

Modelo basado en redes neuronales para predecir las emisiones en un motor diésel que opera con mezclas de biodiésel de higuera

Model-based neural networks to predict emissions in a diesel engine operating with biodiesel blends of castor

Recibido: 12-07-2012. Aceptado: 22-11-2012

FABIO NARVÁEZ¹

FABIO EMIRO SIERRA VARGAS²

MANUEL ANTONIO MONTENEGRO MIER³

Resumen

En este documento se explican algunos métodos de identificación de sistemas no lineales mediante el uso de redes neuronales artificiales. También se plantea un modelo basado en redes neuronales *Feed Forward* supervisadas, desarrollado para identificar y predecir el comportamiento de las emisiones volumétricas de la combustión de un motor diésel estacionario en función de dos variables de entrada: la carga del motor y la mezcla de biodiésel de higuera. El entrenamiento de la red neuronal y la validación del modelo se realizaron mediante el programa NNModel.

Palabras clave: Identificación de sistemas, sistemas no lineales, redes neuronales supervisadas, motores de combustión, emisiones.

Abstract

Some identification methods of nonlinear systems using artificial neural networks are explained. Also, a model based on Neural Networks "Supervised Feed Forward" is presented, developed to identify and predict the behavior of volumetric emissions from combustion of a stationary diésel engine based on two input variables: the engine load and the mixture of castor biodiésel. The neural network training and model validation was performed by using the NNModel.

Keywords: System identification, nonlinear systems, supervised neural networks, combustion engines, emissions.

Introducción

La representación que caracteriza un sistema o proceso físico se realiza mediante un modelo matemático que puede obtenerse de dos maneras: en forma estrictamente teórica (modelado) y en forma experimental, basándose en datos reales de entrada y salida del sistema (identificación). La principal ventaja del modelado de procesos es que permite predecir el comportamiento dinámico y estático de los sistemas antes de construirlos y analizar el desempeño de uno

1 M. Sc(c) Ingeniería Mecánica. Instructor del SENA-CTT. Miembro del Grupo de Investigación en Mecanismos de Desarrollo Limpio y Gestión Energética (MDLYGE) de la Universidad Nacional de Colombia. favionarvaez@hotmail.com

2 Ph.D. Profesor asociado, Departamento de Ing. Mecánica y Mecatrónica, Universidad Nacional Sede Bogotá. Director Grupo de Investigación en MDLYGE de la Universidad Nacional. fesierav@unal.edu.co

3 M. Sc(c) Ingeniero. Instructor del SENA-CTT. Grupo de Investigación en Mecanismos de Desarrollo Limpio y Gestión Energética (MDLYGE) de la Universidad Nacional de Colombia. : montenegromano@gmail.com

ya existente a fin de estudiar su comportamiento. Además, sin exponer el proceso a daños se puede determinar qué podría ocurrirle mediante la simulación del modelo con una condición, entrada inusual o perturbación. Para obtener los modelos existen diferentes técnicas de identificación de sistemas, algunas de las cuales demandan medición completa del estado. Sin embargo, su aplicabilidad se ve limitada ya que esto no siempre es posible debido a la gran cantidad de no linealidades y perturbaciones presentes en los procesos. Muchos de los métodos clásicos no conducen a resultados aceptables, por lo tanto puede ser difícil encontrar modelos matemáticos representativos. Esto ha llevado a explorar otras técnicas con el fin de eliminar estos inconvenientes y en este sentido las redes neuronales artificiales se han constituido en una de las áreas de la inteligencia artificial que ha despertado mayor interés en los últimos años y en una herramienta general para abordar una amplia clase de problemas de identificación de sistemas dinámicos, como lo demuestran los trabajos realizados por Narendra y Parthasarathy (1990). En particular, este enfoque resulta muy ventajoso cuando se trata de identificar sistemas no lineales (como es el caso de todos los procesos industriales), campo en el cual la mayoría de los métodos clásicos no conducen a resultados aceptables. Las redes neuronales son capaces, en cambio, de resolver problemas cuya solución por otros métodos resulta extremadamente difícil o insatisfactoria. El presente estudio tiene como objeto la obtención de un modelo basado en redes neuronales que identifique y prediga el comportamiento de las emisiones volumétricas de la combustión de un motor diésel estacionario, variando el porcentaje de carga en el motor y el porcentaje de mezcla de biodiésel de higuierilla. En él también se analiza el error cometido durante la validación del modelo.

Identificación de sistemas no lineales mediante redes neuronales

Se puede definir la identificación de sistemas como la teoría y el arte de construir modelos matemáticos de sistemas dinámicos basados en las observaciones reales de las entradas o variables de control, las salidas o variables controladas y las perturbaciones (Alonso *et al.*, 2007) y

Garrido, 1999). En la Figura 1 se muestra un esquema del proceso de identificación de un sistema.

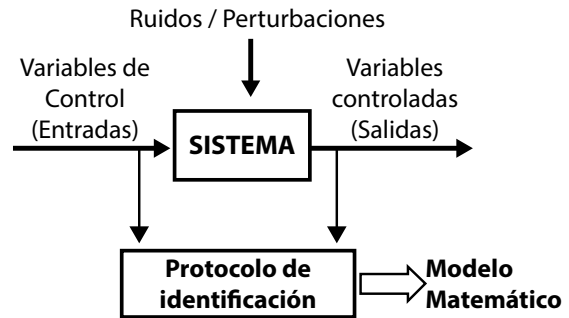


Figura 1. Identificación de un sistema (idea esquemática)

La identificación de sistemas no lineales es compleja ya que implica dos etapas: la selección de la estructura del modelo con un cierto número de parámetros y la selección de un algoritmo que estime dichos parámetros. Aunque muchos sistemas no lineales pueden ser linealizados al representarlos por medio de una ecuación diferencial o en diferencias, modelar sistemas no lineales con modelos lineales implica muchas aproximaciones que con frecuencia no reflejan suficientemente el comportamiento real del sistema no lineal. Por tanto, el obtener un buen modelo con una estructura que refleje la información real del sistema exige un incremento del costo debido a la necesidad de elaborar algoritmos más avanzados que puedan manejar modelos con estructuras complejas. Los modelos pueden ser paramétricos, los cuales tienen la ventaja de estar dados por un conjunto pequeño de coeficientes; o bien, no paramétricos, como las redes neuronales, cuya ventaja es la de no estar restringidos a un cierto número (posiblemente pequeño) de descripciones posibles del modelo. Ljung, 1999 y Wahlberg, 2002, presentan información sobre la identificación de los sistemas.

Identificación serie-paralelo e identificación paralela

Los dos esquemas tradicionales para identificar sistemas dinámicos usando redes neuronales son los llamados serie-paralelo y paralelo (Figura 2). Garrido, 1999.

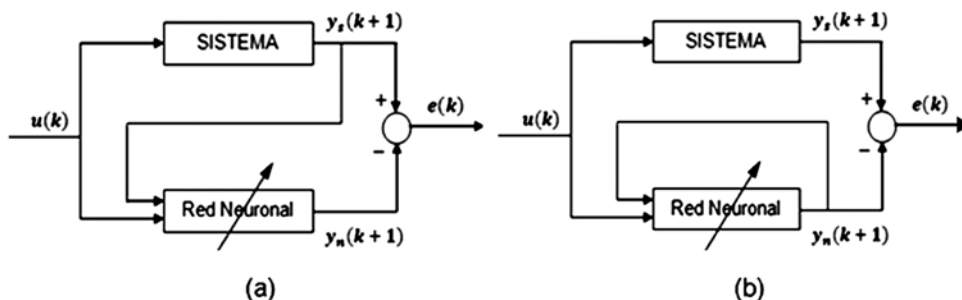


Figura 2. Esquemas para identificación de sistemas dinámicos usando redes neuronales. (a) Identificación serie-paralelo. (b) Identificación paralela.

El esquema de identificación serie-paralelo utiliza las entradas y salidas de la planta y deja que internamente la red deduzca el error existente. Este esquema –también llamado *teacherforcing*– puede ser usado con cualquier algoritmo de aprendizaje. La idea es que durante la fase de entrenamiento, para calcular los nuevos estados de la red neuronal se utilicen en el lazo de realimentación las salidas actuales de la planta, en lugar de las salidas de la red; su implementación puede ser muy sencilla con cualquier algoritmo. El esquema serie-paralelo es útil al inicio del aprendizaje para que los valores de la red no se alejen mucho y converjan más rápido. En el esquema de identificación paralela, la red no tiene información directa acerca de las salidas de la planta; sólo las entradas y el error entre las salidas de la planta y la red.

