

Fault Detection and Isolation In Sensors of an Internal Combustion Engine

M. Guzmán-Zaragoza * J. García-Morales **
C. D. García-Beltrán ** M. Adam-Medina **
M. Cervantes-Bobadilla *** R.F. Escobar-Jiménez **

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

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

*** *Centro de Investigación en Ingeniería y Ciencias Aplicadas (CIICAp-IICBA)/UAEM, Av. Universidad 1001, Chamilpa, 62209 Cuernavaca, Morelos, México*

Abstract: This work presents the fault detection and isolation (FDI) system design for the Throttle Position Sensor (TPS), Mass Air Flow (MAF), and Manifold Absolute Pressure (MAP) sensor of an internal combustion engine. The FDI system utilizes five multilayer perceptron artificial neural network (ANN), which were trained to estimate the value of each sensor using the crankshaft position (CKP) and the Air-Fuel ratio (AFR) sensors to generate analytical redundancy. When a fault is induced in one sensor, the FDI system replaces the faulty signal for an adequate estimation of the signal given by one ANN allowing uninterrupted operation of the internal combustion engine.

Keywords: Fault Detection and Isolation, Internal Combustion Engine, Artificial Neural Networks.

1. INTRODUCCIÓN

Los nuevos avances tecnológicos forman parte de la vida cotidiana, tanto en el ámbito laboral, escolar, hogar, transporte, etc. Sin embargo, todos los sistemas están sujetos a fallar en cualquier momento, por este motivo se ha incrementado el interés por la supervisión y detección de fallas en línea, con el fin de aumentar la eficiencia, mantenibilidad y fiabilidad de los sistemas aún en presencia de fallas, Chen and Patton (1999). Es por ello que se han desarrollado sistemas tolerantes a fallas empleando diferentes algoritmos de estimación para visualizar parámetros y variables de un sistema como se presenta en García-Morales et al. (2015), Escobar et al. (2011), Amin and Mahmood-ul Hasan (2019), Lin and Wu (2019) y Mu et al. (2017).

El motor de combustión interna (MCI) es un sistema susceptible a fallas. En los últimos años el MCI ha cambiado en gran medida con el fin de mejorar su rendimiento y de cumplir con las regulaciones de emisión de gases contaminantes, lo cual, ha provocado un aumento en la cantidad de sus componentes, como sensores y actuadores, León et al. (2018). Este incremento de sensores y actuadores

hace más complicado la detección de fallas, debido a que una falla de un sensor puede provocar que otros sensores también tengan mediciones fuera de sus parámetros y complique la detección.

Las empresas automovilísticas han desarrollado esquemas de detección de fallas en los MCI con la finalidad de dar aviso al usuario de la ocurrencia de alguna falla, a pesar de ello, los usuarios no siempre atienden los indicadores de fallas, sobretodo, si las fallas permiten que el vehículo siga operando por mucho tiempo, sin embargo, en general estas fallas ocasionan que el caudal de combustible inyectado al motor no sea el adecuado y la combustión no se realice de forma completa generando principalmente mayor emisión de gases contaminantes y exceso de consumo de combustible, entre otras implicaciones (pérdida de potencia, detonaciones fuera de tiempo, deterioro de la máquina, etc.); estos problemas se pueden reducir implementando un sistema de detección y aislamiento de fallas. Recientemente se han implementado sistemas de detección y aislamiento de fallas (FDI) en los MCI con la finalidad de que el vehículo siga funcionando pero con señales estimadas a partir de otros sensores. En el trabajo presentado por Carbot-Rojas et al. (2019),

