



Universidad
Zaragoza

Trabajo Fin de Grado

Modelo de redes neuronales para la predicción de parámetros de funcionamiento y de emisiones de motores de combustión interna alternativos (MCIA) alimentados con combustibles alternativos

Autor/es

Javier Pintado de Blas

Director/es

Eva M^a Llera Sastresa

Escuela de Ingeniería y Arquitectura
2016



DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD

(Este documento debe acompañar al Trabajo Fin de Grado (TFG)/Trabajo Fin de Máster (TFM) cuando sea depositado para su evaluación).

TRABAJOS DE FIN DE GRADO / FIN DE MÁSTER

D./D^a. Javier Pintado de Blas,

con nº de DNI 72798201G en aplicación de lo dispuesto en el art.

14 (Derechos de autor) del Acuerdo de 11 de septiembre de 2014, del Consejo

de Gobierno, por el que se aprueba el Reglamento de los TFG y TFM de la

Universidad de Zaragoza,

Declaro que el presente Trabajo de Fin de (Grado/Máster)
Grado de Ingeniería Mecánica, (Título del Trabajo)

Modelo de redes neuronales para la predicción de parámetros de
funcionamiento y de emisiones de motores de combustión interna alternativos
(MCIA) alimentados con combustibles alternativos

es de mi autoría y es original, no habiéndose utilizado fuente sin ser citada
debidamente.

Zaragoza, 21 de septiembre de 2016

Fdo: Javier Pintado de Blas

Resumen

En las últimas décadas las elevadas emisiones de gases contaminantes producidas por el sector del transporte en general y el transporte por carretera en particular, han incentivado la investigación y el desarrollo de combustibles alternativos a los convencionales derivados del petróleo.

En la situación actual, es interesante el desarrollo de una herramienta que sea capaz de identificar de manera correcta y sencilla los combustibles alternativos que mejor se comporten, en cuanto a emisiones, a las diferentes situaciones operativas propias de los motores de combustión.

En este contexto, el presente trabajo mostrará el potencial de las redes neuronales artificiales (RNA) como herramienta de predicción de las emisiones producidas por un motor alternativo de combustión interna que utiliza diferentes mezclas y combustibles alternativos, en diferentes condiciones de operación.

A lo largo de este trabajo se irán desarrollando los conceptos necesarios para la correcta comprensión de los procesos de entrenamiento y optimización de las RNA, así como los posibles problemas a evitar en fases posteriores. Seguidamente se describirá de forma detallada todas las características que rodea el entrenamiento de estas RNA y sus posteriores optimizaciones. El análisis de estas mejoras y su influencia en los resultados de los sucesivos entrenamientos irán moldeando las características finales de las RNA.

Finalmente, se obtendrán los modelos de RNA que permitirán evaluar de forma eficaz las diferentes mezclas y combustibles alternativos presentes en el estudio, caracterizados por los parámetros fundamentales de los motores de combustión interna alternativos.

Índice

1.	INTRODUCCIÓN	1
1.1.	ESCENARIO ACTUAL.....	1
1.2.	MOTIVACIÓN DEL PROYECTO.....	1
1.3.	ALCANCE Y OBJETIVOS DEL MISMO.....	1
1.4.	ESTRUCTURA DE LA MEMORIA	2
2.	COMBUSTIBLES ALTERNATIVOS	3
2.1.	INTRODUCCIÓN	3
2.2.	DEFINICIÓN.....	3
2.3.	ELECTRICIDAD	3
2.4.	HIDRÓGENO.....	4
2.5.	BIOCARBURANTES	4
2.6.	COMBUSTIBLES SINTÉTICOS	5
2.7.	GAS NATURAL	5
2.8.	LEGISLACIÓN VIGENTE.....	6
2.9.	CONCLUSIONES	6
3.	DATOS.....	7
3.1	INTRODUCCIÓN	7
3.2	PARAMETROS Y EMISIONES	8
4.	REDES NEURONALES ARTIFICIALES (RNA).....	10
4.1.	DEFINICIÓN.....	10
4.2.	CARACTERÍSTICAS PRINCIPALES.....	10
4.3.	ELEMENTOS BASICOS	11
4.4.	ALGORITMO BACKPROPAGATION (LEVENBERG-MARQUARDT)..	13
4.5.	GENERALIZACIÓN DE RNA.....	15
4.6.	FASES DEL ENTRENAMIENTO	15
4.7.	INICIALIZACIÓN DE LOS PESOS	16
4.8.	ACTUALIZACION DE LOS PESOS	16
5.	DESARROLLO DE LAS RNA PARA LA PREDICCIÓN DE EMISIONES	17
5.1	MEDICIÓN DE LA CALIDAD DE LAS RNA	17
5.2	TRATAMIENTO PREVIO DE LOS PATRONES DE ENTRENAMIENTO	18
5.3	ESTRATEGIA DE ENTRENAMIENTO	19
5.4	RNA BASE.....	21
5.5	PREDICIONES DE LAS RNA BASE	24

5.6	CONCLUSIONES DE LA RNA BASE.....	29
5.7	OPTIMIZACIÓN 1: PARAMETROS DE ENTRENAMIENTO	29
5.8	OPTIMIZACIÓN 2: VARIACION DE LA ARQUITECTURA.	34
5.9	OPTIMIZACIÓN 3: VARIACION DEL PREPROCESADO DE PATRONES. 39	
5.10	OPTIMIZACIÓN 4: VARIACIÓN DE LOS PARÁMETROS DE ENTRADA.....	44
5.11	TABLA-RESUMEN DE LAS RNA FINALES	50
6.	CONCLUSIÓN.....	51
7.	ANEXO A: SCRIPT DE LAS RNA EN MATLAB.....	53
7.1.	PREPROCESADO RNA NO _x	53
7.2.	PREPROCESADO RNA CO	54
7.3.	PREPROCESADO RNA HC	55
7.4.	PREPROCESADO RNA CO ₂	56
7.5.	EJEMPLO DE POSTPROCESADO DE LAS RNA (SIMILAR EN TODAS)..	57
8.	ANEXO B: Fase 1 + Fase 2 de los entrenamientos	58
8.1.	RNA BASE NO _x	58
8.2.	RNA BASE CO	59
8.3.	RNA BASE HC	60
8.4.	RNA BASE CO ₂	61
8.5.	OPTIMIZACIÓN 1 NO _x	62
8.6.	OPTIMIZACIÓN 1 CO	63
8.7.	OPTIMIZACIÓN 1 HC	64
8.8.	OPTIMIZACIÓN 1 CO ₂	65
8.9.	OPTIMIZACIÓN 2 NO _x	66
8.10.	OPTIMIZACIÓN 2 CO	67
8.11.	OPTIMIZACIÓN 2 HC	68
8.12.	OPTIMIZACIÓN 2 CO ₂	69
8.13.	OPTIMIZACIÓN 3 NO _x	70
8.14.	OPTIMIZACIÓN 3 CO	71
8.15.	OPTIMIZACIÓN 3 HC	72
8.16.	OPTIMIZACIÓN 3 CO ₂	73
8.17.	OPTIMIZACIÓN 4 NO _x	74
8.18.	OPTIMIZACIÓN 4 CO	75
8.19.	OPTIMIZACIÓN 4 HC	76

8.20. OPTIMIZACIÓN 4 CO ₂	77
9. REFERENCIAS	78

Lista de Acrónimos

RNA: Red neuronal artificial

MACI: Motor alternativo de combustión interna

MEC: Motor de Encendido por Compresión

MEP: Motor de Encendido Provocado

PCI: Poder Calorífico Inferior

PCS: Poder Calorífico Superior

NO_x: Óxidos de Nitrógeno

CO₂: Dióxido de Carbono

SO_x: Óxidos de azufre

PM: Materia particulada

HC: Hidrocarburos, combustible inquemado

CO₂: Dióxido de carbono

GEI: Gases de efecto invernadero

GNC: Gas natural comprimido

GNL: Gas natural licuado.

