neuronales tienen diversas aplicaciones en la calibración de motores de encendido por chispa. R. F. Turkson *et al.* [10] han propuesto que aquellas permiten la identificación del sistema para el prototipado rápido, la detección virtual, estrategias de control emergentes y aplicaciones de diagnóstico a bordo (OBD).

Otra importante aplicación de las redes neuronales (ANN) con modelos cinéticos como funciones de activación para las neuronas en la capa oculta es aplicable para el estudio de degradación del poliuretano de un colector de admisión automotriz con tratamiento isotérmico [11].

El sistema de diagnóstico propuesto puede detectar fallos en motores de encendido provocado que no son detectadas por la ECU (Engine Control Unit). El sistema se sustenta en la utilización de las señales de los sensores MAP y CMP, ya que tienen la facultad de reducir al mínimo el tiempo de diagnóstico, esto último evita usar técnicas intrusivas en el MEP como por ejemplo, el uso de manómetros para medición de compresión de cilindros y presión de combustible, vacuómetro, escáner automotor, entre otras. Las técnicas antes indicadas tienen la función de determinar el fallo mecánico.

2. Métodos y materiales

En la presente sección se desarrollan las temáticas principales que tienen que ver con la selección de unidad experimental e instrumentación mínimamente invasiva, condiciones de toma de muestras, metodología para la adquisición de datos, obtención de matriz de atributos, reducción de atributos, selección de atributos para entrenamiento de la RNA y algoritmo de la red neuronal en Matlab.

2.1. Selección de la unidad experimental e instrumentación mínimamente invasiva

Se toma en consideración como principal objetivo evitar el desarmado de elementos y piezas del motor para diagnosticar fallas mecánicas, por lo que se determina medir la depresión del motor mediante la instalación de un sensor tipo MAP en una toma de vacío del múltiple de admisión, ubicándolo después de la mariposa de aceleración, de tal manera que la conexión no afecta el funcionamiento del motor.

La identificación de cada uno de los cilindros se realiza mediante el registro de la señal del sensor CMP. En la Figura 1 se presentan la unidad experimental puesta a prueba Motor Hyundai Sonata 2.0 DOHC, una computadora personal (PC), tableta, Ni DAQ-6009 y la interfaz del escáner automotor. En la Figura 2 se muestra la conexión del sensor MAP, la toma de vacío en el múltiple de admisión y la herramienta de adquisición de datos Ni DAQ-6009.



Figura 1. Instrumentación en el motor.




Figura 2. Conexión del sensor MAP.

2.2. Condiciones de toma de muestras

Se utiliza el *software* Labview 2017 junto con una tarjeta Ni DAQ-6009, para la obtención de muestras. Las muestras se adquieren en ralentí aproximadamente a 850 rpm con un rango de temperatura del MEP de entre 92 °C y 97 °C, carga del motor de 40 % y se aplica el escáner automotor para corroborarlas. Según un estudio preexperimental se determina que la señal del sensor MAP posee picos de mayor frecuencia, de tal manera que se realiza la toma de muestras a una velocidad de 10 KHz en un tiempo de 5 segundos para cada una de las señales, dicha velocidad supera el criterio de Nyquist (1.416 KHz).

2.3. Metodología para la obtención de datos

En la Figura 3 se presentan los elementos físicos necesarios para el muestreo de señales.




Figura 3. Elementos necesarios para la toma de muestras.

Para obtener los datos de las señales de los sensores MAP y CMP se sigue el flujograma de proceso que se presenta en la Figura 4.