se realizó un sistema de detección de fallas en los sensores de presión y temperatura del múltiple de admisión usando un banco de filtros de Kalman extendidos. En Yu et al. (2014), los autores aplicaron un esquema de FDI utilizando un modelo de red neuronal artificial para detectar fugas en el múltiple y mal funcionamiento del inyector en el MCI, obteniendo resultados favorables. En Meng et al. (2019), se muestra el desarrollo de un observador basado en el filtro de Kalman extendido con el fin de optimizar la mezcla aire-combustible minimizando el ruido del sistema de inyección del MCI. En Sangha et al. (2005), se utilizó una red neuronal con función de base radial para el desarrollo de un FDI con el fin de detectar fugas en el múltiple, fallas en la válvula de recirculación de gases de escape (EGR), obteniendo resultados satisfactorios para los casos propuestos. En Murtaza et al. (2018), los autores implementaron un FDI y un FTC por medio de observadores de alto orden por modos deslizantes y control adaptable, enfocado a fallas estructurales en la recirculación de gases en un motor Diesel de uso industrial, demostrando en simulación la efectividad del algoritmo propuesto. En Vasu et al. (2015), los autores presentaron un banco de observadores basados en el modelo del valor medio del motor (MVEM), con el objetivo de aislar fallas en el sensor del acelerador, fugas en el escape y fallas en el sensor de la válvula de EGR.

De acuerdo con Hendricks and Luther (2001), el objetivo del sistema de control del MCI es mantener una adecuada relación estequiométrica aire-combustible (AFR) bajo cualquier condición de operación del MCI. Por lo tanto, la confiabilidad de la lectura ininterrumpida de las variables del MCI es de suma importancia. Las principales variables para mantener la AFR adecuada son la medición de la apertura de la válvula de mariposa, el caudal másico de aire y la presión del múltiple de admisión. La correcta relación de aire-combustible mejora la eficiencia de combustión y mantiene un uso eficiente del combustible, así mismo, la potencia de la máquina mejora y disminuye la emisión de gases contaminantes.

En este trabajo de investigación se realiza la detección y aislamiento de fallas en tres sensores del MCI, específicamente en el sensor de posición de la válvula de mariposa (TPS), sensor de flujo másico de aire (MAF) y el sensor de presión del múltiple de admisión (MAP), esto es posible debido al esquema propuesto para la detección y aislamiento fallas. El esquema propuesto utiliza redundancia en las redes neuronales para detectar la falla y sustituir la señal fallada utilizando una red neuronal que estima la variable con falla a partir de otros sensores saludables. Utilizando la redundancia de redes neuronales se logró establecer una tabla de firmas con la cual es posible identificar cualquiera de los tres sensores con fallas y tomar la decisión de qué red neuronal debe reemplazar la señal fallada.

2. REDES NEURONALES ARTIFICIALES

Una red neuronal artificial (RNA o ANN en inglés) es un algoritmo matemático que permite modelar las relaciones entre datos de entrada $x \in \mathbb{R}^n$ y salida $y \in \mathbb{R}^m$ proporcionados por medio de un proceso de entrenamiento, Jung (2020). Las RNA varían dependiendo de la cantidad de neuronas, cantidad de capas y el tipo de conexiones entre ellas, en este caso, la RNA mostrada en la Fig. 1 es una red tipo perceptrón multicapa de una capa oculta y una capa de salida, con tres entradas y dos salidas. La relación entrada-salida de esta RNA está dada por la Ec. (1).

$$\mathbf{y}_k^{II} = [\mathbf{w}_{ik}^{II} \varphi^{II}(\mathbf{w}_{ij}^I \varphi^I(\mathbf{x}_i + \theta_j^I) + \theta_k^{II})] \quad (1)$$

donde \mathbf{y}_k , \mathbf{x}_i , φ^I , φ^{II} , \mathbf{w}_{ik}^{II} , \mathbf{w}_{ij}^I , θ_j^I , θ_k^{II} , son la k-ésima salida, la i-ésima entrada, las funciones de activación de la primera y segunda capas, los i-ésimos pesos sinápticos de la k-ésima neurona de la segunda capa, los i-ésimos pesos sinápticos de la j-ésima neurona de la primera capa, el j-ésimo bias de la primera capa y el k-ésimo bias de la segunda capa, respectivamente, siendo k el número de neuronas en la capa de salida y j el número de neuronas en la capa oculta.

