

Modelo basado en redes neuronales artificiales de un motor de combustión interna

J. D. Martínez-Morales*, E. Palacios**, G. Velázquez-Carrillo***

*Centro de Investigación y Estudios de Posgrado, Facultad de Ingeniería-UASLP, S.L.P., México
(Tel: 444 8 17 33 81; e-mail: jdaniel.martinez@alumnos.uaslp.edu.mx).

**Facultad de Ciencias-UASLP, S.L.P., México. En estancia sabática en la Sección de Mecatrónica,
CINVESTAV-IPN (e-mail: epalacios@fciencias.uaslp.mx)

*** Departamento de Mecatrónica, ITESM Campus Santa Fe, D. F., México.

Resumen—En este trabajo, se presenta el modelo de un motor de combustión interna basado en redes neuronales artificiales (RNA), los datos de entrenamiento son extraídos de un motor de gasolina de 1.6 L. El motor está acoplado a un dinamómetro hidráulico, siendo posible variar la velocidad del motor a través de una carga impuesta al motor. Las variables medidas del motor son velocidad, tiempo de inyección, ángulo del pedal del acelerador y emisiones contaminantes (hidrocarburos, monóxido de carbono y óxidos de nitrógeno).

Palabras clave: Motor de combustión, RNA, emisiones contaminantes.

I. INTRODUCCIÓN

El diseño de sistemas de control para motores a gasolina de los automóviles modernos, ha llegado a ser una tarea muy demandante en tiempo. La cantidad creciente de variables y su mutua interacción conduce a dificultades en encontrar modelos del motor de combustión y su calibración. Los motores de ignición por chispa (SI, spark ignition) tienen múltiples entradas, como la cantidad de combustible inyectado, el ángulo de ignición, ángulo de inyección, además de la razón aire/combustible, velocidad del motor, presión de inyección, entre otras. Estas entradas están acopladas e influyen en las salidas del motor como consumo de combustible y emisiones contaminantes. Esto resulta en el problema de encontrar un modelo para un sistema con múltiples entradas y múltiples salidas acopladas no linealmente (Cawsey et. al 2004, Hafner 2001).

Una búsqueda manual para la solución óptima de la calibración de un motor de combustión interna (MCI), no es viable si se considera el alto número de variables que deben ser controladas. Por lo tanto, se necesitan de nuevos modelos para calibrar los mapas de control fuera de línea en la PC. Algunos de los modelos para el motor de combustión interna requieren conocimiento específico de los parámetros dinámicos del motor, que en la mayoría de los casos son desconocidos. Aunque se han desarrollado modelos químicos y físicos del motor de combustión, no se ha encontrado una solución general (Hiroyasu et. al, 1976, Barths et. al, 1996), por otra parte, la mayoría de los modelos presentados son en la forma de modelos de cajas negras (Atkinson et. al 2000, Hafner et. al 2001, Hafner et. al 2000, Alonso et. al 2007). Las redes neuronales

artificiales han sido ampliamente usadas en diversas áreas de la ingeniería debido a su habilidad para modelar fenómenos no lineales. En este trabajo se presenta el modelo de las emisiones contaminantes de un motor de combustión interna, con la finalidad de utilizarlo posteriormente para predecir las emisiones en una PC.

1.1. Banco experimental del motor de combustión interna.

Para el presente trabajo, se realizaron mediciones de emisiones contaminantes de hidrocarburos (HC), monóxido de carbono (CO) y óxidos de nitrógeno (NOx) en régimen estático, para diferentes valores de velocidad del motor n_{eng} (rpm) y ángulo del pedal del acelerador α_{pedal} (%). Las emisiones se midieron mediante el analizador de gases FGA4000XDS y los parámetros como presión del múltiple de admisión, razón aire/combustible y flujo de combustible m_{fuel} (lb/hr) mediante el software del dinamómetro Super Flow SF-902. Adicionalmente se midió el tiempo de apertura de un inyector t_{inj} (ms) mediante un osciloscopio Tektronix. En las Figuras 1 y 2 se muestran el esquema empleado para realizar las mediciones y el motor a gasolina respectivamente. El MCI está acoplado a un dinamómetro hidráulico, siendo posible variar la velocidad del motor a través de una carga impuesta al motor. El ángulo de la válvula de admisión impone la cantidad de aire que entra al motor, que es utilizado por la unidad de control electrónica (ECU, por sus siglas en inglés) para determinar la cantidad de combustible a inyectar. El dinamómetro sólo aplica una carga en torque y la velocidad angular del motor aumenta o disminuye en consecuencia