GLP: Gas licuado del petróleo

FFV: Vehículos de combustión flexible

R: Coeficiente de correlación.

A5%: Porcentaje de puntos predichos que tienen una dispersión menor del 5%

A10%: Porcentaje de puntos predichos que tienen una dispersión menor del 10%

Q: Factor de calidad de las redes neuronales artificiales

G1: Subdivisión de los parámetros de entrenamiento 1

G2: Subdivisión de los parámetros de entrenamiento 2

G3: Subdivisión de los parámetros de entrenamiento 3

G4: Subdivisión de los parámetros de entrenamiento 4

E1: Conjunto para el entrenamiento 1

E2: Conjunto de entrenamiento 2

E3: Conjunto de entrenamiento 3

E4: Conjunto de entrenamiento 3

P1: Conjunto para la predicción correspondiente a E1

P2: Conjunto para la predicción correspondiente a E2

P3: Conjunto para la predicción correspondiente a E3

P4: Conjunto para la predicción correspondiente a E4

MSE: Función del error cuadrático medio

MSE_{val_min}: Error del entrenamiento correspondiente al error de validación mínimo

H₂: Hidrogeno

n: Regimen de giro

η_{ef} : Rendimiento efectivo

r_c : Relación de compresión

Ne: Potencia efectiva.

pme: Presión media efectiva

Cm: Velocidad media del pistón

F: Dosado

λ : Lambda

Mf: Flujo másico de combustible

Ma: Flujo másico de aire

η_{vol} : Rendimiento volumétrico

V_T: cilindrada

z: Numero de cilindros

S/D: Relación carrera diámetro

μ o **Mu: Parámetro de regulación**

μ_{in} o **Mu_{in}: Parámetro de regulación inicial.**

μ_{inc} o **Mu_{inc}: Tasa de incremento del parámetro de regulación**

μ_{dec} o **Mu_{dec}: Tasa de decrecimiento del parámetro de regulación**

1. INTRODUCCIÓN

El presente Trabajo Fin de Grado se centra en el desarrollo de una herramienta de predicción basada en redes neuronales artificiales con el objetivo de predecir las emisiones de diferentes combustibles alternativos para un amplio rango de parámetros operativos característicos de los motores de combustión interna alternativos (MACI).

1.1. ESCENARIO ACTUAL

Durante las últimas décadas la expansión económica de los países desarrollados ha implicado un importante aumento de las operaciones de transporte, lo que ha provocado un notable impacto medioambiental.

Según la Agencia Europea del Medio Ambiente, en 2012 el sector del transporte fue el culpable del 21% de las emisiones de gases de efecto invernadero (GEI) y alrededor del 94% de estas emisiones fueron producidas por el transporte por carretera. Además fue el principal causante de las emisiones de CO, NO_x, SO_x y materia particulada (PM) debido a que cerca del 93% de la energía utilizada provino de la gasolina o el diésel.

Por lo tanto, es necesario el uso de alternativas energéticas en el transporte, que replacen a los combustibles convencionales derivados del petróleo con el objetivo de reducir el impacto ambiental y alcanzar el objetivo marcado por el Libro Verde Sobre la Seguridad del Abastecimiento Energético de reemplazar el 20% de los combustibles convencionales para el año 2020.

En este contexto el desarrollo de los diferentes combustibles alternativos se muestra como la única opción para cumplir los objetivos de reducción de emisiones a corto, medio y largo plazo.

1.2. MOTIVACIÓN DEL PROYECTO

Este estudio se basa en la necesidad de disponer de una herramienta sencilla que permita identificar la mezcla combustible que presente el mejor comportamiento en cuanto a sus emisiones ante diferentes condiciones de operación de un motor de combustión interna alternativo.

1.3. ALCANCE Y OBJETIVOS DEL MISMO.

El objetivo de este TFG es evaluar y predecir el comportamiento medioambiental de combustibles alternativos (hidrógeno, biocarburantes, gas natural) y sus mezclas para su uso en el sector transporte a partir del análisis de datos procedentes de pruebas en banco de ensayos de motores.

Se utilizarán redes neuronales para relacionar las diferentes condiciones de operación con las prestaciones de un motor de combustión interna alternativo. Si bien existen experiencias previas en el uso de redes neuronales para la predicción y la optimización de emisiones y consumos energéticos en motores diésel, la principal dificultad estriba

en el tratamiento de los datos cuando se trata de combustibles alternativos. Dada la imposibilidad de realizar ensayos a medida se utilizarán datos de pruebas publicados en revistas científicas.

1.4. ESTRUCTURA DE LA MEMORIA

En primer lugar, se va a realizar una breve introducción combustibles alternativos y a sus características más importantes. También se expondrá la situación actual de la normativa europea sobre emisiones contaminantes.

Posteriormente se presentaran los datos (parámetros del motor y emisiones) obtenidos a partir de diferentes ensayos en motores, que han sido publicados por revistas especializadas y se identificarán las variables seleccionadas como entradas y su influencia en las emisiones elegidas como salidas.

A continuación, se explicará que es una red neuronal artificial (RNA), sus principales características y los elementos que las constituyen. Se describirán las cuestiones generales sobre RNA que pueden ser de interés para la comprensión del trabajo, tales como: las fases de su entrenamiento, los algoritmos utilizados en el mismo, los principales problemas a tener en cuenta, etc.

Una vez explicados los conceptos teóricos necesarios, se procederá a desarrollar el tratamiento previo practicado los datos y la estrategia de entrenamiento seguida para las RNA iniciales y las sucesivas optimizaciones, con el fin de obtener la mejor herramienta de predicción posible. La metodología seguida será la proporcionada por la bibliografía principal de este trabajo []. Para el desarrollo de los entrenamientos y optimizaciones se utilizará el programa MATLAB y su interfaz gráfica para redes neuronales artificiales. Finalmente se analizarán los resultados mostrados por las diferentes optimizaciones para cada RNA y se describirán las características finales de las redes neuronales optimizadas.

Por último, se expondrán las conclusiones generales del proceso de optimización tras analizar los resultados para cada RNA y la influencia de las diferentes optimizaciones en esos resultados.

2. COMBUSTIBLES ALTERNATIVOS

2.1.INTRODUCCIÓN

El transporte por carretera es un factor determinante para el desarrollo socio-económico y la cohesión de los diferentes territorios. Sin embargo, genera un alto consumo energético y altos niveles de emisiones de gases contaminantes, además de producir congestión en las redes viarias y causar una elevada siniestralidad.