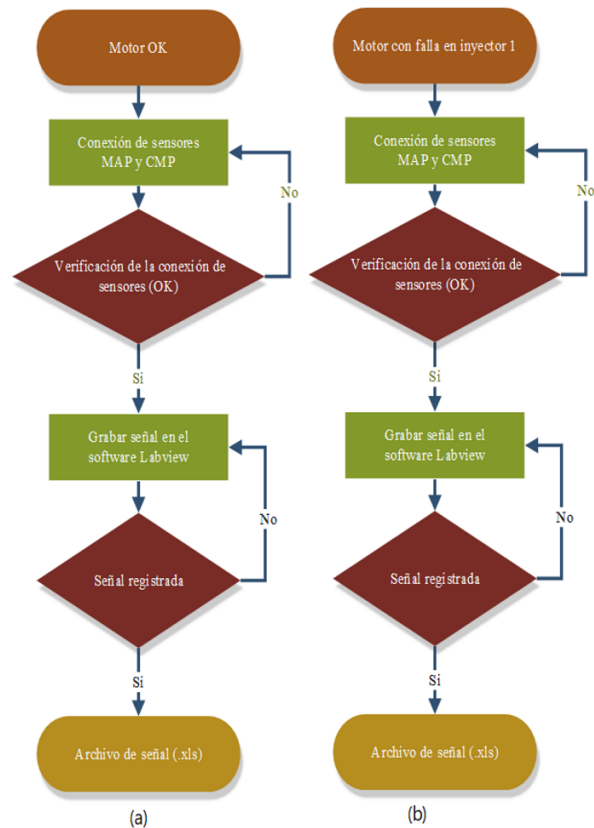


Figura 4. Flujograma de proceso para la adquisición de muestras (a) motor ok, (b) motor con falla.

El proceso de obtención de datos se inicia con la revisión del motor en correcto funcionamiento o falla supervisada, posterior a ello se procede a inspeccionar la conexión de los sensores. Si la conexión es correcta, se graba la señal con el *software* Labview y se registra en un archivo de Excel, de lo contrario, se procede a verificar la conexión de los sensores. Para registrar las señales se aplica el procedimiento antes descrito tanto para el caso de motor en buen funcionamiento como para el motor con falla supervisada, Figura 4(a); 4(b).

En la Tabla 1 se indica el total de 18 fallas que se generan en la unidad experimental, cada una con su respectivo código de identificación; también se indica la condición del motor en óptimo funcionamiento.

2.4. Obtención de matriz de atributos

Una vez desarrollada la adquisición de señales temporales se procedió a elaborar un algoritmo en el *software* Matlab para lectura y obtención de matriz general de atributos. Dichos atributos son los siguientes: media geométrica, máximo, mínimo, mediana, covarianza, varianza, desviación estándar, moda, factor de curtosis, coeficiente de asimetría, energía, potencia, área bajo la curva, entropía, coeficiente de variación, rango, raíz media cuadrática y factor de cresta.

En la Figura 5 se ilustra el corte completo de un ciclo del motor ($720^\circ \pm 180^\circ$), con el reglaje de dis-

tribución de adelanto a la apertura de admisión (AAA) y retraso de cierre de admisión (RCA), correspondiente a cada uno de los cilindros, del cual se realiza un ventaneo que se observa en la Figura 6 y se obtiene la caracterización de la señal.

Tabla 1. Condiciones funcionales en la unidad experimental

N.º	Tipo de condición mecánica	Código de identificación
1	Motor en óptimo funcionamiento	100
2	Falla inyector 1	200
3	Falla inyector 2	300
4	Falla inyector 3	400
5	Falla inyector 4	500
6	Falla bujía 1	600
7	Falla bujía 2	700
8	Falla bujía 3	800
9	Falla bujía 4	900
10	Falla en bobina 1-4	1000
11	Falla en bobina 2-3	1100
12	Baja presión de combustible	1200
13	Alta presión de combustible	1300
14	Árbol de admisión (+1) y escape (0)	1400
15	Árbol de admisión (-1) y escape (0)	1500
16	Árbol de admisión (0) y escape (+1)	1600
17	Árbol de admisión (0) y escape (-1)	1700
18	Árbol de admisión (+1) y escape (+1)	1800
19	Árbol de admisión (-1) y escape (-1)	1900

2.5. Reducción de atributos

Para la selección y reducción del número de atributos se analiza la matriz general a través de 3 métodos estadísticos: ANOVA, matriz de correlación y Random Forest.

La aplicación del método estadístico ANOVA de un solo factor, permite determinar los mejores atributos que ingresan a la matriz general mediante el análisis de los 18 atributos. Tomando en consideración en el método el mayor valor de R^2 , puesto que los valores cercanos al 100 % indican que existe un correcto ajuste de los datos al modelo, es decir, se determina la variación entre los atributos. Además, en el método se consideran los valores de p próximos a 0 que determinan si los atributos son estadísticamente significativos [12].

Respecto a la matriz de correlación, se descartaron los atributos que contienen coeficientes próximos a -1 o 1, dado que con los mismos existe una relación fuerte entre las variables, ya sea negativa (-1) o positiva (1). En efecto se seleccionaron los atributos con coeficientes próximos a cero, puesto que con estos atributos no existe una correlación fuerte entre las variables [13].