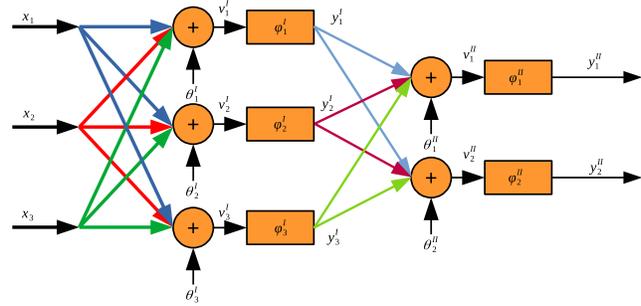


Fig. 1. Red neuronal artificial 3-2 perceptrón multicapa

2.1 Entrenamiento de RNA

En esta investigación se utilizaron cinco redes neuronales artificiales perceptrón multicapa, de arquitectura como la mostrada en la Fig. 1, a excepción de la RNA 5, la cual es de cinco neuronas en la capa oculta y dos en la capa de salida. Las RNA fueron entrenadas con datos experimentales obtenidos del motor de combustión interna de 4 tiempos, 4 cilindros, 1.6 litros de 78 kW/6000 RPM que se localiza en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) ubicado en Cuernavaca, Morelos.

Para el entrenamiento de la red los datos experimentales fueron divididos aleatoriamente, el 60% se utilizó para actualizar los valores de los pesos y bias, un subconjunto de validación del 20% y subconjunto de prueba del 20% con el objetivo de combatir el fenómeno de sobreajuste. Para el entrenamiento se utilizó un total de 60000 muestras para la actualización, validación y prueba de la RNA. Los pesos y los bias se obtuvieron mediante el algoritmo de

retropropagación del error, los algoritmos de retropropagación utilizan una función de error para minimizarlo, utilizando un algoritmo de optimización como el gradiente descendiente o Levenberg-Marquardt (LM), entre otros. En este caso se utilizó el algoritmo LM representado en la Ec. (2) para entrenar cada red, obteniendo los pesos sinápticos y los *bias* para cada neurona.

$$\mathbf{X}_{k+1} = \mathbf{X}_k - [\mathbf{J}^T(\mathbf{X}_k)\mathbf{J}(\mathbf{X}_k + \mu_k\mathbf{I})^{-1}\mathbf{J}^T(\mathbf{X}_k)\mathbf{V}(\mathbf{X}_k)] \quad (2)$$

donde \mathbf{X} es el vector de entradas, \mathbf{J} es la matriz Jacobiana y \mathbf{V} es la función de error, respectivamente. La matriz Jacobiana se entiende como el arreglo de derivadas parciales de cada error con respecto a cada peso y *bias* de cada capa.

2.2 Estimación de variables

Para el sistema de detección es necesario estimar las mediciones de los tres sensores sobre los que se va a trabajar, por consiguiente, se proponen cinco redes con el propósito de tener disponible estimaciones correctas aún cuando alguna red que depende de un sensor fallado proporcione una estimación errónea. Para una mejor estimación, se utilizan las señales de la velocidad del cigüeñal proporcionado por el sensor CKP y la relación aire-combustible como señales de entrada auxiliares en cada una de las redes. En la Tabla 1 se muestran las señales de entrada principal de cada red y el par de estimaciones correspondiente a cada una.

Table 1. Redes neuronales del esquema de detección

Red	Entrada	Estimación 1	Estimación 2
RNA1	MAF	MAF	TPS
RNA2	TPS	MAF	TPS
RNA3	MAP	MAF	TPS
RNA4	MAF	MAF	MAP
RNA5	TPS	MAF	MAP

3. ESQUEMA DE DETECCIÓN DE FALLAS

Para poder detectar cada falla es necesario clasificar la estimación resultante de cada red para obtener la firma característica de cada falla y seleccionar la red que podría reemplazar al sensor fallado. En la Fig. 2 se muestra la clasificación de las estimaciones del banco de redes en caso de que ocurriese cada una de las fallas.