Las ventajas del transporte por carretera han estimulado la investigación y el desarrollo de **combustibles alternativos** con el fin de reducir sustancialmente los efectos negativos que conlleva en cuanto a emisiones contaminantes.

2.2.DEFINICIÓN

La Unión Europea define en la DIRECTIVA 2014/94/UE¹ a los combustibles alternativos como:

“Los combustibles o fuentes de energía que sustituyen, al menos en parte, a los combustibles fósiles clásicos como fuente de energía en el transporte y que pueden contribuir a la descarbonización de estos últimos y a mejorar el comportamiento medioambiental del sector del transporte. Incluyen, entre otros:

- la electricidad,
- el hidrógeno,
- los biocarburantes, tal como se definen en el artículo 2, letra i), de la Directiva 2009/28/CE,
- los combustibles sintéticos y parafínicos,
- el gas natural, incluido el biometano, en forma gaseosa [gas natural comprimido (GNC)] y en forma licuada [gas natural licuado (GNL)], y
- el gas licuado del petróleo (GLP).”

2.3.ELECTRICIDAD

Los vehículos eléctricos puros no producen emisiones atmosféricas en el punto de uso, son muy silenciosos y tienen bajos costes de funcionamiento. Sin embargo, sus ventas son muy limitadas y desde finales de los años 90 se ha transferido gran parte del interés y los recursos a la investigación de los vehículos híbridos debido a su mayor potencia y autonomía.

Aunque el motor eléctrico puro es ideal para el medio ambiente, la poca autonomía de las baterías y su gran peso (mientras que en un vehículo de combustión el carburante representa aproximadamente un 5% del peso del automóvil, en uno eléctrico puede suponer el 40%) provocan que este motor no sea competitivo a corto plazo.

¹DIRECTIVA 2014/94/UE DEL PARLAMENTO EUROPEO Y DEL CONSEJO del 22 de octubre de 2014 relativa a la implantación de una infraestructura para los combustibles alternativos.

Los automóviles híbridos poseen tanto un motor térmico como uno eléctrico lo que hace que sean más eficientes y más limpios que un vehículo convencional. Esta tecnología es utilizada con el fin de reducir el consumo o generar más potencia sin penalizar demasiado el consumo. Las menores emisiones de este tipo de vehículos a contribuido a fomentar su desarrollo, sobre todo para uso urbano.

2.4.HIDRÓGENO

Existen dos aplicaciones del hidrógeno como combustible para automóviles: las **pilas de combustible** y los **motores alternativos de combustión interna**. En ambas aplicaciones el hidrógeno se combina con el oxígeno obteniendo electricidad en el caso de las pilas de combustible y energía mecánica en el caso de los MACI. En los dos casos la única emisión que se produce a la atmósfera en el punto de utilización es vapor de agua, lo que implica grandes beneficios medioambientales. Sin embargo, hay que mencionar, que en el proceso de producción del hidrógeno se producen emisiones contaminantes pues la mayor parte de este combustible se obtiene a partir de gas natural mediante un proceso que genera CO₂.

El problema del hidrógeno como combustible es su almacenamiento, que requiere de pesados y voluminosos depósitos.

2.5.BIOCARBURANTES

Son aquellos combustibles producidos a partir de biomasa (a través de reacciones físico-químicas) y por lo tanto renovables, que pueden ser utilizados en los actuales motores de combustión interna (diésel y gasolina).

Los biocarburantes más importantes son el biodiésel y bioetanol. El primero es una alternativa al gasóleo mientras que el segundo es un aditivo o un sustituto de la gasolina.

Biodiésel

Hace referencia a los ésteres metílicos obtenidos por esterificación, a partir de los aceites vírgenes extraídos principalmente de semillas de girasol, colza, palma y soja o de aceites vegetales usados y de grasas animales.

Poseen características combustibles similares a las del gasóleo. El biodiésel puede utilizarse como único combustible en sustitución del gasóleo o mezclarse en distintas proporciones en motores MEC o MEP siendo la mezcla más frecuente con gasóleo y en la proporción 5% de biodiésel y 95% de gasóleo (los motores diésel modernos podrían funcionar con mezclas de hasta un 30% en biodiésel). Esta mezcla es válida para los motores diésel convencionales sin que sea necesaria ninguna modificación.

Este combustible reduce las emisiones netas de gases de efecto invernadero frente al empleo de gasóleo fósil, se biodegrada fácilmente y constituye una fuente europea de suministro de carburante.

Bioetanol

Este combustible se fabrica mediante la fermentación del azúcar, del almidón o de la celulosa. El bioetanol puede utilizarse mezclado con gasolina en una proporción de 5%

de Bioetanol y 95% de gasolina sin que sea necesaria ninguna modificación en el motor. También puede emplearse como único combustible en motores MEP, pero en este caso sí que son necesarias ciertas modificaciones en el motor. Es interesante la fabricación y uso de vehículos de combustible flexible (FFV), diseñados para utilizar una amplia gama de concentraciones de etanol.

El bioetanol presenta ventajas medioambientales respecto a la gasolina ya que reduce las emisiones de gases de efecto invernadero.

2.6.COMBUSTIBLES SINTÉTICOS

Son combustibles obtenidos mediante procesos termoquímicos a partir de diferentes materias primas, principalmente: gas natural, carbón y biomasa. Se dividen en tres tipos atendiendo a su materia prima:

- Gas natural.
- Carbón.
- Biomasa.

Hay que destacar que los combustibles sintéticos basados en gas natural y carbón utilizan como materia prima combustibles fósiles no renovables. Sin embargo estos combustibles presentan menores emisiones de contaminantes que los combustibles normales. Por otro lado, las emisiones globales de gases de efecto invernadero son superiores a las de combustibles convencionales salvo para el caso del combustible sintético basado en la biomasa.

2.7.GAS NATURAL

El gas natural es una mezcla rica de hidrocarburos ligeros, compuesto mayoritariamente por metano. Es el combustible fósil que presenta el menor impacto ambiental negativo, tanto por sus características, como por las tecnologías disponibles para su utilización. Presenta importantes reducciones en todas las emisiones (PM, NOx, etc) incluidas el CO₂ (10-20%).

Atendiendo a su almacenamiento se distinguen dos tipos:

- Gas natural comprimido (GNC): El gas se comprime a 250 bar (200 bar en España) y se almacena en el vehículo en cilindros instalados en la parte trasera, el chasis o en el techo. El gran tamaño y peso de estos depósitos de almacenaje es uno de los grandes inconvenientes que presenta.
- Gas natural licuado (GNL): El gas se almacena a presiones entre 70-210 kPa (14-24 bar en España) a una temperatura de -160°C. Los depósitos son de doble pared con aislante intermedio y posteriormente se vaporiza para ser utilizado en el motor. Presenta ventajas frente al GNC como el menor peso del depósito y un notable aumento de la autonomía del vehículo.

