

## Comparación de desempeño de las redes RBF y LOLIMOT para modelar las emisiones de NO<sub>x</sub> de un motor de combustión interna

José D. Martínez-Morales\*, Elvia R. Palacios-Hernández\*\*, José M. Romo-Orozco\*\*\*

\*Unidad Académica Multidisciplinaria Zona Media, Universidad Autónoma de San Luis Potosí, 79617, México  
(Tel: 487-8725099; e-mail: daniel.martinez@uaslp.mx)

\*\*Facultad de Ciencias, Universidad Autónoma de San Luis Potosí, 78290, México  
(Tel: 444-8262491; e-mail: epalacios@fciencias.uaslp.mx)

\*\*\*Unidad Académica Multidisciplinaria Zona Media, Universidad Autónoma de San Luis Potosí, 79617, México  
(Tel: 487-8725099; e-mail: jmromo@uaslp.mx)

---

**Resumen:** En este trabajo, se presenta el desempeño de dos tipos de redes neuronales artificiales (RNA) para predecir el comportamiento de emisiones de óxidos de nitrógeno (NO<sub>x</sub>) de un motor de combustión interna (MCI). Los modelos están basados en la red de base radial (RBF) y la red de árboles de modelos locales lineales (LOLIMOT). Para llevar a cabo el entrenamiento de las RNA, se han extraído datos de un motor de gasolina de 1.6 L, acoplado a un dinamómetro hidráulico. Las variables medidas del MCI para predecir NO<sub>x</sub> son la velocidad del motor, el tiempo de inyección, el ángulo del pedal del acelerador, la presión del múltiple de admisión, el flujo de combustible inyectado y el ángulo de ignición. El desempeño de las diferentes RNA fue evaluado usando criterios de evaluación estadísticos estándar. Los resultados muestran que el uso de las redes RBF y LOLIMOT son capaces de predecir el comportamiento de las emisiones de NO<sub>x</sub> con coeficientes de correlación  $R^2 = 0.97979$  y  $R^2 = 0.99452$  respectivamente.

*Palabras clave:* Motor de combustión interna, redes neuronales artificiales, RBF, emisiones NO<sub>x</sub>.

---

### 1. INTRODUCCIÓN

Con el objetivo de llevar a cabo la calibración de motores de combustión interna (MCI), se requiere conocer las respuestas del motor para toda la gama de condiciones de funcionamiento para re-ajustar el valor de los parámetros de control de la unidad de control electrónico (ECU, electronic control unit), mejorando el rendimiento del motor y reduciendo las emisiones de escape (Deng et al. 2012), que tienen efectos negativos sobre la salud y el medio ambiente. Sin embargo, realizar experimentos con el MCI para la gama completa de condiciones de funcionamiento podría ser muy costoso y requerir mucho tiempo. Para superar estos inconvenientes, la calibración del sistema de control electrónico puede llevarse a cabo con la ayuda de un modelo de las respuestas del motor, que establezca la relación entre los parámetros de control como el flujo de combustible inyectado, el tiempo de inyección, el ángulo de ignición, la velocidad del motor, entre otros, que tienen influencia en el consumo de combustible, las emisiones y la capacidad de conducción (Guerrier et al. 2004). Los modelos utilizados en la calibración del motor se pueden dividir en dos grupos principales, fenomenológicos y modelos empíricos. Aunque se han propuesto varios modelos fenomenológicos (Mehrnoosh et al. 2012, Kim et al. 2001, Rakopoulos et al. 2008), las respuestas del motor son difíciles de identificar utilizando sólo principios físicos. Mehrnoosh et al. (2012), presentaron un modelo termodinámico para predecir las concentraciones de consumo de combustible y las emisiones

de CO<sub>2</sub>, CO, NO y UHC de un MCI de encendido por chispa, alimentado con gasolina y gas natural comprimido. Kim et al. (2001), desarrollaron un modelo multidimensional para predecir las emisiones de NO y hollín. En su estudio, el cálculo se realiza mediante un código KIVA-3V. Rakopoulos et al. (2008), aplicaron el modelado de múltiples zonas para explicar las emisiones de NO y hollín de un motor diesel alimentado con mezclas de etanol y diesel. Sin embargo, estas simulaciones pueden tomar algunas horas o días, dependiendo de la complejidad del modelo químico.