Con motivo de clarificar la clasificación de estimaciones se utilizará como ejemplo una falla en el sensor MAF. El sensor MAF es utilizado como entrada en las redes neuronales 1 y 4, entonces en caso de falla del MAF las estimaciones de dichas redes serán incorrectas, aún cuando el sensor que se esté estimando, TPS o MAP, se considere saludable, es decir:

$$\begin{aligned} \hat{y}_{1,RNA1} &= \text{medición}_{MAF} \\ \hat{y}_{2,RNA1} &\neq \text{medición}_{TPS} \\ \hat{y}_{1,RNA2} &\neq \text{medición}_{MAF} \\ \hat{y}_{2,RNA2} &= \text{medición}_{TPS} \end{aligned} \quad (3)$$

En otras palabras, la estimación de la medición sensor MAF por la red 2 es correcta, ya que esta red no utiliza la señal del sensor fallado, sino la medición del sensor TPS, y por el contrario, aún cuando no existe una falla en sensor TPS, la estimación otorgada por la red 1 es incorrecta ya que utiliza al sensor fallado (MAF) para generar la estimación. Siguiendo esta lógica en el resto de redes y para los otros dos escenarios se realizó una clasificación utilizando un código de colores para identificar que red neuronal puede sustituir la señal fallada.

- Ambas señales saludables (medición y estimación) de color verde.
- Estimación correcta, medición fallada de color amarillo.
- Medición saludable, estimación fallada de color naranja.
- Ambas señales falladas de color rojo.

Para los otros dos casos (MAP y TPS) la clasificación se aplica de la misma forma. Esta clasificación nos permite obtener la firma de fallas mostrada en la Tabla 2.

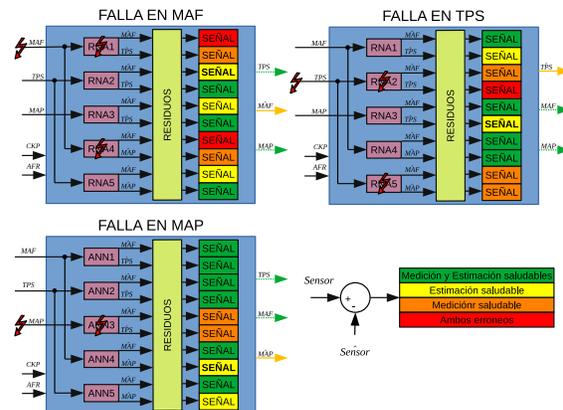


Fig. 2. Clasificación de estimaciones y detección de fallas

En la Fig. 3 se muestra la representación esquemática del sistema FDI propuesto, las mediciones son tomadas directamente de los sensores del motor de combustión interna, pasan por el sistema FDI para posteriormente tomar la decisión que señal se enviará a la Unidad de Control del Motor (ECU, por sus siglas en inglés) con el fin de que se determine un caudal de combustible correcto y un tiempo de ignición adecuado.

3.1 Generación de residuos

La generación de residuos se realiza al comparar la estimación de cada RNA con la medición del sensor, si esta diferencia sobrepasa un umbral, se asigna un valor de 1 o HIGH a dicho residuo, de lo contrario se asigna un valor de 0 o LOW. Los umbrales de cada residuo son determinados a partir del comportamiento de las fallas inducidas, es decir, se ajustaron heurísticamente. Esto debido a que

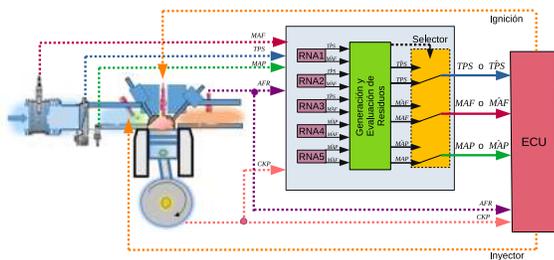


Fig. 3. Esquema de detección y aislamiento de fallas

las variables estimadas tienen una relación importante entre sí en el ambiente de simulación, p.ej. una falla en el sensor MAF significaría que el caudal de aire que ingresa al sistema tiene una degradación y por ende la presión dentro del múltiple también debería ser afectada, pero el sensor TPS medirá correctamente que la apertura de la válvula no ha sido afectada.