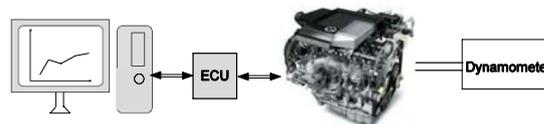


Figura 1. Diagrama a bloques del banco experimental.

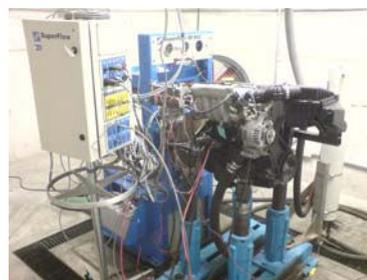


Figura 2. MCI acoplado al dinamómetro SF-902.

En la Tabla 1 se muestran las características del motor de combustión empleado.

TABLA I.
Características del MCI

Característica	Valor
Modelo	Z16SE 2005
Potencia máxima	100 Hp a 5600 rpm
Cilindrada	1597 cc.
Carrera	81.5 mm
Relación de compresión	9.4:1
Tipo de inyección	Secuencial
Torque máximo	138 Nm a 300 rpm

II. MODELO DEL MOTOR DE COMBUSTIÓN INTERNA

Se desarrolló un modelo dinámico del motor de combustión interna basado en redes neuronales artificiales (RNA). La función de aproximación generada por la red neuronal fue usada para transformar el comportamiento no lineal de las entradas del motor de combustión, en una salida que se aproxime a la salida real del motor. La red neuronal de base radial está basada en la suma de productos, cuya función de activación es de base radial (función de validez) descrita por la siguiente ecuación

$$\phi(x, c) = \exp\left(\frac{-\|x - c\|^2}{2\sigma^2}\right) \quad (1)$$

donde x son las entradas de la red, c son los centros de las funciones radiales y σ son los anchos de las mismas. En la Figura 3 se muestra la estructura de la red neuronal empleada para modelar el MCI.

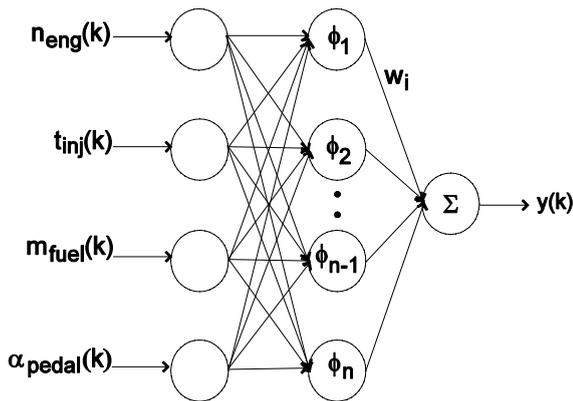


Figura 3. Estructura del modelo neuronal con funciones de activación de base radial.

La salida de la RNA con n neuronas en la capa oculta está dada por:

$$\hat{y} = \sum_{i=1}^n w_i \phi_i(x, c_i) \quad (2)$$

donde w_i denota el peso i de entrenamiento. Se escogió la raíz del error cuadrático medio (RMSE) normalizado como factor para escoger el modelo neuronal óptimo, es

decir, que tenga una respuesta más cercana a los datos del motor de combustión.

$$RMSE = \frac{1}{2} \sqrt{\sum_{i=1}^N \left(\frac{y_i}{\max(y_i)} - \frac{\hat{y}_i}{\max(\hat{y}_i)} \right)^2} \quad (3)$$

donde \hat{y}_i y y_i son las salidas de la red neuronal y las mediciones de las emisiones del MCI respectivamente, y N es el número de muestras. Los datos de entrada de la red neuronal son n_{eng} (rpm), m_{fuel} (lb/hr), t_{inj} (s), α_{pedal} (%), mientras que los datos de salida de la red son HC, CO y NOx, los cuales fueron extraídos del banco experimental. Para este trabajo se consideraron 60 muestras para cada variable, con lo cual se obtiene un mapa del motor de 15 x 4 puntos para cada emisión contaminante. Para el entrenamiento de las redes neuronales se consideró el 60% de los datos extraídos del motor, mientras que el 40% se utilizaron como datos de validación. La selección de los datos de entrenamiento fue realizada de manera aleatoria. En las Figuras 4 y 5 se muestran los datos de entrada y de salida respectivamente, extraídos del banco experimental para llevar a cabo el entrenamiento y verificación del modelo neuronal.