En cuanto al método de Random Forest, permite obtener la estimación de importancia de atributos con uso de los métodos de Curvature test, Standard CART e Interaction test. Posterior a ello, se aplicó el análisis de Pareto para seleccionar los atributos de mayor prioridad, considerando solo el primer 95 % de la distribución acumulada [14].

Los resultados de los métodos estadísticos aplicados: ANOVA, matriz de correlación y Random Forest se observan en la Tabla 2.

La matriz general contiene los 18 atributos correspondientes a las 19 condiciones inducidas a la unidad experimental.




Figura 5. Corte de la señal de los sensores MAP y CMP para análisis.




Figura 6. Ventaneo de la señal del sensor MAP por cilindro.

2.6. Selección de atributos para entrenamiento de la RNA

Para seleccionar los atributos que serán considerados en la entrada de la red neuronal se realizó un análisis de coincidencia en la Tabla 2 en el cual se seleccionaron los atributos que más se repiten entre los resultados de cada método estadístico aplicado. Los atributos que más se repiten se muestran en la Tabla 3, corroborando la efectividad de cada método utilizado.

Tabla 2. Matriz general de atributos

Métodos estadísticos		Atributos de mayor importancia de los métodos estadísticos							
Correlación	Coef. de variación	Área	RMS	Media	Energía	Entropía	Mínimo	Mediana	Potencia
Coeficientes analizados	Rango/valor	Rango/valor	Rango/valor	Rango/valor	Rango/valor	Rango/valor	Rango/valor	Rango/valor	Rango/valor
342	≤ ± 0.1 / 222	≤ ± 0.1 / 212	≤ ± 0.1 / 216	≤ ± 0.1 / 212	≤ ± 0.1 / 220	≤ ± 0.1 / 214	≤ ± 0.1 / 204	≤ ± 0.1 / 214	≤ ± 0.1 / 214
ANOVA	Mediana	Área	Media	Mínimo	Máximo	RMS	Potencia	Energía	Entropía
R²=100 %	R²=99,4 %	R²=99,39 %	R²=99,39 %	R²=99,38 %	R²=99,38 %	R²=99,26 %	R²=99,25 %	R²=99,25 %	R²=99,16 %
p=0,00	p=0,00	p=0,00	p=0,00	p=0,00	p=0,00	p=0,00	p=0,00	p=0,00	p=0,00
Forest Curvature	Energía	RMS	Entropía	Máximo	Área	Media	Potencia	Mínimo	Factor de cresta
% de Importancia	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.
(0 a 2.5)	2,4	2,3	2,25	2,2	2,18	2,15	2	1,9	1,6
Forest Standard Cart	Energía	Entropía	RMS	Media	Máximo	Área	Potencia	Mínimo	Coef. de variación
% de Importancia	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.
(0 a 3)	2,85	2,7	2,65	2,64	2,63	2,6	2,55	2,46	2,4
Forest Robust	Desviación estándar	Varianza	Energía	Área	RMS	Media	Potencia	Máximo	Mínimo
% de Importancia	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.	% Imp.
(0 a 12)	10,15	10,13	10,11	10,09	9,5	9,1	8,7	8,5	8,4

Tabla 3. Atributos utilizados para entrenar la RNA

Atributos estadísticos	Número de repeticiones
Área (v ²)	5
Energía (J)	5
Entropía (J)	4
Máximo (V)	4
Media (V)	5
Mínimo (V)	5
Potencia (mW)	5
RMS (V)	5

2.7. Algoritmo de la red neuronal en Matlab

Mediante el uso de la plataforma de RNA del *software* Matlab se realizaron diferentes configuraciones para obtener una generalización de la red con un mínimo error.

En la Figura 7 se presenta el flujograma de la creación de la RNA.

El algoritmo inicia con la lectura de la matriz de entrada y respuesta respectiva para la RNA. Luego se normaliza el vector de entrada y la respuesta con el valor máximo de cada matriz con el objetivo de optimizar la creación de la RNA. Una vez normalizada la matriz de atributos se procedió a la creación de la RNA.