En la Tabla 2 se puede observar que cada falla genera un diferente patrón de residuos o firma de falla, con lo cual podemos decir que las fallas son identificables.

Table 2. Tabla de residuos

Residuo	MAF	MAP	TPS
$\hat{M}AF$ RNA 1	0	0	0
$\hat{T}PS$ RNA 1	1	0	0
$\hat{M}AF$ RNA 2	1	0	0
$\hat{T}PS$ RNA 2	0	0	0
$\hat{M}AF$ RNA 3	1	0	1
$\hat{T}PS$ RNA 3	1	1	1
$\hat{M}AF$ RNA 4	0	0	0
$\hat{M}AP$ RNA 4	1	0	0
$\hat{M}AF$ RNA 5	0	0	0
$\hat{M}AP$ RNA 5	0	0	0

En la Fig. 4 se muestran los residuos de las estimaciones de las mediciones de los sensores MAF y TPS de la red 3, donde se observa que coincide de acuerdo a la firma de fallas para el escenario donde se considera una falla en el sensor TPS. De igual forma se obtienen los residuos para el escenario de una falla en el sensor MAF y en el sensor MAP, los cuales se han omitido por motivo del espacio del documento.

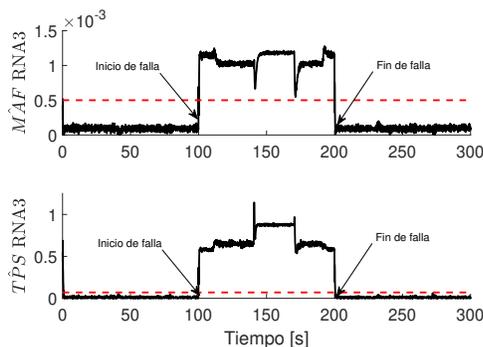


Fig. 4. Residuos de la falla en el sensor TPS

4. RESULTADOS

El esquema propuesto se simuló utilizando el modelo del valor medio del motor, Guzzella and Onder (2009), Mashadi and Crolla (2012). Las fallas se introdujeron por separado para los tres diferentes escenarios de falla. Las fallas que se consideraron son introducidas por software con un porcentaje de degradación de los sensores en un 10% al 20% para considerarlas como fallas por degradación. La velocidad del MCI a la que se realizaron las pruebas para mostrar la funcionalidad del esquema de detección y aislamiento de fallas se muestra en la Fig. 5, partiendo de una velocidad mínima de 880 RPM con incrementos graduales de la velocidad del motor hasta llegar a 3000 RPM. Los cambios de velocidad se realizaron con el fin de obtener el comportamiento de las variables de presión del colector de admisión, flujo másico de aire y apertura de la válvula de mariposa.

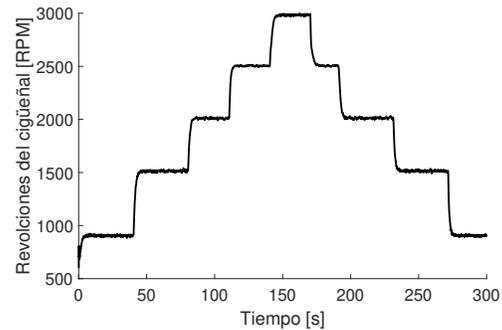


Fig. 5. Velocidad del cigüeñal

En la Fig. 6 se muestra el accionamiento de la válvula de mariposa la cual tiene un rango de apertura de 7.8° a 11° . Para cada ángulo de apertura de la válvula de mariposa corresponde un cambio de velocidad. En la Fig. 6 se puede observar en la línea color rojo el momento de la falla del sensor TPS, la falla aparece a los 100 segundos y de forma inmediata el esquema propuesto sustituye la señal fallada por la señal estimada por la RNA 3 (línea punteada azul) evitando así enviar una señal errónea a la ECU. Si la ECU recibe una señal errónea del TPS, el motor puede seguir operando pero de forma errática o con pérdidas de potencia. En el segundo 200 se recupera la señal del sensor TPS regresando a su medición nominal, provocando que el sistema FDI pase de forma directa la señal medida por el sensor a la ECU.