Redes neuronales con paralelización del tiempo

La representación del tiempo y su influencia en el comportamiento de los sistemas es uno de los problemas más difíciles en las aplicaciones de modelado y control. Una forma de representar eventos temporales es su representación directa como una dimensión explícita en un vector del espacio de entrada. El primer elemento representa el primer evento temporal, el segundo representa el segundo y así sucesivamente.

La representación del tiempo en las redes neuronales utilizadas en aplicaciones de sistemas dinámicos se puede clasificar en dos grupos de métodos distintos. El primer grupo tiende a diseñar su propia arquitectura de red dinámica en aplicaciones específicas; los retardos pueden ser introducidos en la capa de entrada o en las capas internas. La Tabla 1 muestra algunos ejemplos y aplicaciones de este tipo de arquitecturas (Garrido, 1999).

Tabla 1. Ejemplos de RNA con arquitectura propia de red dinámica

Redes neuronales	Aplicaciones
Time Delay Neural Networks (TDNN)	Toma de decisiones y optimización Reconocimiento de caracteres escritos a mano
Redes neuronales recurrentes	Completar secuencias Reconocimiento de caracteres Reconocimiento de voz
Memory Neuron Networks	Reconocimiento de caracteres

El segundo grupo lo forman las modificaciones a las estructuras y a los algoritmos de aprendizaje estático y en ellos se incluye de manera explícita el nuevo parámetro “tiempo” y así poder representar la dinámica del sistema. Una de las más conocidas es la red recurrente (Figura 3a). En ella se aprecia que la capa de entrada está dividida en

dos partes: el conjunto de entradas externas y una copia de la activación de la capa oculta en el instante anterior. La red es de propagación hacia adelante y al ajustar los pesos hay que tener en cuenta aquellos que van desde las entradas auxiliares a la capa oculta. Este tipo de red puede reconocer o reproducir secuencias de periodos cortos. Se ha utilizado para el reconocimiento de palabras generadas por una gramática formal.

Jordan propuso una arquitectura (ver Figura 3b) en la que la capa de entrada está dividida en dos partes: el conjunto de entradas externas y la realimentación de la activación de la capa de salida a través de conexiones de valor fijo. Este tipo de red es utilizada para el reconocimiento y clasificación de secuencias y su empleo en la generación de trayectorias de robots fue sugerido por Jordan. La Tabla 2 muestra dos ejemplos y aplicaciones de otras arquitecturas dentro de este grupo (Garrido, 1999)


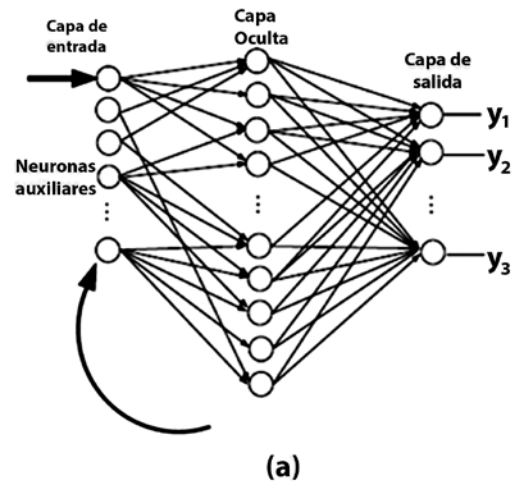


Figura 3. Redes realimentadas. (a) Red con realimentación de la capa oculta. (b) Red con realimentación de la capa de salida

Tabla 2. Ejemplos de RNA con modificaciones a las estructuras y a los algoritmos de aprendizaje estático.

Redes neuronales	Aplicaciones
Backpropagation in Dynamic Systems (BPD)	Identificación y control, control por modelo de referencia [Narendra [6] (1991)]. Propone la construcción de una segunda red llamada sensitivity model para el cálculo en línea de las derivadas de las salidas con respecto a los parámetros (matriz Jacobiana) y de las derivadas con respecto a las entradas. En el artículo se explica con detalle el esquema propuesto para generar el gradiente
Backpropagation through time (BTT)	Identificación, camión remolque [Narendra [8] (1991)]. El fundamento consiste en permitir a la red observar lo que ocurrirá con el sistema durante un tiempo T de pasos futuros, para que pueda adaptar sus pesos en consecuencia. Debido a la duplicación de unidades, los pesos y el coste computacional del entrenamiento, hacen que esta arquitectura no sea muy popular.

Caso práctico: modelo de red neuronal para predecir las emisiones en un motor estacionario que opera con mezclas de biodiésel de higuera

El modelo que se presenta en este artículo fue desarrollado para predecir las emisiones en un motor diésel estacionario, aplicado en una pequeña planta de potencia (12,8 kW) que opera con mezclas de biodiésel de higuera a una altura de 2.600 metros sobre el nivel del mar (Figura 4). Los detalles acerca de las características técnicas y el funcionamiento del motor-generator, así como la metodología experimental utilizada se describen en Narváez *et al.*

La Figura 5 muestra un esquema con las variables de entrada y salida que intervienen en el modelo. La carga del motor es una variable de control relacionada directamente con la demanda de energía eléctrica en el generador y la

mezcla de biodiésel es una variable de control relacionada directamente con la energía química del combustible que entra al motor. Los gases de la combustión en el motor (medidos en unidades volumétricas) y la opacidad del humo representan las variables de respuesta o variables de salida.

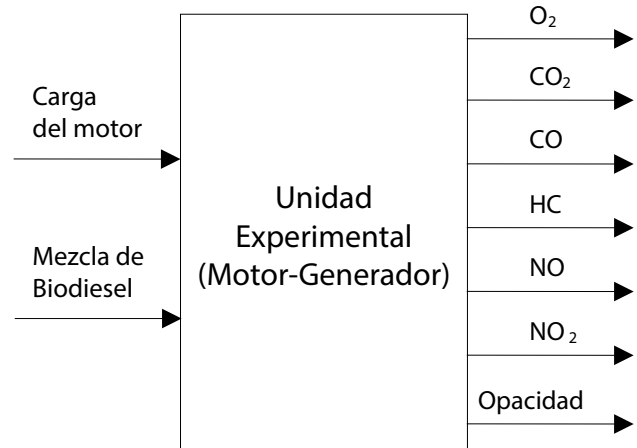


Figura 5. Variables de entrada y salida en la planta

Datos reales de entrada y salida

En la Tabla 3 se presenta la matriz de datos reales de las variables de entrada y salida indicadas en la Figura 5. Estos datos, obtenidos experimentalmente, fueron divididos en dos grupos, uno de los cuales fue utilizado para el entrenamiento de la red neuronal y se dejó un 10% para la validación del modelo.

Entrenamiento de la red neuronal y obtención de la matriz de pesos

El entrenamiento de la red neuronal fue realizado mediante el programa de modelamiento NNModel "versión



Figura 4. Planta de potencia que opera con mezclas de biodiésel de higuera.

Tabla 3. Matriz de datos reales de entrada y salida.