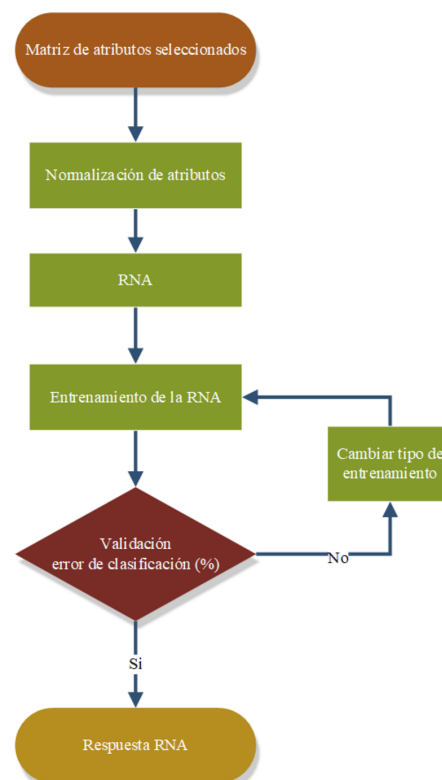


Figura 7. Flujograma de creación de RNA.

En la Figura 8 se observan los parámetros de la creación de la RNA de tipo *feed-forward backpropagation*.

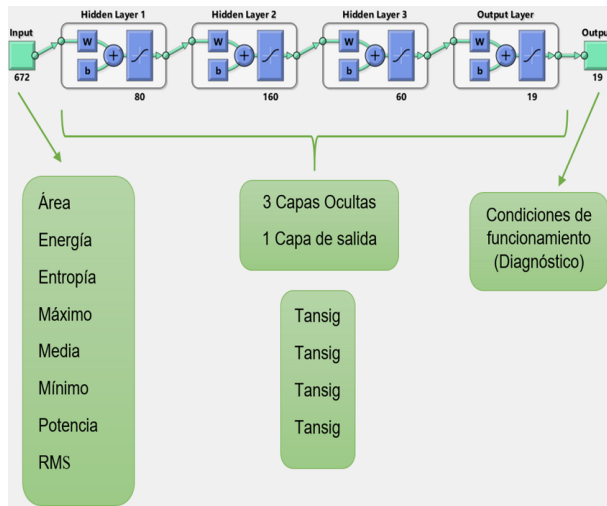


Figura 8. Estructura de red neuronal.

Una vez creada la red, se procedió a entrenar la red neuronal, y para ello se consideraron los siguientes parámetros para el entrenamiento:

1. Tipo de algoritmo
2. Numero de épocas
3. Error máximo

Con la red neuronal previamente entrenada se verificó el error de clasificación, si el error es mayor al 5 %, se procede a cambiar los parámetros para disminuir el error de clasificación.

En la Figura 9 se ilustran los errores de clasificación de diferentes configuraciones de entrenamientos obtenidos con el objetivo de conseguir la red neuronal con el menor error posible.

La red neuronal con una función de entrenamiento *trainscg* utilizada para el sistema de diagnóstico presentó un error de $1.89e^{-11}$ %.

En la Figura 10 se presentan los resultados del coeficiente de correlación de Pearson R de la red neuronal creada, la cual es facilitada por el código de entrenamiento *red.trainFcn = 'trainscg'* del software Matlab.

Las líneas indican los valores esperados y los círculos negros representan los valores pronosticados por la RNA. La predicción determinada por la red neuronal es eficiente y se corrobora con un buen desempeño, dado que se obtiene un índice global de 1 en entrenamiento, validación y prueba lo que indica una relación lineal fuerte positiva entre las condiciones reales del MEP y los resultados proporcionados por la red neuronal [15].




Figura 9. Errores de los diferentes algoritmos de entrenamiento.




Figura 10. Correlación entre los valores esperados y pronosticados por la red neuronal.

En la Figura 11 se muestra la comparación entre la respuesta de la red neuronal con el resultado esperado, es decir, se observan las 19 condiciones mecánicas reales del motor identificadas por la red neuronal.

3. Resultados y discusión

A fin de comparar el correcto funcionamiento del sistema de diagnóstico se procede a realizar varias pruebas bajo diversas condiciones de funcionamiento.

En este apartado se presentan dos condiciones de falla en específico: el inyector 1 (200) y el fallo en bobina 2-3 (1100).




Figura 11. Red neuronal con porcentaje de error de $1.89e^{-11}$, con función de entrenamiento «trainscg».

En la Figura 12 se muestran los resultados de los valores obtenidos por la RNA para las condiciones de funcionamiento cuando el inyector 1 se encuentra con falla, y donde el valor promedio del error del resultado de la red neuronal y la condición real es 0.0127.