2.8.LEGISLACIÓN VIGENTE

La mayoría de los avances en la reducción de emisiones contaminantes en Europa se deben a la sucesión de las diferentes normativas europeas anticontaminantes “Euro” que progresivamente han evolucionado hacia límites de emisiones cada vez más restrictivos.

Actualmente la normativa europea vigente es la “Euro VI”.

Esta normativa, respecto a su predecesora, reduce las emisiones de óxido nitrógeno a 80 mg/km (180mg/km en Euro V) para todas las motorizaciones diésel y mantiene el mismo límite que la normativa anterior en partículas en suspensión. En lo que se refiere a motores de gasolina, se mantienen los límites marcados por la normativa “Euro V” de ambas emisiones (60 mg/km de NOx y 5 mg/km de partículas).

De esta forma queda claro que la normativa Euro VI establece restricciones más fuertes para los motores diésel.

Límites de emisiones Euro 6

Categoría	Clase	Masa de referencia (MR) (kg)	Valores límite													
			Masa de monóxido de carbono (CO)		Masa total de hidrocarburos (THC)		Masa de hidrocarburos no metánicos (HCNM)		Masa de óxidos de nitrógeno (NO _x)		Masa combinada de hidrocarburos y óxidos de nitrógeno (HCT + NO _x)		Masa de materia particulada (PM) (°)		Número de partículas (NP)	
			L ₁ (mg/km)	CI	L ₂ (mg/km)	CI	L ₃ (mg/km)	CI	L ₄ (mg/km)	CI	L ₂ + L ₄ (mg/km)	CI	L ₅ (mg/km)	CI	PI (°) (°)	CI
M	—	Todos	1 000	500	100	—	68	—	60	80	—	170	4,5	4,5	6,0 × 10 ¹¹	6,0 × 10 ¹¹
N ₁	I	MR ≤ 1 305	1 000	500	100	—	68	—	60	80	—	170	4,5	4,5	6,0 × 10 ¹¹	6,0 × 10 ¹¹
	II	1 305 < MR ≤ 1 760	1 810	630	130	—	90	—	75	105	—	195	4,5	4,5	6,0 × 10 ¹¹	6,0 × 10 ¹¹
	III	1 760 < MR	2 270	740	160	—	108	—	82	125	—	215	4,5	4,5	6,0 × 10 ¹¹	6,0 × 10 ¹¹
N ₂	—	Todos	2 270	740	160	—	108	—	82	125	—	215	4,5	4,5	6,0 × 10 ¹¹	6,0 × 10 ¹¹

Clave: PI = encendido por chispa; CI = encendido por compresión.

(°) Se aplica un límite de 5,0 mg/km de emisión máxica de partículas a los vehículos que han recibido la homologación de tipo con respecto a los límites de emisión de este cuadro mediante el anterior protocolo de medición de la masa de partículas, antes del 1 de septiembre de 2011.

(°) Los límites relativos a la masa y al número de partículas correspondientes al encendido por chispa se aplicarán únicamente a los vehículos equipados con motores de inyección directa.

(°) Hasta tres años después de las fechas indicadas en el artículo 10, apartados 4 y 5, para las nuevas homologaciones de tipo, y los vehículos nuevos, respectivamente, a elección del fabricante se aplicará un límite de emisiones de número de partículas de 6,0 × 10¹² #/km a los vehículos Euro 6 PI de inyección directa. Como máximo hasta dichas fechas se aplicará un método de ensayo de homologación de tipo que garantice la limitación efectiva del número de partículas emitidas por los vehículos en condiciones reales de conducción.

Figura2.1: Valores límite marcados por la normativa Euro VI (Fuente: Extraída de [5]).

2.9.CONCLUSIONES

Las sucesivas normativas europeas y el desarrollo de combustibles alternativos demuestran lo que a día de hoy es una prioridad para los países de la UE, mejorar la eficiencia energética del transporte y fomentar el uso de energías alternativas al petróleo.

Todo lo comentado anteriormente justifica el interés de este trabajo, que tiene como objeto la evaluación y predicción del comportamiento medioambiental de los diferentes combustibles alternativos y sus respectivas mezclas utilizadas en el sector del transporte.

3. DATOS

3.1 INTRODUCCIÓN

Para realizar el presente trabajo ha sido necesaria una amplia base de datos con el fin de relacionar parámetros operativos del motor (rpm, carga, rendimiento efectivo, dosado, etc.) con sus parámetros de salida, en este caso, sus emisiones contaminantes (NOx, CO, inquemados, CO₂) mediante la aplicación práctica de las redes neuronales artificiales.

Al no existir vehículos comerciales que permitan obtener los datos necesarios para el conjunto de combustibles alternativos y mezclas a estudiar y la imposibilidad de llevar a cabo las pruebas y ensayos en un banco de motores, se ha tenido que configurar una base de datos a partir de diferentes ensayos publicados en revistas científicas.

Este tipo de pruebas en motores corresponde a los ensayos de investigación, encaminados a la obtención experimental de parámetros y emisiones de los MACI. La medida de las emisiones es obtenida mediante procesos físico-químicos, por los analizadores de gases del escape, en un banco de pruebas donde se le hace funcionar al motor bajo diferentes puntos de operación.

Las mezclas con gasolina, el hidrógeno y el etanol fueron probadas en motores de encendido provocado (MEP) mientras que las mezclas con diésel y con gas natural se testaron en motores de encendido por compresión (MEC).

COMBUSTIBLE	Fuente
GASOLINA	6, 7, 9, 10, 11, 13
DIÉSEL	8
H ₂ PURO	6
5% H ₂ + 95% GASOLINA	7
10% H ₂ + 90% GASOLINA	7
15% H ₂ + 85% GASOLINA	7
20% H ₂ + 80% GASOLINA	7
25% H ₂ + 75% GASOLINA	7
70% DIÉSEL + 30% H ₂	8
ETANOL PURO	9
50% ETANOL + 50% GASOLINA	11
80% ETANOL + 20% GASOLINA	11
85% ETANOL + 15% GASOLINA	10
GAS NATURAL LICUADO + DIÉSEL	12
GAS NATURAL COMPRIMIDO	13

Tabla 3.1: Combustibles y mezclas.

La Tabla 3.1 muestra los combustibles y mezclas utilizados en este trabajo. La información de las condiciones operativas y de las prestaciones de estas mezclas se han extraído de diferentes artículos publicados en revistas científicas en los que se presentaban datos obtenidos en pruebas de banco de motores.

3.2 PARAMETROS Y EMISIONES

Como ya se ha comentado la forma de obtener los parámetros del motor y sus emisiones ha sido a través de estudios existentes sobre los combustibles y mezclas antes señalados. Sin embargo, no todos los valores se han podido obtener de forma directa. Para completar una base de datos homogénea, necesaria para obtener las matrices de entrada-salida globales a partir de los estudios citados, han sido necesarios diferentes cálculos ya sea aplicando las relaciones existentes entre los diferentes parámetros de un MACI o planteando las reacciones de combustión de los combustibles y mezclas.