ENTRADAS		SALIDAS						
MBH* [%]	Carga motor [%]	O ₂ [% vol]	CO ₂ [% vol]	CO [ppm]	HC [ppm]	NO [ppm]	Opacidad [%]	NO ₂ [ppm]
0,0	0,0	17,7	1,6	413	19	11	10,7	7
0,0	11,8	15,8	2,4	603	8	75	11,6	12
0,0	26,7	14,8	2,9	500	4	126	14,7	18
0,0	39,2	13,7	3,4	400	8	246	16,2	19
0,0	56,9	11,9	4,2	300	6	396	17,8	16
0,0	70,2	10,5	4,9	300	9	526	27,3	16
0,0	87,1	8,5	5,8	784	10	648	51,0	17
0,0	100,0	6,3	6,6	2687	13	725	81,2	16
7,5	0,0	16,4	2,1	532	15	18	8,4	11
7,5	11,8	15,4	2,6	600	17	75	9,4	17
7,5	26,7	13,7	3,1	494	16	155	11,3	27
7,5	39,2	12,9	3,7	400	13	258	16,0	30
7,5	56,9	11,1	4,4	300	21	363	16,3	25
7,5	70,2	9,4	5,3	300	22	517	26,9	26
7,5	87,1	7,3	6,1	1010	23	599	48,9	26
7,5	100,0	6,2	7,1	2648	31	734	78,2	28
12,5	0,0	16,2	2,2	648	13	26	7,8	13
12,5	11,8	15,2	2,8	600	21	103	8,9	29
12,5	26,7	13,4	3,3	490	13	170	9,3	36
12,5	39,2	12,7	3,9	400	12	255	15,8	36
12,5	56,9	11,0	4,5	300	18	333	16,2	26
12,5	70,2	8,8	5,5	303	20	539	24,3	26
12,5	87,1	7,1	6,4	1587	21	642	43,8	27
12,5	100,0	5,6	7,3	2281	24	740	74,7	37
17,5	0,0	15,8	2,3	800	12	27	6,0	36
17,5	11,8	14,5	2,9	600	32	113	7,5	33
17,5	26,7	13,1	3,6	500	11	199	8,2	40
17,5	39,2	11,9	4,1	409	11	265	15,7	46
17,5	56,9	9,9	5,0	300	15	318	15,8	37
17,5	70,2	8,3	5,7	295	21	642	22,2	37
17,5	87,1	6,1	6,6	965	14	685	41,2	42
17,5	100,0	4,0	7,4	1842	18	747	72,7	57
22,5	0,0	15,7	2,4	800	11	42	3,6	39
22,5	11,8	14,3	3,0	610	37	113	5,6	42
22,5	26,7	13,0	3,7	491	13	206	6,5	46
22,5	39,2	11,8	4,2	400	12	278	14,9	49
22,5	56,9	9,6	5,2	300	11	326	15,1	46
22,5	70,2	8,3	5,8	294	18	694	21,7	49
22,5	87,1	6,1	6,9	800	11	715	39,6	54
22,5	100,0	3,9	7,6	1597	19	769	69,7	56

*MBH: Mezclas de biodiésel de higuera.

1.51". Una vez que el programa NNModel importa la matriz de datos reales establece algunos parámetros para cada una de las variables, los cuales son fundamentales y se requieren posteriormente para el desarrollo de las ecuaciones del modelo. Dos de estos parámetros son los términos "Scale" y "Offset", tal como se indica en la Figura 6 (ver detalle). Las columnas "Min" y "Max" que se indican en la Figura 6, contienen los valores mínimos y máximos de cada variable tomados de la matriz de datos reales de la Tabla 3 y dentro de los cuales se podrá realizar el modelamiento.

Label	Format	Units	Min	Max	Clip Lo	Clip Hi	Usage	Flag	Scale	Offset	FType
MEZCLA	4.1		0.0	22.5	MISSING	MISSING	N	0	0.026667	7.499992	0
CARGA	5.1		0.0	100.0	MISSING	MISSING	N	0	0.006000	33.333298	0
O2	4.1		3.9	17.7	MISSING	MISSING	N	0	0.043478	0.699995	0
CO2	3.1		1.6	7.6	MISSING	MISSING	N	0	0.100000	0.399998	0
CO	6.1		294.0	2687.0	MISSING	MISSING	N	0	0.000251	503.665833	0
HC	4.1		4.0	37.0	MISSING	MISSING	N	0	0.018182	6.999989	0
NO	5.1		11.0	769.0	MISSING	MISSING	N	0	0.000792	241.666397	0
OPACIDAD	4.1		3.6	81.2	MISSING	MISSING	N	0	0.007732	22.266640	0
NO2	4.1		7.0	57.0	MISSING	MISSING	N	0	0.012000	9.666649	0

Figura 6. Parámetros y características de las variables de entrada y salida, según NNModel

La interfaz que se muestra en la Figura 7 permite editar los parámetros de entrenamiento de la red neuronal. En este caso, se utilizó una red "Circular Back-Propagation" con máximo cuatro capas ocultas y con conexión de las entradas con las salidas. Se utilizó el criterio del mejor "R square" para finalizar el entrenamiento cuyo valor de 0,99 es el objetivo por alcanzar. La Figura 8 muestra la interfaz que permite seleccionar las variables de entrada y dar inicio al entrenamiento de la red neuronal.

Parameter	Value
Max Hid Neurons	4
Eon	100
Max Train Count	10000
Tolerance	5 e-002
Error Tolerance	1 e-003
Good RSQ	0.99
Signal Increase	5 e-002
No Signal Increase	5 e-003
Hidden Freeze	0.75
Best Eon	0
Best Fuzz	1 e-004
Learning Rate	0.75
HLearning Rate	1.5
TLearning Rate	0.75
IO Learning Rate	0.1
Alpha	0.8
Theta	0.5
Random Fact	0.5
InflRandon Fact	0
Seed	15
CG Max Iterations	1

Figura 7. Parámetros de entrenamiento de la red neuronal.

I/O	Variable	Col #	TimeS
1	MEZCLA	0	0
2	CARGA	1	0
3	O2	2	0
4	CO2	3	0
5	CO	4	0
6	HC	5	0
7	NO	6	0
8	OPACIDAD	7	0
9	NO2	8	0

Figura 8. Variables de entrada y salida, seleccionadas en NNModel.

La Figura 9 permite observar la dinámica del entrenamiento de la red neuronal. Esta gráfica muestra seis factores internos que indican qué tan bien se está llevando a cabo el entrenamiento de la red. Esta dinámica está afectada directamente por los parámetros indicados en la Figura 7.

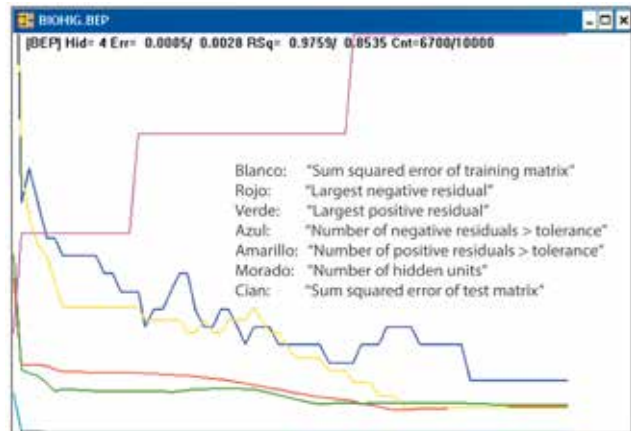


Figura 9. Dinámica del entrenamiento de la red neuronal.

Una vez que el programa NNModel finaliza la fase de entrenamiento, se obtiene la matriz de pesos de la red neuronal (ver Figura 10). Esta matriz permite describir, entre otras, las siguientes características: número de variables de entrada (2), número de variables de salida (7), número de capas ocultas que integran la red neuronal (4), número de puntos de la matriz de entrenamiento (16), número de puntos de la matriz de prueba (40), la matriz de pesos entre las neuronas de la capa de entrada y las neuronas de la capa oculta, la matriz de pesos entre las neuronas de la capa oculta y las neuronas de la capa de salida, la matriz de pesos entre las neuronas de la capa de entrada y las neuronas de la capa de salida, los valores de los factores de activación o "sesgos" en la capa oculta y los valores de los factores de activación o "sesgos" en la capa de salida. En

la siguiente la sección se describirá la utilización de dichas matrices y de los factores de activación en la formulación del modelo de la red neuronal.

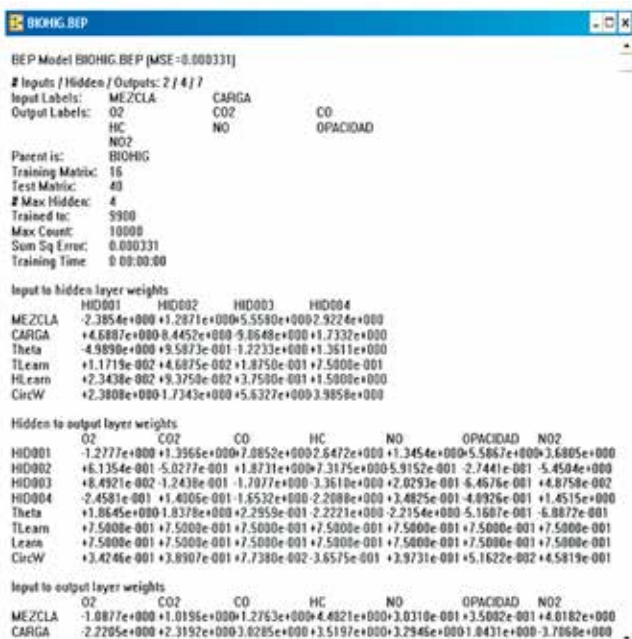


Figura 10. Matriz de pesos después del entrenamiento, obtenida con NNModel.