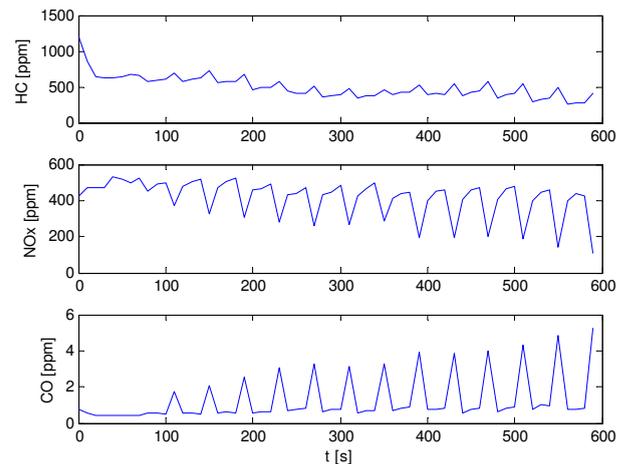


Figura 4. Datos de entrada para el entrenamiento y verificación del modelo del motor.

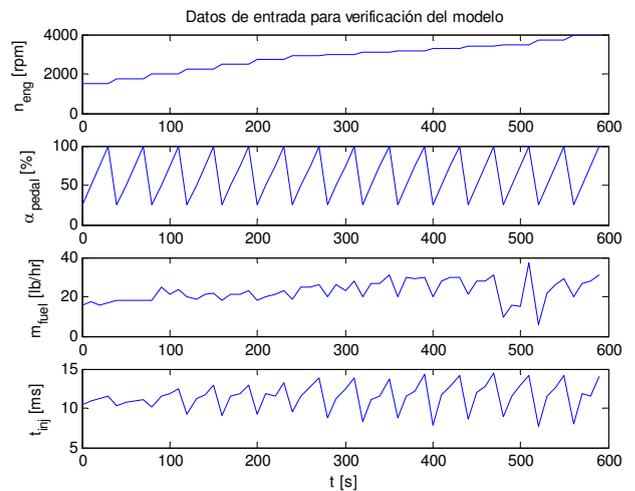


Figura 5. Datos de salida para el entrenamiento y verificación del modelo del motor.

Se construyó una RNA para cada emisión, esto para permitir un mejor ajuste de la red para cada emisión. A continuación se muestran los resultados experimentales, en las Figuras 6, 7 y 8 se muestran los mapas proporcionados por las RNAs y por el MCI para cada emisión.

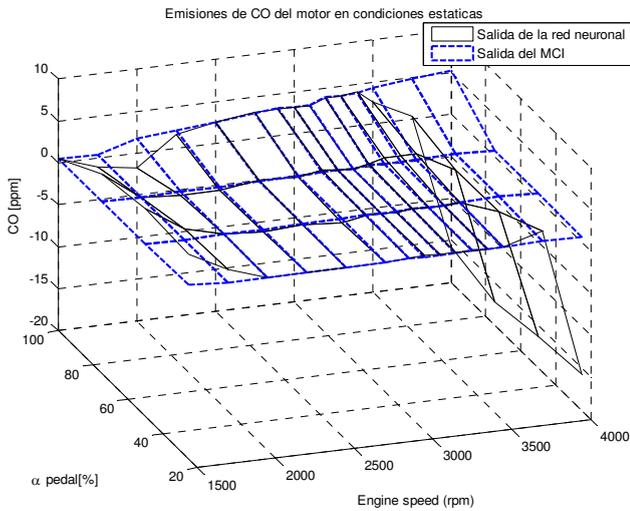


Figura 6. Mapas del MCI y el modelo neuronal para CO.