En la Fig. 7 se muestra el comportamiento de la presión en el múltiple de admisión. En la línea color negro se puede observar el comportamiento de la presión del múltiple de admisión cuando el motor opera sin falla. La presión del múltiple de admisión depende de la velocidad del MCI y de la apertura de la válvula de mariposa pero tiene una mayor dependencia de la velocidad del MCI para este caso en específico, mientras mayor es la velocidad mas fuerte es la presión de vacío generada en el múltiple de admisión. En color rojo se observa el instante en el

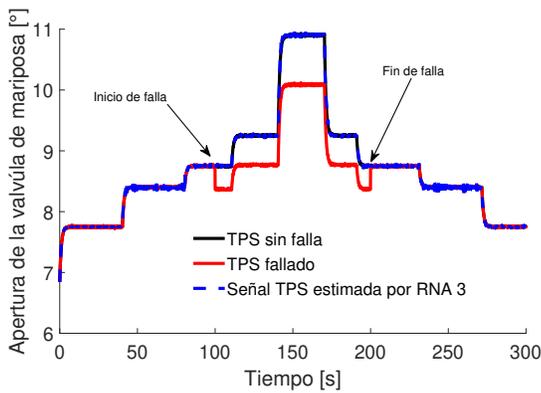


Fig. 6. Reconfiguración de la falla del sensor TPS

que ocurre la falla. La falla inicia en el segundo 10, sin embargo, el sistema FDI sustituye la señal fallada por la señal estimada por la RNA 4, evitando que la ECU reciba la señal fallada. La falla del sensor MAP puede ocasionar que el MCI tenga un consumo excesivo de combustible, en el segundo 280 se recupera la señal del sensor MAP y el sistema FDI deshabilita la señal estimada y permite que la ECU adquiera la señal directa del sensor MAP.

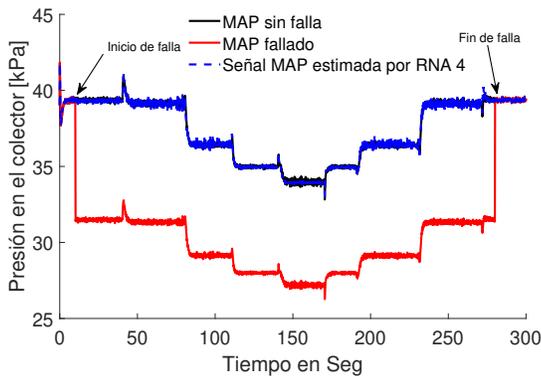


Fig. 7. Falla del sensor MAP

En la Fig. 8 se muestra el flujo de masa de aire que ingresa al MCI. La línea color negra representa la señal del sensor MAF sin falla. La línea color roja muestra la falla en el sensor MAF, la cual inicia en el segundo 55 y se recupera la medición nominal a los 180 segundos, siendo el sistema capaz de aislar la falla en el momento en que se detecta, sustituyendo la señal del sensor fallado por la estimación de la RNA 2. En este caso la estimación no es tan precisa como en los otros casos, sin embargo, la degradación consiguiente es aceptable en comparación a la degradación si se utilizara el sensor fallado.

En la Fig. 9 se muestra el error de estimación para cada variable. El error de estimación se obtiene a partir de la diferencia entre la señal saludable y la estimación de las redes neuronales. En la parte superior de la figura se muestra el error de estimación de la señal del TPS.