Descripción y formulación del modelo de la red neuronal

Los algoritmos y las ecuaciones del modelo de la red neuronal contenidos en el programa NNModel, permiten determinar directamente cada una de las variables de salida en función de las variables de entrada. La Figura 11 muestra un ejemplo particular en el cual se obtienen los valores de los gases de escape (salidas) cuando la mezcla de biodiésel y la carga del motor (entradas) son, respectivamente, 7,5% y 26,7%.

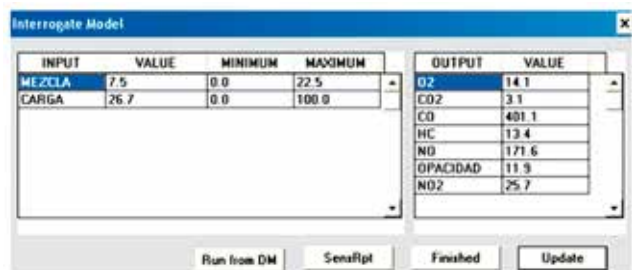


Figura 11. Ejemplo en el cual el programa NNModel obtiene las variables de salida a partir de los datos ingresados como variables de entrada.

Sin embargo, en esta sección se describirá la manera como el programa NNModel realiza los cálculos matemáticos en el modelo de red neuronal, para lo cual se utilizará

Excel como una herramienta adicional. Esto permitirá asimismo verificar paso a paso los resultados de dichos cálculos. Haciendo uso del programa NNModel se definen los parámetros de entrenamiento de la red neuronal y se acotan en el rango 0,2 a 0,8 para que la función de entrenamiento sigmoideal permita calcular en un rango lineal. Estos parámetros se muestran en la Tabla 4, en la cual; los valores de "Scale" y "Offset" son tomados de la Figura 6 y con ellos se escalan tanto los valores de entrada para llevarlos al rango 0,2 a 0,8 como los de salida para obtener los valores de salida, de acuerdo con las unidades medidas.

Tabla 4. Parámetros de entrenamiento de la red neuronal.

		MIN	MAX	Scale	Offset	
Entrada	MEZCLA	0	22,5	0,026667	7,499992	Entrada
Entrada	CARGA	0	100	0,006000	33,333298	Entrada
Salida	O2	3,9	17,7	0,043478	0,699995	Salida
Salida	CO2	1,6	7,6	0,100000	0,399998	Salida
Salida	CO	294	2687	0,000251	503,665833	Salida
Salida	HC	4	37	0,018182	6,999989	Salida
Salida	NO	11	769	0,000792	241,666397	Salida
Salida	OPACIDAD	3,6	81,2	0,007732	22,26664	Salida
Salida	NO2	7	57	0,012000	9,666649	Salida

Una vez definidos los parámetros de entrenamiento de la red, se toman los valores de la matriz de pesos obtenida por el programa NNModel (ver Figura 10) y se reorganizan en una hoja de Excel –tal como se muestra en la Tabla 5, con el fin de aplicar las ecuaciones de modelamiento, como lo veremos en detalle a continuación.

Tabla 5. Matriz de pesos de la red neuronal, obtenida con NNModel.

Matriz de pesos entre la capa de entrada y la capa oculta y factores de activación (Theta) de las neuronas de la capa oculta					
	HID001	HID002	HID003	HID004	
Mezcla	-2,38537	1,287055	5,558038	-2,922375	
Carga	4,688653	-8,445175	-9,064837	1,73324	
Theta-oculta	-4,98896	0,9587266	-1,223274	1,361104	
Matriz de pesos entre la capa oculta y la capa de salida y factores de activación de las neuronas de la capa de salida					
	HID001	HID002	HID003	HID004	Theta-salida
O2	-1,277737	0,6135359	0,08492115	-0,2458123	1,864474
CO2	1,396608	-0,5027739	-0,1243832	0,1400572	-1,837775
CO	7,08519	1,873109	-1,707729	-1,653155	0,2295919
HC	-2,647214	7,317491	-3,360955	-2,208791	-2,222082
NO	1,345418	-0,5915211	0,2029302	0,3482465	-2,21545
OPACIDAD	5,58673	-0,2744063	-0,646758	-0,4092601	-0,5160713
NO2	3,6805	-5,450365	0,0487579	1,451487	-0,6887184
Matriz de pesos entre la capa de entrada y la capa de salida					
	MEZCLA	CARGA			
O2	-1,087673	-2,220542			
CO2	1,019555	2,31922			
CO	1,276289	-3,028475			
HC	4,402113	3,519687			
NO	0,3031012	3,294559			
OPACIDAD	0,3500216	-1,043114			
NO2	4,01822	-3,706005			

En primer lugar, definimos A y B como los vectores de escala de las variables de entrada y salida respectivamente. Así mismo, definimos B y C como los vectores de "Offset" de las variables de entrada y salida respectivamente. De acuerdo con la Tabla 4, los valores de los vectores A, B, C y D quedan establecidos de la siguiente manera:

$$\begin{aligned} A^T &= [a_1 \ a_2] = [(0,026667 \ 0,006000)] \\ B^T &= [b_1 \ b_2 \ b_3 \ b_4 \ b_5 \ b_6 \ b_7] \\ &= [0,043478 \ 0,100000 \ 0,000251 \ 0,018182 \ 0,000792 \\ &\quad 0,007732 \ 0,012000] \\ C^T &= [c_1 \ c_2] = [7,499992 \ 33,333298] \\ D^T &= [d_1 \ d_2 \ d_3 \ d_4 \ d_5 \ d_6 \ d_7] \\ &= [0,699995 \ 0,39999850 \ 3,665833 \ 6,999989 \\ &\quad 241,666397 \ 22,26664 \ 9,666649] \end{aligned}$$

donde A^T , B^T , C^T , y D^T son los respectivos vectores transpuestos de A, B, C y D.

Definimos P como la matriz de pesos entre las neuronas de la capa de entrada y las neuronas de la capa oculta; U como la matriz de pesos entre las neuronas de la capa oculta y las neuronas de la capa de salida; y W como la matriz de pesos entre las neuronas de la capa de entrada y las neuronas de la capa de salida. Según la Tabla 5, los valores de las matrices P, U y W quedan establecidos de la siguiente manera:

$$\begin{aligned} P &= \begin{bmatrix} p_{11} & p_{12} & p_{13} & p_{14} \\ p_{21} & p_{22} & p_{23} & p_{24} \end{bmatrix} \\ &= \begin{bmatrix} -2,38537 & 1,287055 & 5,558038 & -2,922375 \\ 4,688653 & -8,445175 & -9,064837 & 1,73324 \end{bmatrix} \\ U &= \begin{bmatrix} u_{11} & u_{12} & u_{13} & u_{14} & u_{15} & u_{16} & u_{17} \\ u_{21} & u_{22} & u_{23} & u_{24} & u_{25} & u_{26} & u_{27} \\ u_{31} & u_{32} & u_{33} & u_{34} & u_{35} & u_{36} & u_{37} \\ u_{41} & u_{42} & u_{43} & u_{44} & u_{45} & u_{46} & u_{47} \end{bmatrix} \\ &= \begin{bmatrix} -1,2777370 & 1,39660800 & 7,0851900 & -2,647214 & 1,345418 & 5,5867300 & 3,6805000 \\ 0,61353590 & -0,5027739 & 1,8731090 & 7,3174910 & -0,5915211 & -0,2744063 & -5,450365 \\ 0,08492115 & -0,1243832 & -1,707729 & -3,360955 & 0,2029302 & 0,646758 & 0,0487579 \\ -0,2458123 & 0,1400572 & -1,653155 & -2,208791 & 0,3482465 & -0,4092601 & 1,4514870 \end{bmatrix} \\ W &= \begin{bmatrix} w_{11} & w_{12} & w_{13} & w_{14} & w_{15} & w_{16} & w_{17} \\ w_{21} & w_{22} & w_{23} & w_{24} & w_{25} & w_{26} & w_{27} \end{bmatrix} \\ &= \begin{bmatrix} -1,087673 & 1,019555 & 1,276289 & 4,402113 & 0,3031012 & 0,3500216 & 4,01822 \\ -2,220542 & 2,31922 & -3,028475 & 3,519687 & 3,294559 & -1,043114 & -3,706005 \end{bmatrix} \end{aligned}$$

Definimos Θ como el vector de activación (sesgo) de las neuronas de la capa oculta, y Φ como el vector de activación (sesgo) de las neuronas de la capa de salida. Según la Tabla 5, los valores de los vectores Θ y Φ quedan establecidos de la siguiente manera:

$$\begin{aligned} \Theta &= [\theta_1 \ \theta_2 \ \theta_3 \ \theta_4] \\ &= [-4,98896 \ 0,95887266 \ -1,223274] \\ \Phi &= [\phi_1 \ \phi_2 \ \phi_3 \ \phi_4 \ \phi_5 \ \phi_6 \ \phi_7] \\ &= \begin{bmatrix} 1,8644474 & -1,837775 & 0,2295919 & -2,222082 \\ -2,21545 & 0,5160713 & 0,6887184 & \end{bmatrix} \end{aligned}$$

Sea X el vector que determina las dos variables de entrada: carga del motor y mezcla de biodiésel de higuierilla; y sea Y el vector que representa las siete variables de salida: O_2 , CO_2 , CO , HC , NO , Opacidad y NO_2 . Así, los vectores X y Y estarán definidos de la siguiente manera:

$$\begin{aligned} X^T &= [x_1 \ x_2] \\ Y^T &= [y_1 \ y_2 \ y_3 \ y_4 \ y_5 \ y_6 \ y_7] \end{aligned}$$

El objetivo es encontrar un modelo matemático que permita obtener el vector y en términos del vector X .