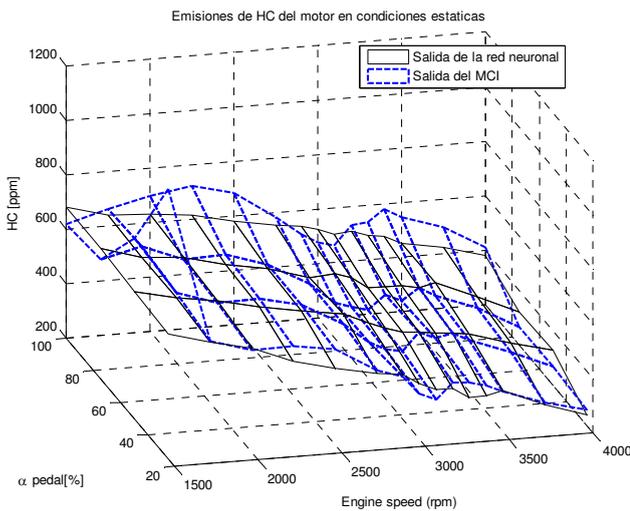


Figura 7. Mapas del MCI y el modelo neuronal para HC.

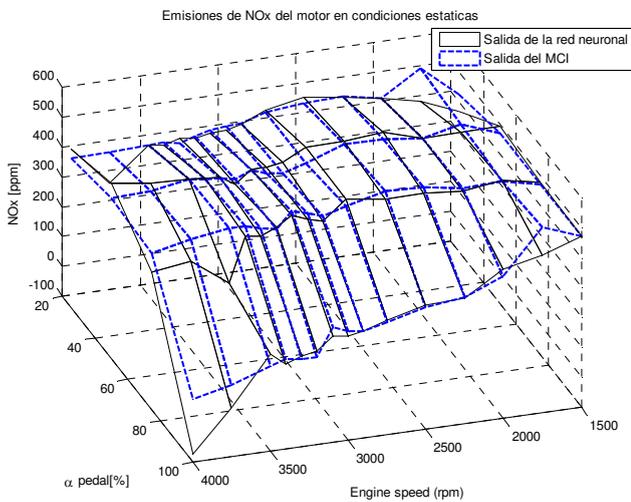


Figura 8. Mapas del MCI y el modelo neuronal para NOx.

Los valores de σ fueron elegidos mediante el método de prueba y error en base a los valores RMSE obtenidos por cada red. En las Figuras 9, 10 y 11 se muestran los valores RMSE para dos modelos neuronales diferentes para cada emisión, se puede observar que el error crece entre las muestras 50 y 60, esto debido a que la salida de cada red es sensible a los parámetros de la misma

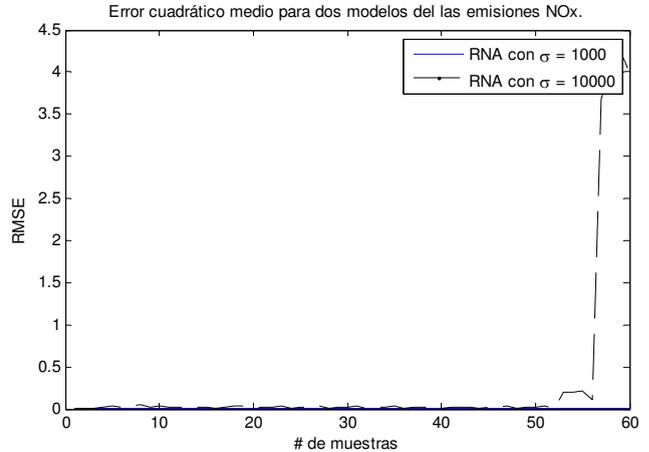


Figura 9. RMSE para la salida de emisiones de NOx para diferentes valores de σ .