Como alternativa, las redes neuronales artificiales (RNA) se pueden emplear para predecir las emisiones contaminantes del MCI para la mayoría de las condiciones de funcionamiento del motor a partir de datos experimentales. Esencialmente, los elementos de proceso de una red neuronal son análogos a las neuronas en el cerebro, que consisten de muchos elementos computacionales dispuestos en varias capas (Simpson, 1990). La estructura de las RNA permite encontrar relaciones no lineales del MCI, y tienen la capacidad de predecir los casos que no están incluidos en el conjunto de datos de entrenamiento. Estas habilidades hacen a las RNA adecuadas para solucionar problemas complejos no lineales, incluyendo aplicaciones de modelado de emisiones contaminantes en los MCI (Ghazikhani et al. 2011, Cay et al. 2013). Ghazikhani et al. (2011), emplearon redes neuronales perceptrón multicapa (MLP, multilayer perceptron) para predecir las emisiones de hollín de un motor diesel con inyección directa y turboalimentado, teniendo en cuenta como parámetros de entrada de la red a la presión del

colector de admisión, la temperatura del múltiple de admisión, el flujo de aire de entrada, el consumo de combustible, el torque y la velocidad del motor. En su estudio, la RNA puede predecir las emisiones con un coeficiente de correlación  $R^2$  de 0.9998. Cay et. al (2013), emplearon RNA con cuatro algoritmos diferentes de entrenamiento para predecir el consumo de combustible específico de frenado (BSFC, break specific fuel consumption), la relación de aire y combustible (AFR, air fuel ratio), y las emisiones de CO y HC de un motor alimentado con mezclas de gasolina y metanol. Ellos consideraron el tipo de combustible, el torque, la velocidad del motor y el flujo de combustible como entradas a la RNA. En su estudio, el modelo de RNA es capaz de predecir el rendimiento del motor y las emisiones con coeficientes de correlación de 0.9986, 0.9776, 0.9983 y 0.9960 para el BSFC, CO, HC y AFR respectivamente.

En este trabajo se presenta el modelado de las emisiones contaminantes de óxidos de nitrógeno (NOx) de un MCI alimentado con gasolina para diferentes puntos de operación definidos por la velocidad del motor y el ángulo del pedal del acelerador. La predicción se realiza en términos de las variables de tiempos de inyección, ángulos de ignición, flujo de combustible inyectado y presión absoluta del múltiple de admisión.

1.1. Descripción del motor de combustión interna y el banco de pruebas

Para el presente trabajo, los experimentos se llevaron a cabo en un MCI de cuatro tiempos con ignición por chispa (Chevrolet Z16SE2005®). El MCI tiene un volumen de cilindro de 1.597 L y una relación de compresión de 9.4:1. Otras especificaciones del MCI se muestran en la Tabla 1.

Tabla 1. Especificaciones del MCI

Especificación	Valor
Modelo	Z16SE 2005
Potencia máxima	100 Hp/5600 rpm
Cilindrada	1.597 L
Carrera	81.5 mm
Relación de compresión	9.4:1
Tipo de inyección	Secuencial
Torque máximo	138 Nm/3200 rpm

Se realizaron mediciones de las emisiones contaminantes de NOx en régimen estático para 60 condiciones de funcionamiento definidas por 15 velocidades del motor ( $n_{eng}$ ) en el rango de 1,500 a 4,000 rpm, con 25%, 50%, 75% y 100% de apertura del pedal del acelerador ( $\alpha_{th}$ ). La emisión de NOx se adquirió mediante el analizador de gases modelo FGA4000XDS® que tiene una precisión de 0.1%. Mientras que los parámetros de entrada de la RNA como la presión absoluta del múltiple de admisión, IMAP (kPa), flujo de combustible inyectado  $m_{fuel}$  (kg/s) y el ángulo de ignición  $\theta_{ign}$  (°) se adquieren mediante el software del dinamómetro

hidráulico Super Flow SF-902®. Adicionalmente se adquirió el tiempo de apertura de un inyector  $t_{inj}$  (ms) mediante un osciloscopio Tektronix®. En las Figs. 1 y 2 se muestran el MCI y la posición de los sensores en el banco de pruebas respectivamente.



Fig. 1. Motor de combustión interna a gasolina acoplado al dinamómetro SuperFlow SF-902.