Definimos R como el vector rango

$$R^T = [r_1 \ r_2]$$

donde los valores del término están entre 0,2 y 0,8. El término r_k (para $k = 1, 2$) está dado por la siguiente expresión:

$$r_k = (x_k + c_k) * a_k \quad (3.1)$$

En donde los parámetros a_k y c_k están definidos en los vectores A y C respectivamente.

Sea el vector M definido de la siguiente manera:

$$M^T = [m_1 \ m_2 \ m_3 \ m_4]$$

En donde el elemento m_j (para $j = 1, 2, 3, 4$) está dado por la siguiente expresión:

$$m_j = (-1) [\sum(p_{jk} * r_k) + \theta_j] \quad (3.2)$$

en la cual, el parámetro p_{jk} (para $j = 1, 2, 3, 4; k = 1, 2$) está definido en el vector P. El término r_k está dado por la ecuación 3.1, y el parámetro θ_j (para $j = 1, 2, 3, 4$) está expresado según el vector Θ . En forma vectorial, se puede expresar el vector M como sigue:

$$M = [P^T * R + \Theta^T] \quad (3.3)$$

Sea el vector N definido de la siguiente manera:

$$N^T = [n_1 \ n_2 \ n_3 \ n_4]$$

En donde el elemento n_j (para $j = 1, 2, 3, 4$) está dado por la siguiente expresión:

$$n_j = \frac{1}{1 + e^{m_j}} \quad (3.4)$$

en la cual, el término m_j (para $j = 1, 2, 3, 4$) está definido por la ecuación 3.2.

Definimos ahora el vector V dado por la siguiente expresión:

$$V^T = [v_1 \ v_2 \ v_3 \ v_4 \ v_5 \ v_6 \ v_7]$$

En donde el elemento V_i (para $i = 1, 2, 3, 4, 5, 6, 7$) está dado por la siguiente expresión:

$$v_i = \sum(u_{ij} * n_j) + \phi_i \tag{3.5}$$

en la cual, el parámetro u_{ij} (para $i = 1, 2, 3, 4, 5, 6, 7; j = 1, 2, 3, 4$) está definido en el vector U . El término n_j está dado por la ecuación 8.4, y el parámetro Θ (para $i = 1, 2, 3, 4, 5, 6, 7$) está expresado según el vector ϕ . En forma vectorial, podemos expresar el vector V de la siguiente manera:

$$V = U^T * N + \Phi^T \tag{3.6}$$

Definimos ahora el vector S como sigue:

$$S^T = [s_1 \ s_2 \ s_3 \ s_4 \ s_5 \ s_6 \ s_7]$$

En donde el elemento S_i (para $i = 1, 2, 3, 4, 5, 6, 7$) está dado por la siguiente expresión:

$$s_i = \sum(w_{ik} * r_k) \tag{3.7}$$

en la cual, el parámetro w_{ik} (para $i = 1, 2, 3, 4, 5, 6, 7; k = 1, 2$) está definido en el vector W , y el término r_k está dado por la ecuación 3.1. En forma vectorial, podemos expresar el vector S como sigue:

$$S = W^T * R \tag{3.8}$$

Definimos ahora el vector Z como sigue:

$$Z^T = [z_1 \ z_2 \ z_3 \ z_4 \ z_5 \ z_6 \ z_7]$$

en donde el elemento Z_i (para $i = 1, 2, 3, 4, 5, 6, 7$) está dado por la siguiente expresión:

$$z_i = (-1) (v_i + s_i) \tag{3.9}$$

en la cual, los términos V_i y S_i (para $i = 1, 2, 3, 4, 5, 6, 7$) están definidos respectivamente por las ecuaciones 8.5 y 8.7. En forma vectorial, Z se puede expresar como sigue:

$$Z = (-1) (V + S) \tag{3.10}$$

Definimos ahora el vector Q como sigue:

$$Q^T = [q_1 \ q_2 \ q_3 \ q_4 \ q_5 \ q_6 \ q_7]$$

en donde el elemento q_i (para $i = 1, 2, 3, 4, 5, 6, 7$) está dado por la siguiente expresión:

$$q_i = \frac{1}{1 + e^{z_i}} \tag{3.11}$$

en la cual, el término Z_i (para $i = 1, 2, 3, 4, 5, 6, 7$) está definido por la ecuación 3.9.

De esta manera, el vector Y que corresponde a las variables de salida, quedará expresado como sigue:

$$Y^T = [y_1 \ y_2 \ y_3 \ y_4 \ y_5 \ y_6 \ y_7]$$

en donde el elemento y_i (para $i = 1, 2, 3, 4, 5, 6, 7$) está dado por la siguiente expresión:

$$y_i = \frac{q_i}{b_i} - d_i \tag{3.12}$$

en la cual, el término q_i está dado por la ecuación 3.11; los parámetros b_i y d_i (para $i = 1, 2, 3, 4, 5, 6, 7$) están definidos respectivamente en los vectores B y D .

De esta manera, combinando las ecuaciones 3.1 a 3.12, es posible encontrar los valores de cada una de las siete variables de salida (representadas por y_i) en función de las dos variables de entrada (representadas por x_k). La Figura 12 muestra un esquema de la secuencia de los cálculos desarrollados por el modelo de la red neuronal (las salidas se muestran en color verde y las entradas en amarillo). Con el fin de verificar las ecuaciones y comparar los resultados, los cálculos fueron realizados en Excel con los mismos valores de las variables de entrada usados en el ejemplo de la Figura 11 (mezcla de biodiésel 7,5% y carga del motor 26,7%). La estructura de la red neuronal se muestra en la Figura 13.

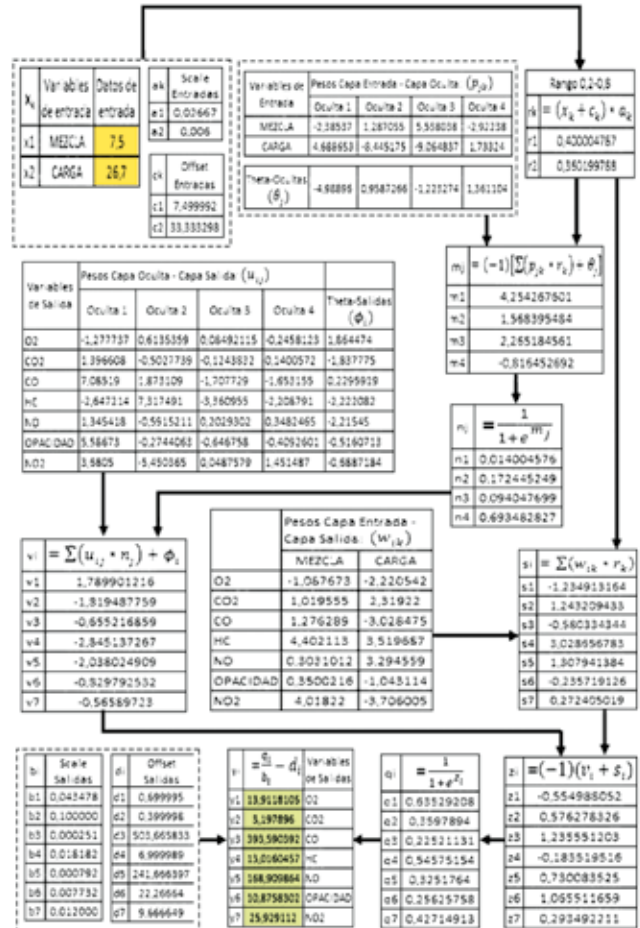


Figura 12. Esquema de los cálculos del modelo de la RNA, desarrollados con Excel, para un ejemplo particular.