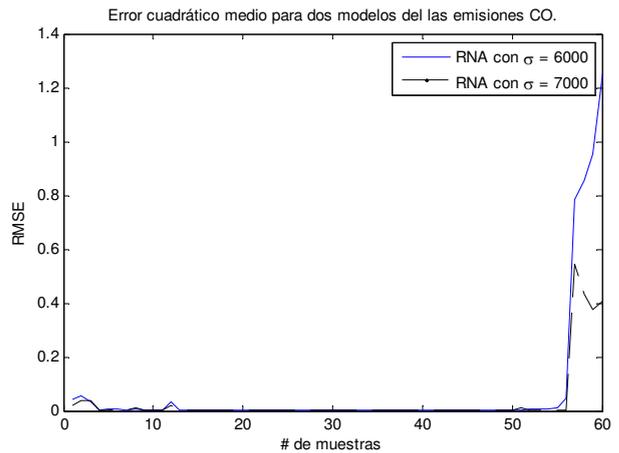


Figura 10. RMSE para la salida de emisiones de CO para diferentes valores de σ .

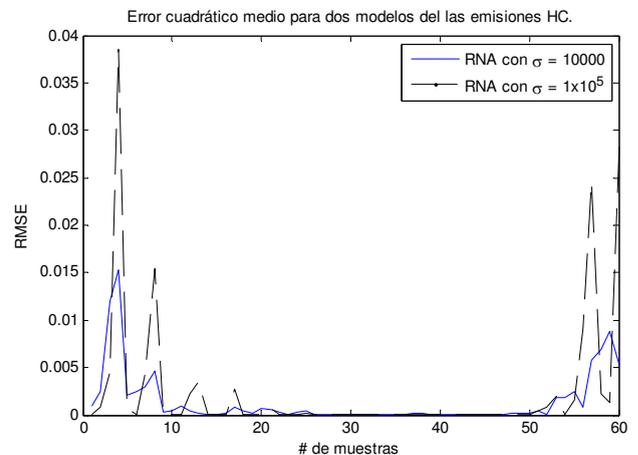


Figura 11. RMSE para la salida de emisiones de HC para diferentes valores de σ .

Como puede observarse el RMSE es pequeño para distintos valores de σ , lo que garantiza una buena aproximación a la salida real del motor. Finalmente, en las Figuras 12, 13 y 14 se muestran las salidas del modelo de emisiones de HC, CO y NOx, para la fase de verificación.

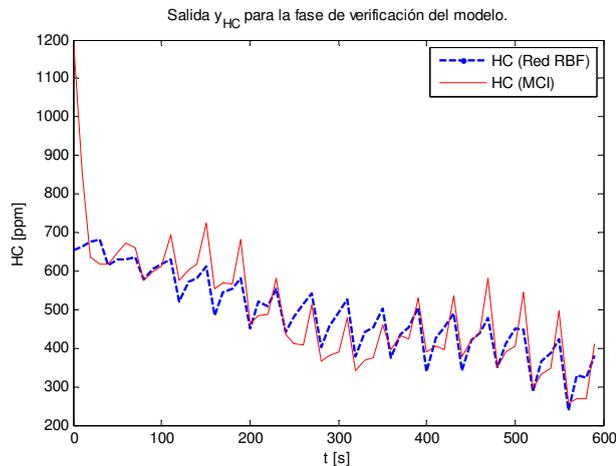


Figura 12. Salida de la red neuronal para las emisiones de HC.

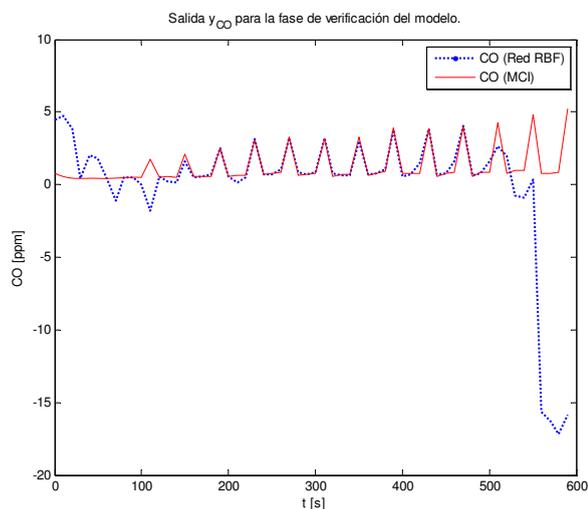


Figura 13. Salida del modelo neuronal para las emisiones de CO.