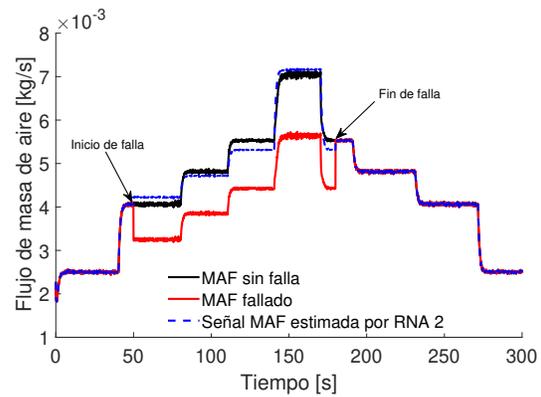


Fig. 8. Reconfiguración del sensor MAF

El cual no sobrepasa de 0.2° . En la parte central de la figura se encuentra el error de estimación de la señal MAF como se mencionó antes, la estimación que sustituye al sensor MAF no es tan precisa como las estimaciones de los otros sensores a pesar de ello, se considera una estimación aceptable para reemplazar al sensor en caso de falla. En la parte inferior se muestra el error de estimación de la presión del múltiple, la cual se observa que tiene una variación promedio de 0.8 kPa. Esta variación en la estimación de la presión no tiene un impacto significativo en la operación del MCI.

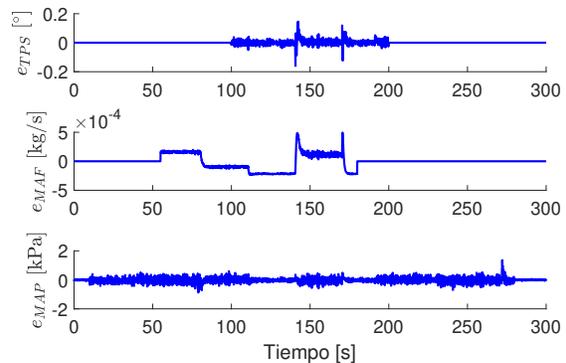


Fig. 9. Error de estimación en la reconfiguración de fallas

En la Fig. 10 se muestra el comportamiento de la relación aire-combustible la cual se observa que se encuentra en un valor de 14.6. El mantener la AFR en 14.6 es un indicativo de que el esquema FDI propuesto cumple con el objetivo de mantener el motor operando de forma aceptable aun en presencia de falla.

5. CONCLUSIÓN

Este trabajo presentó el diseño de un sistema de detección y aislamiento de fallas basado en redundancia analítica para atacar fallas por degradación en los sensores MAF, TPS y MAP de un MCI. Para ello se entrenó y probó en simulación un banco de 5 RNA para estimar la presión del múltiple de admisión, el caudal másico de aire y

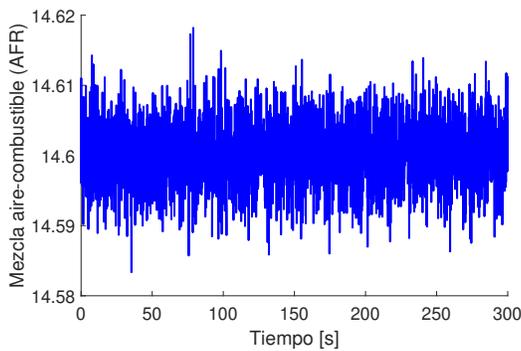


Fig. 10. Relación aire-combustible

la apertura de la válvula de mariposa utilizando las mediciones de velocidad y la relación aire-combustible. Las variables que miden los sensores están fuertemente interrelacionadas, lo cual dificulta la identificación de la falla, sin embargo es posible obtener una firma de fallas diferente para cada escenario. Los resultados muestran que el esquema es capaz de reemplazar la señal de un sensor fallado por la estimación de alguna de las redes. Al reemplazar los sensores fallados se mantiene una relación estequiométrica adecuada en la mezcla aire-combustible, evitando así un gasto excesivo de combustible, un alza en la emisión de gases contaminantes y pérdida de potencia.

ACKNOWLEDGEMENTS

Miguel Maximiliano Guzmán Zaragoza agradece el apoyo financiero proporcionado por el CONACYT (Consejo Nacional de Ciencia y Tecnología de México) mediante la beca con no. CVU: 996676. Además, los autores agradecen el apoyo del TecNM (Tecnológico Nacional de México) por su apoyo en el desarrollo de la investigación en el concurso de Proyectos de Desarrollo Tecnológico e Innovación 2020 con número 9866.20P. Jarniel García Morales, Ricardo Fabricio Escobar Jiménez, Manuel Adam Medina, Marisol Cervantes Bobadilla y Carlos Daniel García Beltrán agradecen el apoyo otorgado por SNI-CONACyT.