Todas las variables seleccionadas como entradas de la RNA tienen influencia de forma directa o indirecta en las emisiones que se producen en un MACI. Las emisiones de CO en MEP están determinadas fundamentalmente por el dosado, y se originan con mezclas ricas dándose estas principalmente en el arranque en frío y en condiciones de plena carga. En MEC al trabajar con mezclas pobres estas emisiones son normalmente reducidas. Las emisiones de hidrocarburos (HC) no solo se producen con mezclas ricas, también con mezclas pobres por lo que a bajos grados de carga estas emisiones pueden ser considerables, otra variable que influye en este contaminante es la relación de compresión (a mayor r_c , mayores emisiones) y la relación carrera/diámetro (mayor S/D, menores emisiones). En las emisiones de NOx el dosado vuelve a ser la variable principal a tener en cuenta junto con la concentración de oxígeno y la temperatura. Su máxima concentración se producen con dosados ligeramente pobres donde se produce la combinación de exceso de oxígeno y altas temperaturas. Las emisiones de CO₂ se producen por la combustión completa de los hidrocarburos, hablar de CO₂ es hablar de consumo de combustible.

La Tabla 3.2 muestra las entradas y salidas de las RNA y las unidades utilizadas.

ENTRADAS	
COMBUSTIBLES	UNIDADES
Gasolina	%
Diésel	%
Hidrogeno	%
Etanol	%
Gas Natural Licuado (GNL)	%
Gas Natural Comprimido (GNC)	%
PARAMETROS DE OPERACIÓN	UNIDADES
Régimen de giro del motor	rpm
Rendimiento Efectivo	%
Carga	%
Consumo Específico	g/kWh
Relación de Compresión	-
Potencia Efectiva	kW
Par	Nm
Presión Media Efectiva	bar
Velocidad Media del Pistón	m/s
Dosado	-
Lambda	-
Flujo Másico de Combustible	kg/s
Flujo Másico de Aire	kg/s
Rendimiento Volumétrico	%
Cilindrada	cm ³
Cilindros	-
Relación Carrera-Diámetro	-
SALIDAS	
EMISIONES	UNIDADES
NOx	g/kWh
CO	g/kWh
HC	g/kWh
CO ₂	g/kWh

Tabla 3.2: Entradas y salidas de las RNA.

4. REDES NEURONALES ARTIFICIALES (RNA)

4.1. DEFINICIÓN

A continuación se presentan dos definiciones básicas sobre qué es una red neuronal artificial que pueden ser aclaratorias:

- “Una red neuronal es un procesador distribuido y con estructura paralela que tiene una tendencia natural a almacenar conocimiento experimental, haciéndolo apto para su uso. Se parece al cerebro en dos cosas: el conocimiento es aprendido por la red a través de un proceso de aprendizaje y este conocimiento se almacena en los pesos sinápticos o conexiones entre neuronas” [53].
- “Una red neuronal es un modelo computacional con un conjunto de propiedades específicas, como son la habilidad de adaptarse o aprender, generalizar u organizar la información, todo ello basado en un procesamiento eminentemente paralelo” [72].

4.2. CARACTERÍSTICAS PRINCIPALES

La estructura distribuida y paralela, así como su capacidad de entrenamiento y por tanto de generalización, hacen que las RNA sean capaces de resolver cierto tipo de problemas muy complejos.

Las principales ventajas de las RNA son:

1. **No linealidad:** Las neuronas son elementos de proceso generalmente no lineales. Esta característica permite modelar procesos intrínsecamente no lineales. Por el contrario complica los métodos de análisis de las estructuras resultantes.
2. **Modelado de relaciones entrada-salida:** Una RNA es capaz de aprender a partir de un conjunto de parejas de datos entrada-salida sin necesidad de conocer las características del problema.
3. **Aprendizaje adaptativo:** Las RNA tienen la cualidad de aprender a realizar tareas a partir de un entrenamiento debido a la capacidad de auto-ajuste de los elementos de procesado (neuronas) que componen el sistema. Esta auto-organización conlleva la generalización y permite a la RNA responder de forma adecuada a situaciones a las que no había sido entrenada anteriormente.
4. **Tolerancia a fallos:** Las RNA pueden aprender a reconocer patrones distorsionados o con ruido siempre y cuando haya suficiente información correcta que le permita distinguir errores
5. **Fácil inserción dentro de la tecnología existente:** Las RNA presentan un alto grado de conectividad y una gran rapidez de ejecución, lo que las hace ideales para ser implantadas en sistemas modulares, además su funcionamiento tipo caja negra (se introducen unas entradas que producen unas salidas) las hace muy recomendables para estos sistemas.
6. **Operación en tiempo real:** Aunque el entrenamiento de las RNA puede llegar a ser muy costoso en tiempo, una vez que ya han sido entrenadas, su respuesta ante nuevas variables de entrada es muy rápida.

4.3.ELEMENTOS BASICOS

En esta sección se presentan los elementos básicos de procesado encargados de realizar las operaciones de la red neuronal.

Sistema de patrones entrada-salida

Un patrón de entrada de una RNA es un conjunto de variables independientes de entrada que representan el sistema que se quiere modelar. Del mismo modo un patrón de salida será el conjunto de variables de respuesta del sistema a modelar, correspondiente a un patrón de entradas. Al conjunto de patrones de entrada y salida disponibles para el entrenamiento y posterior validación se les denomina sistema de patrones de entrada y salida respectivamente.

Conexiones y pesos sinápticos

Las conexiones sinápticas son las vías de comunicación entre los diferentes elementos de procesado (neuronas) y entre éstos y las entradas-salidas del sistema. Estas conexiones exclusivamente pueden transmitir información en un sentido y se establecen únicamente entre dos elementos.

Cada conexión que une las neuronas lleva asociada un peso o ponderación. Además de este, existen unos pesos adicionales llamados bias o sesgos asociados a unas conexiones con una unidad ficticia de entrada unidad y la neurona de llegada. Este último grado de libertad mejora la convergencia del ajuste de los pesos durante el entrenamiento.

Funciones de activación

Al igual que las neuronas biológicas pueden estar excitadas o no, las neuronas artificiales también poseen diferentes grados de activación que pueden limitarse a dos o variar entre un rango de valores (normalmente entre $[0,1]$ o $[-1,1]$). Este valor indica si la neurona esta activa (1) o inactiva (-1 o 0), o se encuentra en un estado intermedio de activación entre esos límites.

La salida final de una neurona se obtiene al aplicar la función de activación a la entrada ponderada total.

Normalmente se utilizan funciones de activación identidad (función lineal) para las neuronas de la capa de salida (es la utilizada en el presente trabajo para la capa de salida), mientras que para las capas intermedias las funciones de activación más comunes son las funciones sigmoideas ya sean en su forma binaria (la utilizada en el trabajo) o en forma bipolar (tangente hiperbólica), la diferencia entre ambas funciones es el intervalo de variación de cada una de sus salidas: $[0,1]$ en su forma binaria y $[-1,1]$ en la forma bipolar. Cabe destacar que existen un gran número de funciones de activación pero las nombradas son las más comunes.

Por último, comentar que estas funciones cumplen con el requisito necesario de que sean derivables para poder aplicar los algoritmos de entrenamiento tipo *Backpropagation*, que será el utilizado en este trabajo. Más adelante se describirá este algoritmo.