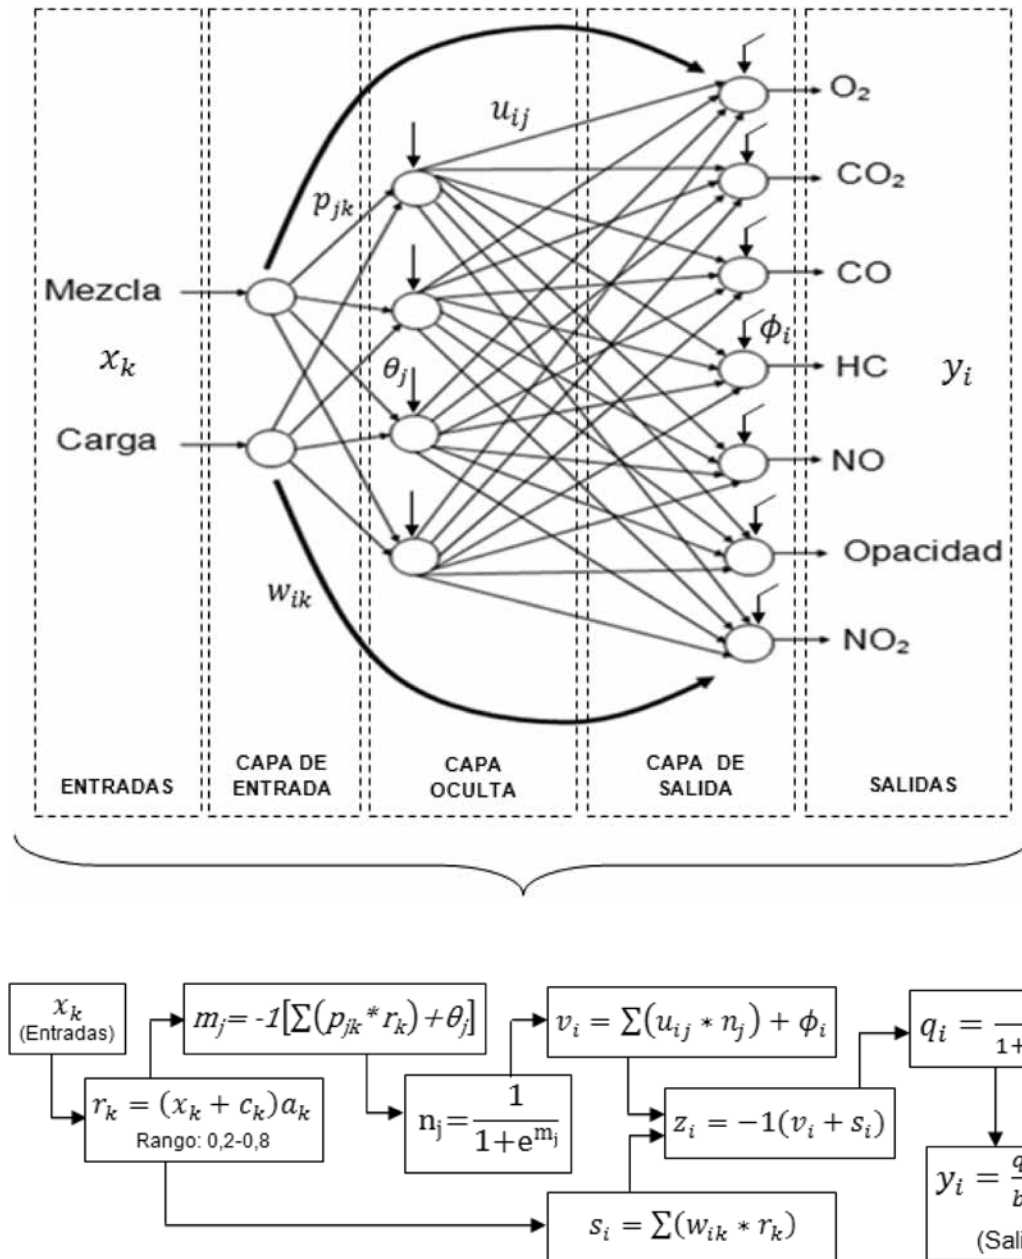


Figura 13. Estructura de la red neuronal.

Como se puede observar en la Figura 12, los resultados de las variables de salida obtenidos con las ecuaciones de Excel son muy similares a los resultados obtenidos directamente con el programa NNModel. La mayor desviación se obtuvo para el caso de la opacidad, para la cual el error cometido con las ecuaciones de Excel es de 8,65%. Sin embargo, el error promedio apenas alcanza el 2,9%, lo cual se considera aceptable.

Validación del modelo de la red neuronal

La validación del modelo se puede realizar ya sea utilizando las ecuaciones desarrolladas en Excel o bien mediante una de las herramientas incorporadas en el programa NNModel (ver Figura 11). Se escogió esta última opción como método más directo y para ello se utilizarán los datos experimentales obtenidos para las mezclas de biodiésel de 5%, 10% y 15% (BH5, BH10 y BH15 respectivamente), los cuales se muestran en la Tabla 6.

Tabla 6. Datos reales de entrada y salida, usados para validar el modelo de RNA.

Variables de entrada		Variables de salida (experimentales)						
MBH* [%]	Carga motor [%]	O ₂ [% vol]	CO ₂ [% vol]	CO [ppm]	HC [ppm]	NO [ppm]	Opacidad [%]	NO ₂ [ppm]
5,0	0,0	17,1	1,9	680	18	12	9,3	10
5,0	11,8	15,6	2,5	602	15	75	10,4	16
5,0	26,7	14,1	3,0	450	13	155	12,8	21
5,0	39,2	13,3	3,5	403	15	247	16,1	25
5,0	56,9	11,3	4,3	350	18	385	19,9	23
5,0	70,2	10,2	5,1	560	21	510	28,1	22
5,0	87,1	7,8	5,9	1180	24	580	49,6	22
5,0	100,0	6,2	7,0	2451	25	732	79,1	26
10,0	0,0	16,3	2,2	627	17	20	8,1	13
10,0	11,8	15,3	2,8	600	16	92	9,0	20
10,0	26,7	13,6	3,2	402	14	162	10,5	28
10,0	39,2	12,7	3,8	400	13	256	13,0	32
10,0	56,9	11,0	4,4	406	20	350	18,3	30
10,0	70,2	9,2	5,3	600	21	529	25,1	24
10,0	87,1	7,2	6,3	1320	24	615	45,9	25
10,0	100,0	5,8	7,1	2435	26	738	75,1	28
15,0	0,0	16,1	2,3	800	20	26	7,6	21
15,0	11,8	14,9	2,9	450	15	105	7,8	26
15,0	26,7	13,2	3,5	320	11	183	8,7	33
15,0	39,2	12,3	4,0	260	13	261	10,7	37
15,0	56,9	10,5	4,9	300	17	394	16,1	32
15,0	70,2	8,7	5,6	503	20	524	23,6	31
15,0	87,1	6,9	6,4	1241	18	676	43,0	38
15,0	100,0	5,0	7,4	1952	19	743	73,1	44

*MBH: Mezclas de biodiésel de higuera.

En la Tabla 7 se muestran los resultados de las variables de salida obtenidos con el modelo de RNA mediante el programa NNModel (ver herramienta de NNModel

indicada en la Figura 11), usando las mismas variables de entrada de la Tabla 6.

Tabla 7. Variables de salida, obtenidas con el modelo de RNA de NNModel.