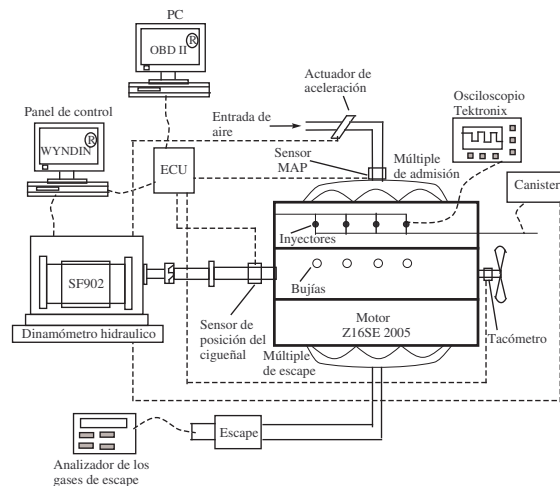


Fig. 2. Esquema del banco de pruebas para el MCI y posición de los sensores.

Cabe mencionar que las mediciones se realizan con el motor funcionando en estado estacionario. Una vez que se establece la posición deseada del pedal del acelerador y se mantiene constante, la velocidad del MCI es entonces controlada mediante el sistema de control del dinamómetro hidráulico. El principal objetivo de realizar estas pruebas es la adquisición de los parámetros del motor en un amplio rango de velocidades y ángulos de la válvula de mariposa. Por lo tanto, la diversificación de los datos se puede lograr para el entrenamiento y la prueba de las RNA. En las Figs. 3 y 4 se muestran los conjuntos de datos para cada parámetro de funcionamiento del MCI, tanto las entradas como la salida de las RNA respectivamente. Los datos para el entrenamiento de las RNA consisten en 40 conjuntos. Mientras que los restantes 20 conjuntos de datos se utilizan para la prueba de las RNA.

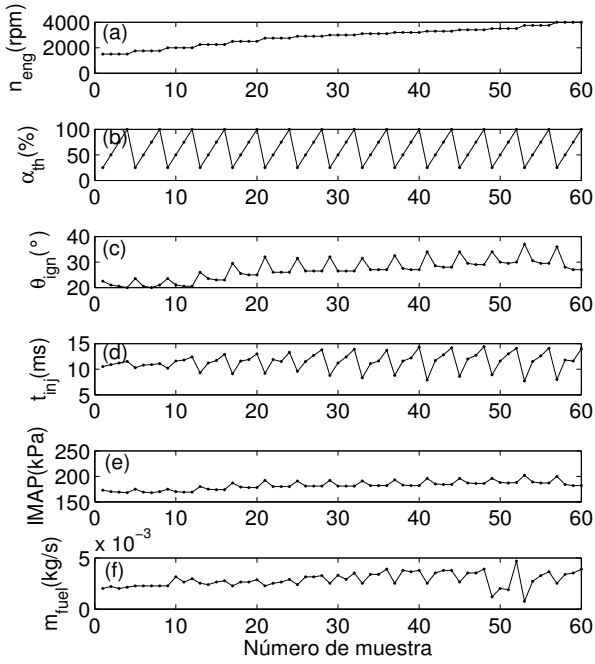


Fig. 3. Datos de entrada para el entrenamiento y prueba de las RNA. (a) velocidad del motor, (b) ángulo del pedal del acelerador, (c) ángulo de ignición, (d) tiempo de inyección, (e) presión absoluta del múltiple de admisión, (f) flujo de combustible inyectado.

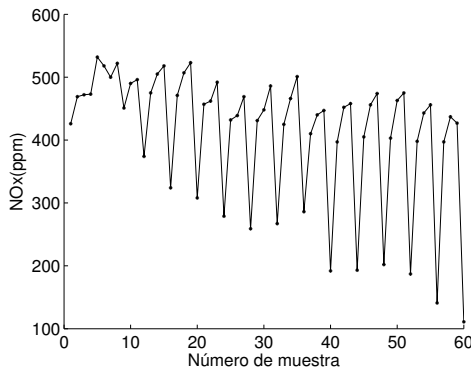


Fig. 4. Datos de salida de las RNA, emisión contaminante de NOx.

## 2. MODELO DE NO<sub>x</sub> DEL MOTOR DE COMBUSTIÓN INTERNA

La función de aproximación generada por la red neuronal fue usada para transformar el comportamiento no lineal de las entradas del MCI,  $x \in R^{N \times p}$  en las salidas  $y_{pred} \in R^{N \times q}$ , donde  $p$  y  $q$  denotan el número de variables de entrada y salida, y  $N$  define el número de muestras para cada variable. Las señales de entrada son  $n_{eng}$ ,  $m_{fuel}$ ,  $t_{inj}$ ,  $\alpha_{th}$ , IMAP y  $\theta_{ign}$ , mientras que la salida de la red es la emisión de NO<sub>x</sub>.