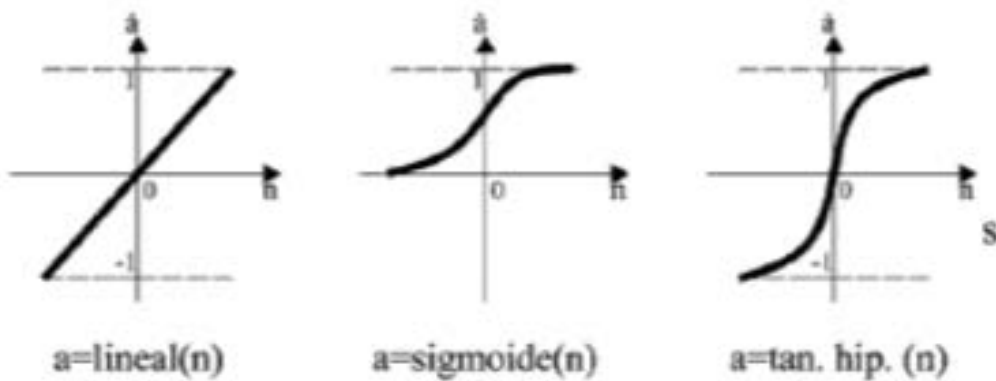


Figura 4.1: Funciones de activación más comunes (Fuente: Extraída de [18])

Elemento de procesado: neurona

La neurona es el elemento encargado de procesar la información en las RNA, a continuación se describe su modo de operación:

1. El conjunto de entradas que llegan a la neurona será multiplicado por cada uno de los pesos asociados a las conexiones.
2. Se realizara una suma de esta ponderación de entradas con los pesos y con el valor del sesgo de la neurona.
3. Se obtiene la salida final aplicando a la suma ponderada una función de activación propia de la neurona.




Figura 4.2: Funcionamiento de una neurona artificial (Fuente: Extraída de [19]).

Asociación de neuronas

Dentro de la red neuronal, las neuronas se organizan en distintos niveles denominados capas. Según su situación se clasifican en 3 tipos:

- **De entrada:** Constituye la primera capa de la red neuronal y está formada por tantas neuronas como entradas tiene la RNA. Las neuronas de esta capa se limitan a distribuir las entradas externas a las capas posteriores, sin realizar ninguna de “sus funciones”.
- **Ocultas:** Estas neuronas no tienen contacto directo con las señales externas a la red. Son las que se encargan de realizar el trabajo, y las que mejor se ajustan a la definición de neurona hecha anteriormente. Puede haber varias capas ocultas (redes multicapa).
- **De salida:** Son las encargadas de transmitir la información generada por la red al exterior. En esta capa el número de neuronas vendrá determinado por el número de salidas que tiene la RNA.




Figura 4.3: Estructura de una red neuronal monocapa (Fuente: Extraída de [20]).

4.4.ALGORITMO BACKPROPAGATION (LEVENBERG-MARQUARDT)

Dado que este es el método de entrenamiento de las RNA utilizado en el presente trabajo en esta sección se va a describir su funcionamiento.

Este algoritmo es uno de los más avanzados dentro de los algoritmos supervisados² de aprendizaje por corrección del error³.

Su nombre deriva de la forma que tiene de propagar el error desde la capa de salida a la de entrada (hacia atrás), modificando los pesos de las capas intermedias, lo que permite que sea aplicable a modelos de redes multicapa.

Diagrama de flujo

El funcionamiento de este algoritmo se desarrolla en un proceso iterativo de entrenamiento que consiste en cinco pasos:

² Tipo de entrenamiento donde se dispone de un conjunto de pares de datos entrada-salida.

³ Aprendizaje que consiste en minimizar la diferencia entre los valores deseados y los obtenidos en la salida de la red, ajustando los pesos de las diferentes conexiones de la RNA.

1. **Inicialización de los pesos:** Asignación aleatoria de los pesos iniciales.
2. **Cálculo ascendente:** Con los pesos asignados, se calculan desde la capa de entrada a la de salida los resultados proporcionados por todas las neuronas, a partir de los patrones de entrenamiento.
3. **Cálculo del error:** Una vez obtenidas las salidas de la red, se comparan con las salidas deseadas mediante la función del error cuadrático medio. En el algoritmo se definen las diferentes condiciones de parada: alcanzar un error mínimo previamente definido, un número máximo de épocas (iteraciones del algoritmo), etc. Si se cumple la condición de parada el entrenamiento termina.
4. **Cálculo descendente:** De esta fase es donde viene el nombre del algoritmo ya que avanza en sentido contrario al de las conexiones, en ella, se calculan los parámetros de retropropagación para la posterior actualización de los pesos.
5. **Actualización de los pesos:** Tras realizarse el cálculo descendente, se modifica el valor de los pesos.

Este proceso se repetirá desde el paso 2 hasta que se cumpla alguna de las condiciones de parada definidas en el paso 3. El diagrama inferior, obtenido de la referencia en la que se ha basado este trabajo [1], muestra el proceso arriba descrito.




Figura4.4: Diagrama de flujo del algoritmo Backpropagation (Fuente: Extraída de [1]).

Algoritmo Levenberg-Marquardt

Como ya se ha comentado anteriormente el algoritmo Backpropagation es uno de los más importantes y eficaces. Sin embargo, el problema de este tipo de métodos radica en la dificultad de reconocer, al converger en una solución, si ésta se trata de un mínimo global o simplemente es una solución local. Esto último provoca que la solución analítica no sea fácil de encontrar.

Por lo anterior, existen diferentes métodos de optimización del algoritmo Backpropagation estándar. Uno de estos métodos es el algoritmo Levenberg-Marquardt.

Este algoritmo será el utilizado en el entrenamiento de las RNA pues es el que mejor respuesta ofrece presentando una rápida convergencia, un reducido tiempo de cálculo y unas mejores predicciones [1].

4.5.GENERALIZACIÓN DE RNA

La capacidad de generalización de una RNA es de vital importancia para la buena predicción de los datos no usados en el entrenamiento y conseguir reproducir correctamente el fenómeno que se pretende modelar.

A continuación se van a describir dos factores de influencia en la capacidad de generalización de la RNA.

Patrones de entrenamiento

Hay que tener en cuenta que las RNA son modelos empíricos, donde la precisión del modelo estará siempre supeditada por el conjunto de patrones de entrenamiento que se le proporcione para su ajuste o entrenamiento. Por ello es importante disponer de una base de datos experimentales amplia, representativa, completa y de calidad del problema que se intenta modelar.

Sobreentrenamiento

Este es uno de los problemas más importantes en el entrenamiento de RNA y que es necesario evitar para conseguir buenas predicciones en la fase de testeo (cuando se le presentan datos no entrenados previamente). Aunque en los casos donde se dispone de un número de patrones de entrenamiento suficientemente grande las mejores generalizaciones suele corresponder con largos entrenamientos, esto no ocurre en la mayoría de los casos, donde se tiene un conjunto de patrones de entrenamiento más reducido. En este caso un número excesivo de iteraciones provocan el sobreentrenamiento, pues la RNA aprende las características específicas de los patrones que se han utilizado durante el entrenamiento provocando una peor generalización y unas predicciones muy alejadas del comportamiento esperado.