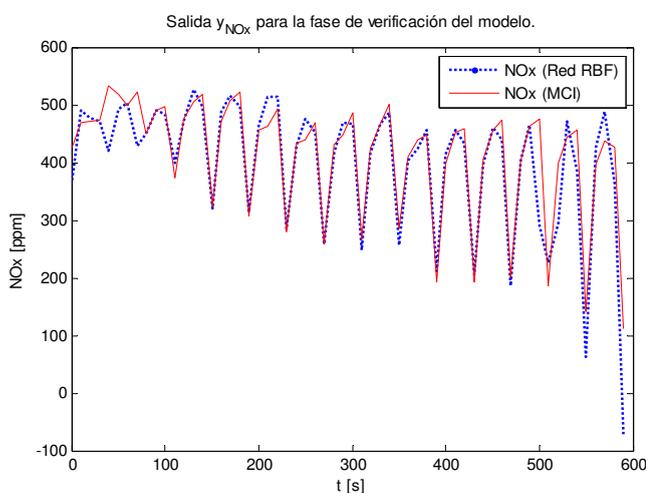


Figura 14. Salida del modelo neuronal para las emisiones de NOx.

Este modelo puede ser empleado para predecir el comportamiento de las emisiones contaminantes del MCI y posteriormente ajustar los mapas motores mediante algoritmos de optimización multi-objetivo con el fin de reducir las emisiones contaminantes del motor (Jankovic et. al 2006, Hafner et. al 2003).

III. CONCLUSIONES

En este trabajo se propone un modelo basado en redes neuronales para las emisiones contaminantes de hidrocarburos, monóxido de carbono y óxidos de nitrógeno del motor de combustión interna a gasolina, al tener un modelo computacional que predice el comportamiento del motor es posible reducir el tiempo de calibración de un motor. El modelo es capaz de reproducir los mapas del motor que pueden ser usados para disminuir las emisiones contaminantes mediante algoritmos de optimización multiobjetivo lo cual se considera como trabajo a futuro.

AGRADECIMIENTOS

J. D. Martínez-Morales agradece el soporte financiero de CONACYT a través de la beca 45765. Este trabajo fue apoyado por SEP-Conacyt (61375).

REFERENCIAS

- Cawsey P. y Guerrier, M. (2004). The development of model based methodologies for gasoline IC engine calibration. SAE paper 2004-01-1466.
- Hafner M. (2001). Model Based Determination of Dynamic Engine Control Function Parameters. SAE Technical Paper 2001-01-1981, 2001.
- Hiroyasu H., Kadota T. (1976). Models for Combustion and Formation of Nitric Oxide and Soot in Direct Injection Engines, SAE Technical Paper 760129, 1976.
- Barths H., Pitsch H., y Peters N. (1996). Three-Dimensional Modeling of NOx and Soot Formation in Di-Diesel Engines Using Detailed Chemistry Based on the Interactive Flamelet Approach. SAE Technical Paper 962057, 1996.
- Atkinson C.M., Thompson G.J., Clark N.N., Long T.W., y Hanzevack E. (2000). Neural network Modelling of the Emissions and Performance of a Heavy-Duty Diesel Engine. In Proc. Instn. Mech. Engineers. Part D: J. Automobile Eng. 2000;214:111-126.
- Hafner M. y Isermann R. (2001). Mechatronic Combustion Engines-From Modeling to Optimal Control, Eur. J. Control 2001;7:220-247.
- Hafner M., Schuler M., Nelles O., Isermann R. (2000). Fast Neural Networks for Diesel Engine Control Design. In Control Eng. Prac. 2000;8:1211-1221.
- Alonso J.M., Alvarruiz F., Desantes J.M., Hernandez L., Hernandez V., Molto G. (2007). Combining Neural Networks and Genetic Algorithms to Predict and Reduce Diesel Engine Emissions. IEEE Trans. Evol. Comput. 2007;11:46-55.
- Jankovic M., Popovic D., Magner S., y Teel A.R. (2006). Extremum Seeking Methods for Optimization of Variable Cam Timing Engine Operation. IEEE Trans. Control Syst. Technol. 2006;14:398-407.
- Hafner M., Iserman R. (2003). Multiobjective Optimization of Feedforward Control Maps In Engine Management Systems Towards Low Consumption and Low Emissions. T. I. Meas. Control 2003;25:57-74