Figura 12. Resultado de condición de funcionamiento de inyector 1.

En la Figura 13 se muestran los resultados de los valores obtenidos por la RNA para condiciones de funcionamiento cuando la bobina 2-3 se encuentra con falla y el valor promedio del error del resultado de la red neuronal y la condición real es 0,0060.




Figura 13. Resultado de condición de funcionamiento de bobina de ignición de alta tensión 2-3.

Obtenidos los resultados de las condiciones funcionales del MEP, se puede destacar que la diferencia entre las respuestas tanto de condición real y como de respuesta de red neuronal tienen un valor próximo a cero. Por lo tanto, la aplicación del sistema de diagnóstico es capaz de detectar la condición funcional de falla verdadera.

En efecto en la Figura 14 se observa que al agrupar los datos mediante el método estadístico de Tukey con un índice de confianza de 95 % de las respuestas obtenidas de la RNA y de la condición real del motor, se determina que las medias son equivalentes y no existe una diferencia estadísticamente significativa, ya que las medias de cada una de las respuestas coinciden en un valor próximo a cero.

Además, la Figura 15 de intervalos indica que no existe diferencia entre los promedios de las pruebas en las diferentes condiciones funcionales del motor.




Figura 14. Gráfica de diferencias de las medias para datos de respuesta real vs. red neuronal.

Asimismo, en la Figura 16 se corrobora que existe una relación entre la respuesta esperada y de la red neuronal ya que comparten la misma letra de agrupación (A) y el valor p (p -value) es igual a 0,965. Dando como resultado un valor de confiabilidad del 96,5 %, siendo este valor muy aceptable para temas de diagnóstico de motores de combustión interna de encendido provocado.

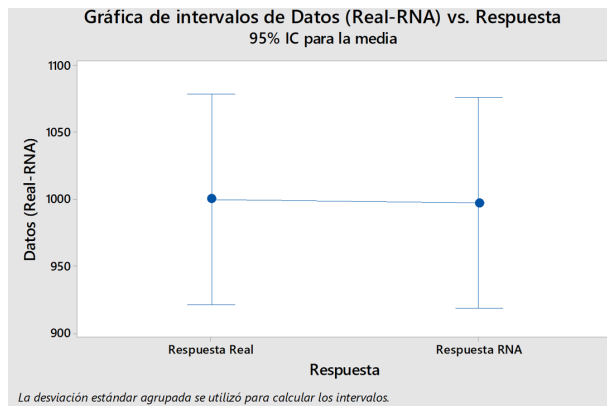


Figura 15. Gráfica de intervalos de datos de respuesta real vs. red neuronal.

Análisis de Varianza

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Respuesta	1	597	597	0,00	0,965
Error	378	114792201	303683		
Total	379	114792798			

Comparaciones en parejas de Tukey

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

Respuesta	N	Media	Agrupación
Respuesta Real	190	1000,0	A
Respuesta RNA	190	997,5	A

Figura 16. Resultados del análisis de varianza y comparaciones en parejas de Tukey.

4. Conclusiones

El modelo de red neuronal desarrollado posee un error de clasificación de $1,89e^{-11}$ con la función de entrenamiento *trainscg*, lo que permitió la identificación precisa de los diferentes tipos de condiciones mecánicas del MEP, por lo que constituye una alternativa claramente viable para ser integrada en un sistema de diagnóstico, debido a la rapidez computacional que ofrecen las redes neuronales artificiales.

Mediante el desarrollo del análisis de varianza de un solo factor, se obtuvo un valor de p ($p\text{-value}=0,965$) demostrando que la respuesta real de clasificación de fallas mecánicas es equivalente al resultado obtenido mediante la RNA, de manera que con este valor se demuestra que no existe una diferencia estadísticamente significativa.

En este trabajo se muestra que la aplicación de redes neuronales (*feed-forward backpropagation*) es válida para la detección de condiciones de fallas mecánicas en motores de encendido provocado; además, la técnica de diagnóstico aplicada presenta la ventaja de evitar el desarmado de elementos y piezas del motor con una

técnica mínimamente invasiva fiable y de gran precisión. Para determinar los mejores atributos para el entrenamiento de la RNA se aplicó diferentes métodos estadísticos: análisis de varianza (ANOVA), matriz de correlación, Random Forest, de los cuales se agrupó los resultados en una matriz general que permitió escoger los de mayor coincidencia e importancia para la diferenciación de patrones de fallas mecánicas.