Variables de entrada		Variables de salida (obtenidas con NNModel)						
MBH* [%]	Carga motor [%]	O ₂ [% vol]	CO ₂ [% vol]	CO [ppm]	HC [ppm]	NO [ppm]	Opacidad [%]	NO ₂ [ppm]
5,0	0,0	16,9	2	744,5	20,4	11,3	9,2	9,1
5,0	11,8	15,7	2,4	545,2	15,1	77	10,8	17,1
5,0	26,7	14,3	3,1	389,7	12,4	168,5	12,6	23,1
5,0	39,2	13,1	3,6	341,1	13	250,4	14,7	24
5,0	56,9	11,4	4,4	416,7	16,5	375,9	20,5	21,9
5,0	70,2	9,9	5,1	655,9	19,5	480,1	29,8	20,3
5,0	87,1	7,8	6,1	1396,7	21,9	623,5	52	21
5,0	100,0	6	6,9	2270	22,2	730,9	74,1	24,4
10,0	0,0	16,6	2,1	699,8	19,6	18,8	7,4	13,5
10,0	11,8	15,4	2,6	494,7	14,1	86	8,7	22,3
10,0	26,7	13,9	3,2	368,2	12,5	177,2	10,7	28,6
10,0	39,2	12,7	3,8	349	14,6	257,8	13,1	29,4
10,0	56,9	10,9	4,6	452,9	19,9	381	19	27,3
10,0	70,2	9,5	5,3	694,1	23,7	483,8	27,9	25,8
10,0	87,1	7,4	6,3	1394,8	26,2	626,6	49,2	26,9
10,0	100,0	5,6	7	2222,8	26,1	734,5	71,3	31
15,0	0,0	16,1	2,3	779,5	22,2	25,1	7,3	20,5
15,0	11,8	15	2,8	492,4	14,3	95,9	7,7	29,8
15,0	26,7	13,5	3,4	298	10,5	191,9	8,7	35,9
15,0	39,2	12,2	4	241,6	11,1	276,1	10,3	36,7
15,0	56,9	10,5	4,8	301,2	15	403,2	15,6	34,9
15,0	70,2	9	5,5	498,5	18,2	507,8	24,1	34
15,0	87,1	6,9	6,4	1126,1	20,1	650,3	45,1	36,1
15,0	100,0	5,2	7,2	1951,6	19,4	755,4	67,8	40,8

*MBH: Mezclas de biodiésel de higuera.

Con base en los datos de las Tablas 6 y 7 se determinaron los errores relativos cometidos por el modelo de RNA con respecto a los valores medidos experimentalmente, cuyos resultados se muestran en la Tabla 8. En esta Tabla observamos que los mayores errores cometidos por el modelo de RNA se presentan en la determinación del monóxido de carbono (CO) y los hidrocarburos no quemados (HC), cuyos errores promedio (en valor absoluto) son respectivamente 9,9% y 8,7%. Es de esperarse este resultado debido a que los datos experimentales utilizados para el entrenamiento y obtención del modelo (ver Tabla 7) tienen mayor dispersión precisamente en estos dos gases. Por otra parte, se aprecia que los menores errores se generan en la

predicción del oxígeno (O₂) y el dióxido de carbono (CO₂) ya que son los que presentan menor dispersión en la Tabla 7. Los errores promedio (en valor absoluto) de estos dos gases son respectivamente 1,6% y 2,2%. De todas maneras, el error promedio total cometido por el modelo de RNA, según la Tabla 8, alcanza apenas un valor de 5,5%, lo cual es bastante satisfactorio.

El programa NNModel efectúa también la validación del modelo de RNA utilizando parte de los datos experimentales de la Tabla 3-1, previamente reservados para tal efecto. Los resultados de esta validación se muestran en las Figuras 14 a 20.

Tabla 8. Errores relativos del modelo de RNA desarrollado con NNModel.

Variables de entrada		Errores relativos del modelo de RNA						
MBH* [%]	Carga motor [%]	O ₂ [%]	CO ₂ [%]	CO [%]	HC [%]	NO [%]	Opacidad [%]	NO ₂ [%]
5,0	0,0	-1,2	5,3	9,5	13,3	-5,8	-1,1	-9
5,0	11,8	0,6	-4	-9,4	0,7	2,7	3,8	6,9
5,0	26,7	1,4	3,3	-13,4	-4,6	8,7	-1,6	10
5,0	39,2	-1,5	2,9	-15,4	-13,3	1,4	-8,7	-4
5,0	56,9	0,9	2,3	19,1	-8,3	-2,4	3	-4,8
5,0	70,2	-2,9	0	17,1	-7,1	-5,9	6	-7,7
5,0	87,1	0	3,4	18,4	-8,8	7,5	4,8	-4,5
5,0	100,0	-3,2	-1,4	-7,4	-11,2	-0,2	-6,3	-6,2
10,0	0,0	1,8	-4,5	11,6	15,3	-6	-8,6	3,8
10,0	11,8	0,7	-7,1	-17,6	-11,9	-6,5	-3,3	11,5
10,0	26,7	2,2	0	-8,4	-10,7	9,4	1,9	2,1
10,0	39,2	0	0	-12,8	12,3	0,7	0,8	-8,1
10,0	56,9	-0,9	4,5	11,6	-0,5	8,9	3,8	-9
10,0	70,2	3,3	0	15,7	12,9	-8,5	11,2	7,5
10,0	87,1	2,8	0	5,7	9,2	1,9	7,2	7,6
10,0	100,0	-3,4	-1,4	-8,7	0,4	-0,5	-5,1	10,7
15,0	0,0	0	0	-2,6	11	-3,5	-3,9	-2,4
15,0	11,8	0,7	-3,4	9,4	-4,7	-8,7	-1,3	14,6
15,0	26,7	2,3	-2,9	-6,9	-4,5	4,9	0	8,8
15,0	39,2	-0,8	0	-7,1	-14,6	5,8	-3,7	-0,8
15,0	56,9	0	-2	0,4	-11,8	2,3	-3,1	9,1
15,0	70,2	3,4	-1,8	-0,9	-9	-3,1	2,1	9,7
15,0	87,1	0	0	-9,3	11,7	-3,8	4,9	-5
15,0	100,0	4	-2,7	0	2,1	1,7	-7,3	-7,3

*MBH: Mezclas de Biodiésel de Higuera.




Figura 14. Validación del modelo de RNA para la variable O₂

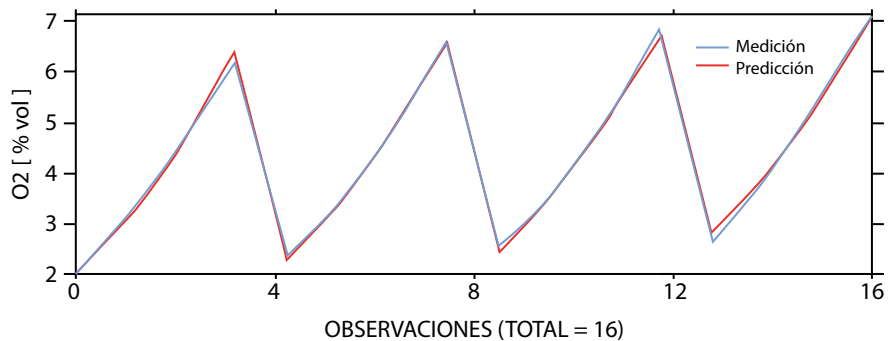


Figura 15. Validación del modelo de RNA para la variable CO₂




Figura 16. Validación del modelo de RNA para la variable CO




Figura 17. Validación del modelo de RNA para la variable HC




Figura 18. Validación del modelo de RNA para la variable NO




Figura 19. Validación del modelo de RNA para la variable Opacidad.




Figura 20. Validación del modelo de RNA para la variable NO₂

Se comprueba nuevamente que los mayores errores del modelo de RNA se presentan en la determinación del CO, el HC y el NO₂ (ver Figuras 16, 17 y 20), mientras que la determinación del O₂, del CO₂, del NO y de la opacidad (ver Figuras 14, 15, 18 y 19) se realiza con mayor precisión.

Reporte estadístico y análisis de sensibilidad, con NNModel

Como resultado del entrenamiento de la red neuronal, el programa NNModel realiza un reporte estadístico del comportamiento de las variables de entrada y salida (ver Tabla 9) y un análisis de sensibilidad (ver Tabla 10) a fin de determinar el nivel de afectación de las dos variables de entrada (mezcla y carga) con respecto a cada variable de salida.

Tabla 9. Reporte estadístico del modelo efectuado por NNModel.