### 2.1 Red neuronal de funciones de base radial (RBF)

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  $\sigma$  son los anchos de las mismas. En la Fig. 5 se muestra la estructura de la red neuronal empleada para modelar el MCI. La salida de la RNA con  $Q$  neuronas en la capa oculta está dada por

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

donde  $w_i$  denota el  $i$ -ésimo peso de entrenamiento.

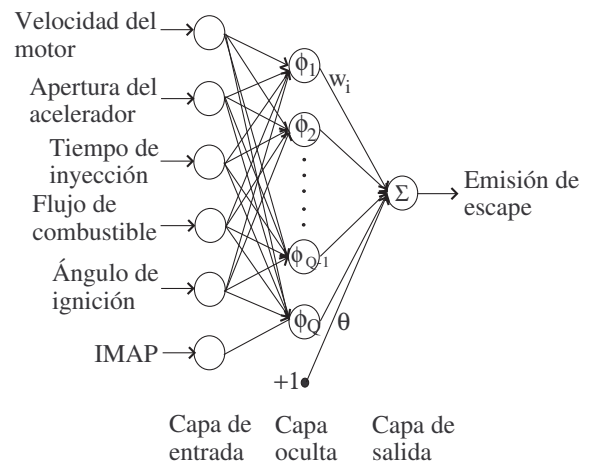


Fig. 5. Estructura del modelo RBF para la emisión de NOx.

### 2.2 Red neuronal de modelos locales lineales (LOLIMOT)

Con el empleo del algoritmo LOLIMOT (Local Linear Model Tree) se desarrolló un modelo de las emisiones del MCI. La red LOLIMOT se basa en la suma de productos de los modelos locales lineales (LLM, local linear model) ponderados y funciones de activación de base radial normalizadas  $\phi_i$ , cuya salida es (Hafner et al. 2000)

$$y_{pred} = \sum_{i=1}^M y_{LLM_i}(x) \phi_i(x), \quad (3)$$

donde  $x = [x_1 \dots x_p]^T$ , cada neurona constituye un modelo local lineal y una función de validez asociada determina la región de validez del LLM. Las salidas de cada LLM son

$$y_{LLM_i}(x) = \sum_{j=1}^p w_{ij} x_j + w_{i0}, \quad (4)$$

donde  $w_{ij}$  denotan los parámetros de cada LLM para la  $i$ -ésima neurona. Las funciones de validez corresponden a funciones Gaussianas normalizadas

$$\phi_i(x) = \frac{\mu_i(x)}{\sum_{j=1}^M \mu_j(x)}, \quad (5)$$

donde

$$\mu_j(x) = \prod_{i=1}^p \exp \frac{-(x_i - c_{ij})^2}{2\sigma_{ij}^2}, \quad (6)$$

ya  $M$  es el número de modelos locales lineales. Los centros  $c_{ij}$  y las desviaciones estándar  $\sigma_{ij}$  definen las funciones Gaussianas. Estos parámetros son optimizados por el llamado algoritmo LOLIMOT. En la Fig. 6 se muestra la estructura de la RNA LOLIMOT empleada.

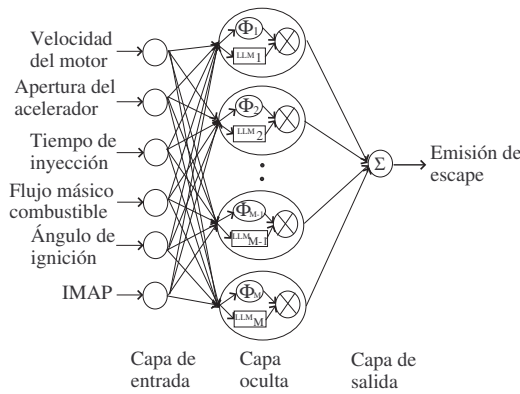


Fig. 6. Estructura de la red LOLIMOT para la emisión de NOx.