Referencias

- [1] W. Contreras, M. Arichávala, and C. Jerez, "Determinación de la presión máxima de compresión de un motor de encendido provocado basado en una red neuronal artificial recurrente," *INGENIUS*, no. 19, pp. 9–18, 2018. [Online]. Available: <http://doi.org/10.17163/ings.n19.2018.01>.
- [2] R. J. Howlett, "Condition monitoring and fault diagnosis in a domestic car engine using a neural network," in *IEE Colloquium on Artificial Intelligence in Consumer and Domestic Products (Digest No. 1996/212)*, Oct 1996, pp. 5/1–5/4. [Online]. Available: <https://doi.org/10.1049/ic:19961142>
- [3] D. Antory, "Fault diagnosis application in an automotive diesel engine using auto-associative neural networks," in *International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06)*, vol. 2, Nov 2005, pp. 109–116. [Online]. Available: <https://doi.org/10.1109/CIMCA.2005.1631454>
- [4] D. Chen and P. Zhao, "Study of the fault diagnosis method based on rbf neural network," in *2011 2nd International Conference on Artificial Intelligence, Management Science and Electronic Commerce (AIMSEC)*, Aug 2011, pp. 4350–4353. [Online]. Available: <https://doi.org/10.1109/AIMSEC.2011.6010128>
- [5] Y. G. Wu, C. Z. Song, and L. P. Shi, "Notice of retraction fault diagnosis of engine mission using modified elman neural network," in *2010 Sixth International Conference on Natural Computation*, vol. 2, Aug 2010, pp. 996–998. [Online]. Available: <https://doi.org/10.1109/ICNC.2010.5582900>
- [6] P. Lian, T. Y. Bin, N. Ning, and C. Aiping, "Application of fuzzy neural network in fault diagnosis of gasoline engine," in *2009 9th International Conference on Electronic Measurement Instruments*, Aug 2009, pp. 4–602–4–605. [Online]. Available: <https://doi.org/10.1109/ICEMI.2009.5274658>
- [7] M. Shah, V. Gaikwad, S. Lokhande, and S. Borhade, "Fault identification for i.c.

- engines using artificial neural network,” in *2011 International Conference on Process Automation, Control and Computing*, July 2011, pp. 1–6. [Online]. Available: <https://doi.org/10.1109/PACC.2011.5978891>
- [8] Y. Cay, “Prediction of a gasoline engine performance with artificial neural network,” *Fuel*, vol. 111, pp. 324–331, 2013. [Online]. Available: <https://doi.org/10.1016/j.fuel.2012.12.040>
- [9] Y. Çay, I. Korkmaz, A. Çiçek, and F. Kara, “Prediction of engine performance and exhaust emissions for gasoline and methanol using artificial neural network,” *Energy*, vol. 50, pp. 177–186, 2013. [Online]. Available: <https://doi.org/10.1016/j.energy.2012.10.052>
- [10] R. F. Turkson, F. Yan, M. K. A. Ali, and J. Hu, “Artificial neural network applications in the calibration of spark-ignition engines: An overview,” *Engineering Science and Technology, an International Journal*, vol. 19, no. 3, pp. 1346–1359, 2016. [Online]. Available: <https://doi.org/10.1016/j.jestch.2016.03.003>
- [11] B. D. de L. Ferreira, N. R. Araújo, R. F. Ligório, F. J. Pujatti, M. I. Yoshida, and R. C. Sebastião, “Comparative kinetic study of automotive polyurethane degradation in non-isothermal and isothermal conditions using artificial neural network,” *Thermochimica Acta*, vol. 666, pp. 116–123, 2018. [Online]. Available: <https://doi.org/10.1016/j.tca.2018.06.014>
- [12] Minitab. (2018) Minitab software. [Online]. Available: <https://goo.gl/NDoMTo>
- [13] Incibe-cert. (2015) Incibe-cert. [Online]. Available: <https://goo.gl/5h7696>
- [14] Mathworks. (2018) Mathworks. [Online]. Available: <https://goo.gl/GVhckj>
- [15] J. Calderón, B. Castillo, and J. Moreno, “Diseño de una red neuronal para la predicción del coeficiente de pérdidas primarias en régimen de flujo turbulento,” *INGENIUS*, vol. 20, pp. 21–27, 2018. [Online]. Available: <https://doi.org/10.17163/ings.n20.2018.02>