REFERENCES

- Amin, A.A. and Mahmood-ul Hasan, K. (2019). Robust active fault-tolerant control for internal combustion gas engine for air-fuel ratio control with statistical regression-based observer model. *Measurement and Control*.
- Carbot-Rojas, D., Besançon, G., and Escobar-Jiménez, R. (2019). EKF based sensor fault diagnosis for an internal combustion engine. In *2019 23rd International Conference on System Theory, Control and Computing (ICSTCC)*, 43 – 48. IEEE.
- Chen, J. and Patton, R. (1999). *Robust Model-based Fault Diagnosis for Dynamic Systems*. Kluger Academic Publisher.
- Escobar, R., Astorga-Zaragoza, C., Téllez-Anguiano, A., Juárez-Romero, D., Hernández, J.A., and Guerrero-Ramírez, G. (2011). Sensor fault detection and isolation via high-gain observers: application to a double-pipe heat exchanger. *ISA Trans.*, 50(3), 480–486.
- García-Morales, J., Adam-Medina, M., Escobar, R.F., Astorga-Zaragoza, C.M., and Garcia-Beltran, C.D. (2015). Diagnóstico de fallas múltiples en los sensores de un intercambiador de calor empleando observadores por modos deslizantes basado en el algoritmo super-twisting. *Revista mexicana de ingeniería química*, 14(2), 553–565.
- Guzzella, L. and Onder, C. (2009). *Introduction to modeling and control of internal combustion engine systems*. Springer Science & Business Media.
- Hendricks, E. and Luther, J.B. (2001). Model and observer based control of internal combustion engines. In *Proceedings of International Workshop on Modeling, Emissions and Control in Automotive Engines (MECA01)*. Citeseer.
- Jung, D. (2020). Residual generation using physically-based grey-box recurrent neural networks for engine fault diagnosis. *arXiv preprint arXiv:2008.04644*.
- León, P.G., García-Morales, J., Escobar-Jiménez, R.F., Gómez-Aguilar, J.F., López-López, G., and Torres, L. (2018). Implementation of a fault tolerant system for the internal combustion engine's maf sensor. *Measurement*, 122, 91–99.
- Lin, T.H. and Wu, S.C. (2019). Sensor fault detection, isolation and reconstruction in nuclear power plants. *Annals of Nuclear Energy*, 126, 398–409.
- Mashadi, B. and Crolla, D.A. (2012). *Vehicle powertrain systems*. Wiley London.
- Meng, L., Luo, J., Yang, X., and Zeng, C. (2019). Intake air mass observer design based on extended kalman filter for air-fuel ratio control on si engine. *Energies*, 12(18), 34–44.
- Mu, W., Wang, J., and Feng, W. (2017). Fault detection and fault-tolerant control of actuators and sensors in distributed parameter systems. *Journal of the Franklin Institute*, 354(8), 3341–3363.
- Murtaza, G., Bhatti, A.I., and Butt, Y.A. (2018). Super twisting controller-based unified fdi and ftc scheme for air path of diesel engine using the certainty equivalence principle. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 232(12), 1623–1633.
- Sangha, M.S., Gomm, J.B., Yu, D.L., and Page, G.F. (2005). Fault detection and identification of automotive engines using neural networks. *IFAC Proceedings*, 38(1), 272–277.
- Vasu, J.Z., Deb, A.K., and Mukhopadhyay, S. (2015). Mvem-based fault diagnosis of automotive engines using dempster-shafer theory and multiple hypotheses testing. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 45(7), 977–989.
- Yu, D.L., Hamad, A., Gomm, J.B., and Sangha, M.S. (2014). Dynamic fault detection and isolation for automotive engine air path by independent neural network model. *International Journal of Engine Research*, 15(1), 87–100.