Existen algunas técnicas para evitar este problema como: disminución de los pesos a ajustar, parada anticipada, validación cruzada, etc.

4.6.FASES DEL ENTRENAMIENTO

A la hora de entrenar las RNA cabe distinguir tres fases:

1. **Entrenamiento:** En esta fase la RNA va ajustando los pesos para obtener las salidas deseadas gracias a los pares de ensayo entrada-salida.
2. **Validación:** En esta fase la red neuronal pretende evaluar la utilidad del modelo obtenido en el entrenamiento y su capacidad de generalización.
3. **Testeo:** En esta última fase pretende obtener una estimación de la precisión en la predicción.

Aunque en el presente trabajo el entrenamiento de las RNA presenta estas tres fases, no es siempre así, pudiéndose dar entrenamientos que solo incluyan dos fases (entrenamiento + validación o entrenamiento + testeo). El conjunto total de los patrones

se divide en tantos grupos como fases tenga el entrenamiento con el fin de que cada fase tenga su subconjunto de patrones propios.

Por último añadir que una vez que se ha realizado el entrenamiento completo se procede a presentar a la RNA nuevos datos, no vistos por la red neuronal, para su predicción.

4.7.INICIALIZACIÓN DE LOS PESOS

Los pesos iniciales elegidos para la minimización del error son de gran importancia tanto para la calidad del mínimo encontrado como para las iteraciones necesarias para encontrarlo. No hay una solución que asegure la correcta selección de los pesos iniciales, pero si ciertos criterios que pueden ayudar:

- Aplicar el conocimiento disponible sobre el problema que se quiere modelar para seleccionar un buen punto de inicio de los pesos. Es la solución más rápida, pero inviable en la mayoría de los casos.
- Emplear métodos de optimización global para que la solución final no dependa del punto inicial elegido, como los métodos de Montecarlo o algoritmos genéticos.
- Realizar varias pruebas de inicialización con el objetivo de quedarse con la que proporcione una mejor solución o un promedio de las mismas. Es un método basado en el ensayo-error por lo que conlleva la multiplicación de los entrenamientos y del coste temporal. En el presente trabajo este será el método utilizado.

La mayoría de los algoritmos implementan una inicialización aleatoria de los pesos distribuida uniformemente sobre un rango $[-r, r]$. En este trabajo este rango será $[-1, 1]$.

4.8.ACTUALIZACION DE LOS PESOS

Existen dos formas de actualizar los pesos en el algoritmo de entrenamiento:

- **Estrategia incremental:** Los pesos se actualizan cada vez que a la red se le presenta un nuevo patrón de entrenamiento.
- **Estrategia batch:** Los pesos se actualizan tras haberle presentado a la red todos los patrones de entrenamiento.

Para este trabajo se ha utilizado la estrategia batch, que es la recomendada cuando no se dispone de bases de datos grandes y redundantes, y en los casos donde se necesita precisión en los datos de salida y entrenamientos optimizados.

5. DESARROLLO DE LAS RNA PARA LA PREDICCIÓN DE EMISIONES

En esta sección se va abordar el objetivo final de este trabajo que es disponer de RNA como herramienta de predicción de las emisiones para diferentes mezclas de combustibles y parámetros de operación. Se comenzará describiendo los tratamientos previos realizados a los datos y se continuará desarrollando las estrategias de entrenamiento y optimización de las RNA para obtener las mejores predicciones posibles. Finalmente se analizarán los resultados obtenidos con el fin de mostrar la influencia de cada optimización para las diferentes RNA.

5.1 MEDICIÓN DE LA CALIDAD DE LAS RNA

Antes de comenzar con los entrenamientos es importante seleccionar un conjunto de criterios para evaluar y comparar la fiabilidad y calidad de las RNA como herramienta de predicción. Los criterios elegidos para este fin son los descritos por la referencia principal en la que se basa este trabajo [1]:

1. **Coefficiente de correlación R:** Este valor establece el grado de asociación lineal entre los valores esperados y los predichos, evaluando la tendencia de los segundos frente a los primeros.
2. **Parámetros A5% y A10%:** Estos estimadores especifican el porcentaje de puntos predichos que tienen una dispersión menor del 5% y del 10% respecto de los valores esperados.
3. **Factor de calidad (Q):** Definido para ayudar a una rápida comparación entre RNA. Este factor aúna en un solo valor los términos definidos anteriormente.

El parámetro Q viene determinado por la siguiente expresión:

$$Q = A5\% \cdot 0.45 + A10\% \cdot 0.3 + 0.25 \cdot R \cdot 100 \quad (5.1)$$

Al definir la ecuación anterior se ha buscado premiar las pequeñas dispersiones (5%) y dar menos representatividad al término R pues suelen presentar valores altos.

4. **Error absoluto:** Se ha utilizado el promedio de los errores absolutos como parámetro alternativo para la estimación de la calidad de la RNA. Comentar también que no se ha incluido el promedio de los errores relativos por la imposibilidad de su cálculo en tres de las cuatro emisiones (HC, CO, CO₂) que presentan valores esperados iguales a 0. La expresión utilizada para obtener el promedio de los errores absolutos es la siguiente:

$$ERRORabs = \frac{1}{N} \sum_{i=1}^N \sqrt{(X_{RNA}(i) - X_{esperado}(i))^2} \quad (5.2)$$

Donde N es el número total de datos evaluados, mientras que X_{RNA} y $X_{esperado}$ representan los valores predichos y esperados, respectivamente.

5.2 TRATAMIENTO PREVIO DE LOS PATRONES DE ENTRENAMIENTO

Antes de comenzar los entrenamientos de las RNA, es necesario organizar el conjunto de patrones de entrada y salida, así como realizar un preprocesamiento previo con el fin de optimizar este conjunto de datos disponibles para una mayor eficacia del entrenamiento posterior.

Organización de los patrones

Uno de los factores importantes que pueden determinar la calidad de las RNA es el número de patrones de entrenamiento disponibles, como se ha explicado en la sección anterior. Teniendo en cuenta que el número de datos de entrenamiento disponibles para este trabajo es reducido se ha optado por realizar la técnica de validación cruzada, que permite entrenar con todos los patrones disponibles a costa de entrenar la RNA varias veces.

En este trabajo se han dividido los patrones en 4 grupos. Cada uno de los 4 entrenamientos seguidos ha utilizado 3 de los 4 grupos, dejando el grupo descartado para el proceso de predicción. La siguiente tabla muestra el esquema seguido y recoge la nomenclatura que se utilizará en las explicaciones posteriores.

	División	Entrenamiento (Entr-Sal)	Predicción
Conjunto total de parámetros de entrada	G1 , G2, G3, G4	E1 (G1, G2, G3)	P1 (G4)
		E2 (G1, G2, G4)	P2 (G3)
		E3 (G1, G3, G4)	P3 (G2)
		E4 (G2, G3, G4)	P4 (G1)

Tabla 5.1: Organización de los patrones para su entrenamiento y predicción.

Con esta técnica no solo se ha conseguido poder utilizar todos los parámetros disponibles para entrenar las RNA, sino que además se ha obtenido la predicción para todos esos parámetros, sin que en ningún caso la red neuronal haya entrenado antes el dato a predecir.