LOLIMOT es un algoritmo de construcción incremental que particiona el espacio de entrada mediante divisiones ortogonales de los ejes. En cada iteración una nueva regla o LLM es adherida al modelo en una partición, la cual es derivada del LLM con peor error local. El error local es la suma de los errores al cuadrado, ponderados con su correspondiente función de validez  $\phi_i$  sobre todas las  $N$  muestras, por lo que el algoritmo LOLIMOT implementa una búsqueda heurística de la estructura de la red. Los parámetros lineales  $w_{ij}$  en (4) de cada  $LLM_i$  con  $i=1,2,\dots,M$ , son adaptados mediante estimación basada en el método recursivo de mínimos cuadrados ponderado (RWLS, recursive weighted least-squares), con un factor de aprendizaje  $\lambda$ . Para la  $i$ -ésima LLM se calcula un nuevo estimado del parámetro  $w_{ij}(k)$  en la  $k$ -ésima iteración como (Nelles et al. 2001)

$$w_i(k+1) = w_i(k) + \gamma_i(k+1)e_i(k+1) \quad (7)$$

$$e_i(k+1) = y(k+1) - \tilde{x}^T(k+1)w_i(k) \quad (8)$$

$$\gamma_i(k+1) = \frac{1}{\frac{\lambda}{\phi_i(x)} + \tilde{x}^T(k+1)P_i(k)\tilde{x}(k+1)} P_i(k)\tilde{x}(k+1) \quad (9)$$

$$P_i(k+1) = \frac{1}{\lambda} (I - \gamma_i(k+1)\tilde{x}^T(k+1))P_i(k), \quad (10)$$

donde  $P_i(k+1)$  es una matriz de covarianza,  $e_i(k+1)$  es el error entre la salida predicha y real,  $\phi_i(x)$  pondera los datos de entrada con el valor de la función de validez y  $\tilde{x} = [x_1, \dots, x_p, 1]^T$ , es el nuevo vector de entrada que contiene un 1 en la posición final con el propósito de ajustar los umbrales  $w_{i0}$ .

### 3. DESEMPEÑO DE LOS MODELOS BASADOS EN RNA

Una comparación de la predicción de la emisión de NOx se lleva a cabo usando redes RBF y LOLIMOT. El número de neuronas en la capa oculta para RBF y LOLIMOT se determina mediante el porcentaje de error medio absoluto (MAPE, mean absolute percentage error) descrito por

$$MAPE = \frac{1}{n} \left[ \sum_{i=1}^n \left| \frac{y_{med_i} - y_{pred_i}}{y_{med_i}} \right| \right] \times 100 \quad (11)$$

donde  $n = 40$  es el número de conjuntos de datos de entrenamiento,  $y_{med}$  y  $y_{pred}$  son los datos medidos y predichos por la RNA respectivamente. En la Fig. 7 se muestra el comportamiento MAPE de la red RBF para diferente número de neuronas en la capa oculta para predecir la emisión de NOx. El MAPE es más pequeño con una estructura (6, 6, 1) para la red RBF. Mientras que el MAPE es más pequeño para la arquitectura (6, 14, 1) de la red LOLIMOT como se muestra en la Fig. 8.

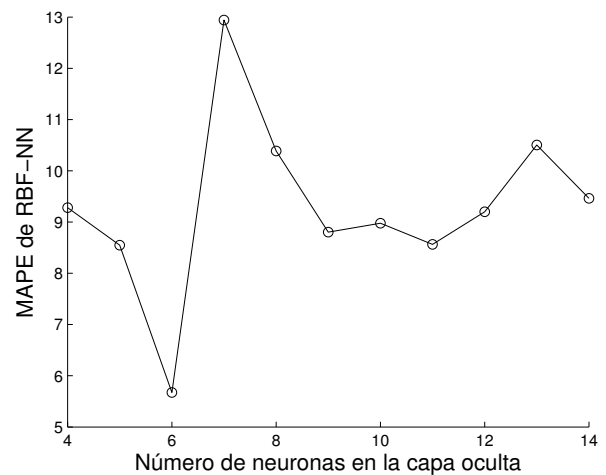


Fig. 7. MAPE de la red RBF para diferente número de neuronas en la capa oculta en la predicción de NOx.




Fig. 8. MAPE de la red LOLIMOT para diferente número de neuronas en la capa oculta para la predicción de NOx.