Variable		Mean	Std. Dev.	Minimum	Maximum	Sum Sq
MEZCLA		12,000000	7,909747	0,000000	22,500000	2440,0000
CARGA		48,987498	33,859871	0,000000	100,00000	44713,143
O ₂	Measured	11,197500	3,796320	3,900000	17,700001	562,06978
	Predicted	11,185821	3,744190	4,189020	17,170383	546,73928
	R Square	0,991828	-	-	-	-
CO ₂	Measured	4,462500	1,717734	1,600000	7,600000	115,07375
	Predicted	4,472755	1,695487	1,817951	7,587382	112,11230
	R Square	0,995353	-	-	-	-
CO	Measured	747,07498	633,97178	294,00000	2687,0000	15674888
	Predicted	777,63750	594,82105	206,55584	2271,3261	13798671
	R Square	0,868596	-	-	-	-
HC	Measured	16,075000	6,977574	4,000000	37,000000	1898,7750
	Predicted	16,394490	5,596627	5,859750	29,702175	1221,5671
	R Square	0,278451	-	-	-	-
NO	Measured	360,47500	258,77444	10,999985	769,00000	2611604,2
	Predicted	360,47081	250,78326	6,606598	791,12695	2452797,6
	R Square	0,972125	-	-	-	-
OP*	Measured	25,317499	22,518389	3,600000	81,199997	19776,036
	Predicted	25,808479	21,886048	7,058479	77,356255	18680,964
	R Square	0,978468	-	-	-	-
NO ₂	Measured	31,250000	13,346948	7,000000	57,000000	6947,5001
	Predicted	31,122245	13,050994	5,739366	56,718826	6642,8092
	R Square	0,930292	-	-	-	-

*OP: Opacidad de los gases de la combustión

Tabla 10. Análisis de sensibilidad del modelo reportado por NNModel.

Variables de afectación (entradas)	Sensibilidad absoluta promedio de las variables de salida						
	O ₂	CO ₂	CO	HC	NO	OP*	NO ₂
Carga	0,80559	0,82159	0,84955	0,45832	0,91371	0,89199	0,37657
Mezcla	0,19441	0,17841	0,15045	0,54168	0,08629	0,10801	0,62343

*OP: Opacidad de los gases de la combustión

Predicción de las emisiones del motor (modelamiento)

Como resultado de la validación del modelo podemos ahora usarlo para predecir el comportamiento de cada una de las emisiones volumétricas de la combustión del motor y la opacidad del humo (variables de salida) ante cambios en las variables de entrada de carga del motor y mezclas de biodiésel. La Tabla 11 muestra un ejemplo de predicción de las emisiones volumétricas de la combustión del motor usando el modelo de RNA. Aunque se mantuvieron los mismos valores de carga del motor, la predicción en dicho ejemplo se hizo para una mezcla de biodiésel diferente

de las utilizadas tanto en el entrenamiento como en la validación del modelo; en este caso se hizo la predicción para una mezcla de biodiésel del 20% (BH20).

El programa NNModel permite obtener gráficas tridimensionales como resultado del modelamiento en las cuales se observa el comportamiento general de las variables de salida. Las Figuras 21 y 22 muestran dos ejemplos de este tipo de gráficas aplicadas respectivamente a los hidrocarburos (HC) y al dióxido de carbono (CO₂) que salen a través del escape del motor. Nuevamente, vemos que el comportamiento del CO₂ tiende a ser bastante lineal mientras que los HC se comportan de manera no lineal.

Tabla 11. Ejemplo de predicción de las variables de salida usando el modelo de RNA.

Variables de entrada		Variables de salida (predicción)						
MBH* [%]	Carga motor [%]	O ₂ [%]	CO ₂ [%]	CO [%]	HC [%]	NO [%]	Opacidad [%]	NO ₂ [%]
20,0	0,0	15,5	2,5	949,8	27,4	32,8	8,8	31,9
20,0	11,8	14,3	3	614,6	18,9	105,5	8,8	40,5
20,0	26,7	12,8	3,7	363,2	13,6	204,9	9,1	45,4
20,0	39,2	11,6	4,2	266,1	12,9	293	10,3	45,9
20,0	56,9	9,8	5,1	278,5	14,4	426,6	15,1	44,7
20,0	70,2	8,3	5,7	447,3	15,7	535,2	23,6	44,4
20,0	87,1	6,2	6,7	1051	15,9	678,8	45,3	47,2
20,0	100,0	4,6	7,4	1878	14,5	780,1	68,4	51,7

*MBH: Mezclas de biodiésel de higuera.




Figura 21. Predicción de HC en función de la carga del motor y la mezcla de biodiésel.

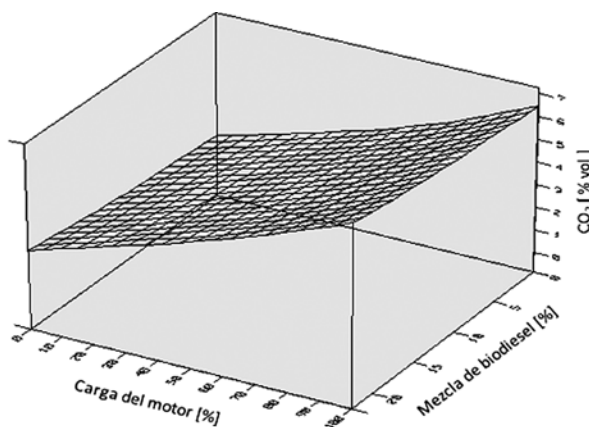


Figura 22. Predicción de CO₂ en función de la carga del motor y la mezcla de biodiésel.

Conclusiones

- Las redes neuronales son una herramienta útil para identificar sistemas no lineales, como es el caso de un motor térmico.
- Determinar el comportamiento de las emisiones en un motor de combustión interna cuando se utiliza un nuevo combustible, como es el uso de aceite de higuera, no se puede hacer mediante el modelamiento matemático tradicional sin caer en imprecisiones. En general, se deben hacer pruebas de laboratorio para hacer las mediciones y estas son válidas solo para las concentraciones o mezclas en que se haga dicha prueba. Con el uso de entrenamiento de redes supervisadas Multilayer Perceptron se ha demostrado con esta investigación que estas son adecuadas para determinar los valores de emisiones de gases en el motor de combustión para mezclas no medidas experimentalmente con un error pequeño. La correlación para la identificación de los diferentes gases varió entre 86% y 99%.
- El modelamiento con redes neuronales permite predecir en forma satisfactoria las emisiones de O₂, CO₂, CO, HC, NO, NO₂ y la opacidad a partir de los valores de mezcla y carga aplicada al motor.
- El software NNModel (versión 1.51) demostró ser una herramienta muy importante en el campo del modelamiento basado en redes neuronales artificiales. Sin embargo, está limitada a predecir o modelar únicamente dentro del rango de los valores mínimos y máximos de las variables de entrada; es decir, permite únicamente interpolar mas no extrapolar.

Agradecimientos

Este proyecto fue parcialmente financiado con recursos de la Dirección de Investigación, Sede Bogotá, de la Universidad Nacional de Colombia dentro del programa *Apoyo a estudiantes de posgrado*.

Referencias

- ACOSTA J., BECERRA L. y FERNÁNDEZ J. Aplicación de las redes neuronales para la identificación de un sistema no lineal. Un caso práctico. 2000
- ALONSO A., SEDANO J. y VILLAR J. Representación de un sistema no lineal usando identificación de sistemas y redes neuronales. 2005
- ALONSO A., SEDANO J. y VILLAR J. Identificación de sistemas no lineales mediante redes neuronales artificiales. *Técnica Industrial*, 2007, 267; p.46-53
- GARRIDO, S. Identificación, estimación y control de sistemas no-lineales mediante RGO. Tesis para optar al título de Doctor. Departamento de Ingeniería de Sistemas y Automática, Universidad Carlos III, Madrid, España. 1999
- HERNÁNDEZ, L. Predicción y optimización de emisores y consumo mediante redes neuronales en motores diésel. Barcelona, España: Editorial Reverté. 2006
- LEVIN A. U. and NARENDRA K. S. Control of nonlinear dynamical systems using neural networks: controllability and stabilization. *IEEE Transactions on Neural Networks*, 1993. 2(4), 192-206.
- LJUNG, L. *System Identification - Theory for the User*, 2nd Edition, Prentice-Hall, Upper Saddle River, N J, 1999 ISBN 0-13-656695-2, 607 pages. Chinese edition 2002.
- NARENDRA K. S. and PARTHASARATHY K. Identification and control of dynamical systems using neural networks. *IEEE Transactionson Neural Networks*, 1990. 1(1), 4-27.
- NARVÁEZ F., SIERRA F. y MONTENEGRO M. Diseño experimental para evaluar el consumo de combustible y las emisiones en motores estacionarios que trabajan con biodiésel de higuera o de pollo. 2012
- NEURAL FUSION. "NNModel 32User's Manual Versión 1.51"
- VAN DEN HOF P., WAHLBERG B, WEILAND, S. *System Identification* Elsevier, 2003