Para la validación de los modelos, se eligen los conjuntos de datos que no se utilizaron para entrenar a las redes. Entonces el coeficiente de correlación  $R^2$  descrito por

$$R^2 = 1 - \left( \frac{\sum_{i=1}^T (y_{med_i} - y_{pred_i})^2}{\sum_{i=1}^T (y_{med_i})^2} \right), \quad (12)$$

se calcula para evaluar el desempeño de las redes, donde  $T = 20$  es el número de conjuntos de datos de prueba. La correlación entre las emisiones medidas y predichas por las redes RBF y LOLIMOT se muestran en las Figs. 9 y 10 respectivamente. Como es visible en estas figuras los valores predichos por cada modelo están muy cerca a los datos experimentales. La Fig. 9 muestra la correlación entre el NOx medido y predicho por la red RBF. Para este caso  $R^2 = 0.97979$ . La Fig. 10 muestra una mejora significativa para la predicción de NOx mediante la red LOLIMOT con un coeficiente de correlación  $R^2 = 0.99452$ .




Fig. 9. Correlación entre la emisión de NOx predicha por la red RBF y medida del MCI.

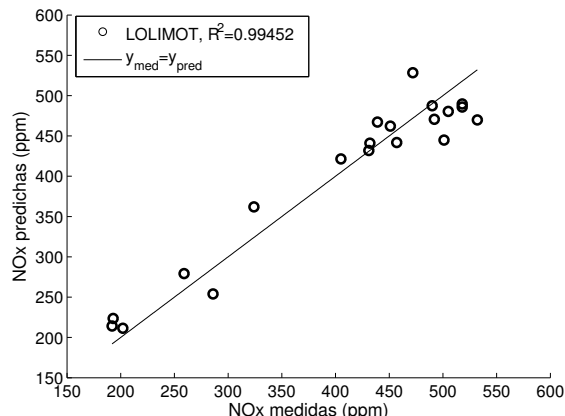


Fig. 10. Correlación entre la emisión de NOx predicha por la red LOLIMOT y medida del MCI.

#### 4. CONCLUSIONES

En este trabajo, se tiene como contribución el desarrollo de redes neuronales artificiales RBF y LOLIMOT para modelar la emisión contaminante de NOx de un motor de combustión interna, en términos de seis parámetros de funcionamiento. Se han comparado las redes RBF y LOLIMOT en función del porcentaje de error medio absoluto y el coeficiente de correlación  $R^2$ . Los mejores valores encontrados de  $R^2$  son 0.97979 correspondiente a la red RBF con arquitectura (6, 6, 1), y  $R^2 = 0.99452$  mediante la red LOLIMOT con estructura (6, 14, 1) para predecir las emisiones de escape de NOx. Resultando la red LOLIMOT con una mejor predicción sobre la red RBF.

#### REFERENCIAS

- Cay, Y., Korkmaz, I., Cicek, A., and Kara, F. (2013). Prediction of engine performance and exhaust emissions for gasoline and methanol using artificial neural network. *Energy*, 50(1), 177-186.
- Deng, Y., Yuan, Z., and Wei, L. (2013). Calibration techniques for modern commercial vehicle. *Proceedings of the FISITA 2012 World Automotive Congress Lecture Notes in Electrical Engineering*, 194, 167-176.
- Ghazikhani, M., and Mirzaii, I. (2011). Soot emission prediction of a waste gated turbo charged DI diesel engine using artificial neural network, *Neural Computing and Applications*, 20, 303-308.
- Guerrier, M., and Cawsey, P. (2004). The development of model based methodologies for gasoline IC engine calibration. *SAE Technical Paper Series*, 2004, 2004-01-1466.
- Hafner, M., Schuler, M., Nelles, O., and Isermann, R. (2000). Fast Neural Networks for Diesel Engine Control Design. *Control Engineering Practice*, 8(11), 1211-1221.
- Kim, H., and Sung, N. (2001). Multidimensional engine modeling: NO and soot emissions in a diesel engine with exhaust gas recirculation. *Journal of Mechanical Science and Technology*, 15(8), 1196-1204.

- Mehrnoosh, D., Asghar, H., and Asghar, M. (2012). Thermodynamic-model for prediction of performance and emission characteristics of SI engine fuelled by gasoline and natural gas with experimental verification. *Journal of Mechanical Science and Technology*, 26(7), 2213-2225.
- Nelles, O. (2001). *Nonlinear system identification*. Springer Verlag Press, Berlin.
- Rakopoulos, C., Antonopoulos, K., Rakopoulos, D., and Hountalas, D. (2008). Multi-zone modeling of combustion and emissions formation in DI diesel engine operating on ethanol–diesel fuel blends. *Energy Conversion and Management*, 49(4), 625-643.
- Simpson, P. (1990). *Artificial neural systems: foundations, paradigms, applications and implementations*. Pergamon Press, New York.