Preprocesado de patrones

El preproceso de las entradas y salidas de las RNA puede mejorar notablemente la eficacia del entrenamiento. Esta mejora deriva de las mejores propiedades numéricas del proceso de optimización evitando las posibles problemas de saturación de las funciones de activación y el problema de la dependencia de los pesos iniciales de la escala de los datos de entrada, además, ayuda a que las diferencias relativas entre los datos sea el factor que domine durante los entrenamientos en vez de las diferencia absolutas.

Las dos soluciones más empleadas son normalizar o estandarizar los datos:

- **Normalizar:** Consiste en escalar los datos para que estén dentro de un rango determinado, normalmente [0,1] o [-1, 1]. Este es el preprocesado elegido para el desarrollo de este trabajo.

- **Estandarización:** En este caso los datos se transforman para que tengan media nula y una desviación estándar igual a uno.

Estas transformaciones se realizan antes de presentar los datos a la red y una vez obtenidas las predicciones es necesario deshacer el cambio para poder comparar con los patrones de salida, además, cada vez que se le proporcione nuevos datos para entrenar o predecir se le debe aplicar el mismo criterio de preprocesado que se utilizó en primer lugar, con el fin de mantener la coherencia del proceso.

5.3 ESTRATEGIA DE ENTRENAMIENTO

El objetivo inicial es implantar una estrategia de entrenamiento que elimine los problemas asociados a factores aleatorios que no se pueden controlar. Entre estos factores se encuentra la variación de las inicializaciones. Como ya se comentó en la Sección anterior al no haber un criterio que garantice la buena elección de las inicializaciones se ha optado por realizar varias pruebas para seleccionar la que mejores resultados proporcione.

Otro de los problemas que pueden surgir en el entrenamiento y que ya fue descrito en la sección anterior es el sobreentrenamiento. Este problema puede ser importante, en el presente estudio, por el reducido número de patrones de entrenamiento de los que disponemos. Para minimizar este problema se ha utilizado el método de parada anticipada.

Este método consiste en dividir el conjunto de patrones de entrenamiento en nuestro trabajo, por ejemplo, E1 (G1, G2, G3) en tres subconjuntos correspondientes a las fases que componen el entrenamiento de las RNA: entrenamiento, validación y testeo.

Como se puede ver en la Figura 5.1 obtenida de uno de los entrenamientos realizados, al comenzar se observa que los errores de la fase de entrenamiento y de la de validación disminuyen, sin embargo a partir de un determinado momento aunque el error de la fase de entrenamiento sigue disminuyendo, el error de validación aumenta.

Este comportamiento indica que la RNA ha comenzado a sobreentrenar. Por lo tanto para evitar el sobreentrenamiento es necesario detener el proceso de aprendizaje cuando el error de validación es mínimo.




Figura 5.1: Imagen de una gráfica donde se puede ver la evolución de los errores de las diferentes fases del entrenamiento. El círculo marca el error de validación mínimo.

La estrategia de entrenamiento seguida se va a dividir en dos fases: la primera consistirá en obtener el error de parada del entrenamiento y la segunda en realizar el entrenamiento de las RNA hasta el error de parada y obtener las predicciones.

Fase 1: Obtención del error de parada

En esta fase se han realizado un total de 40 entrenamientos diferentes para promediar la influencia de las inicializaciones (para cada entrenamiento se ha inicializado la red), de las subdivisiones del conjunto total de los datos (E1, E2, E3, E4) y las subdivisiones propias del entrenamiento (entrenamiento, validación y testeó).

Con el fin de que no se pare el entrenamiento al encontrar el primer error mínimo de validación se ha puesto como condición de parada un número máximo de épocas o iteraciones (300). En cada uno de los entrenamientos se ha identificado el error (MSE) de entrenamiento correspondiente al mínimo error de validación (MSE_{val_min}).

Una vez que se han obtenido los MSE_{val_min} de los 40 entrenamientos se promedian con el objetivo de calcular el error de parada que se utilizará en el entrenamiento de la fase 2.

Con el objetivo de intentar compensar un posible subentrenamiento, que se podría producir al darse algún caso de entrenamiento malo y por el hecho de reservar un porcentaje de datos para la validación, en lugar de obtener directamente el error de parada del promedio de los 40 MSE_{val_min} se ha reducido este valor un 20%. Finalmente la ecuación del error de parada queda de la siguiente forma:

$$Error\ de\ Parada = 0.8 \cdot \frac{\sum_{i=1}^{40} MSE_{val_min}}{40} \quad (5.3)$$

Fase 2: Entrenamiento hasta el error de parada y cálculo de predicciones

En esta fase, utilizando el error de parada calculado anteriormente, se han realizado los sucesivos entrenamientos de las RNA y las predicciones del conjunto de parámetros no vistos por la red neuronal en el entrenamiento.

En esta etapa se han realizado 5 inicializaciones diferentes y para cada una de ellas se han llevado a cabo 4 entrenamientos, uno para cada subconjunto en el que se han dividido el total de los datos (E1, E2, E3, E4). Para cada entrenamiento se ha puesto como condición de parada el error de parada calculado y así evitar posibles problemas de sobreentrenamiento. Después de entrenar la RNA con el subconjunto oportuno se ha procedido a calcular sus predicciones correspondientes entre los cuatro grupos disponibles (P1, P2, P3, P4), con el fin de evitar que la RNA realice la predicción de datos vistos con anterioridad en el entrenamiento

Para esta fase se han definido los siguientes parámetros característicos de los diferentes entrenamientos:

- **MSE entrenamiento:** Es el error en el que se detiene el entrenamiento en la segunda fase y que es cercano al error de parada calculado en la primera fase.
- **Épocas entrenamiento:** Es el número de épocas que ha tardado el algoritmo en alcanzar el error de parada.

5.4 RNA BASE

Con la estrategia de entrenamiento utilizada, ya definida, se va a proceder a presentar las RNA base, que servirán de punto de partida para introducir posteriormente las optimizaciones.

Se han elegido características comunes básicas para todas las RNA para una posterior optimización de forma individual en función de la respuesta que proporcionen las sucesivas mejoras.

Para los factores que describen una RNA, tales como: conjunto de variables de entrada, preprocesado de los patrones, elección de la arquitectura, inicialización de los pesos y tipo de algoritmo utilizado para el entrenamiento se han seguido, en la medida de lo posible, los criterios definidos en la bibliografía principal del trabajo [1].

Los datos elegidos para el entrenamiento y predicción de las RNA base son los ya comentados en la sección dos. Como entradas los porcentajes de los diferentes combustibles y sus mezclas, y parámetros operativos del motor (23 entradas). Para las salidas se han seleccionado cuatro tipos de emisiones contaminantes. En las tablas que se muestra a continuación, a modo de recordatorio, se enumeran los diferentes parámetros de entrada y salida utilizados para las RNA base:

ENTRADAS DE LA RNA BASE (UNIDADES)	Abreviaturas utilizadas
Gasolina (%)	-
Diésel (%)	-
Hidrogeno (%)	H ₂
Etanol (%)	-
Gas natural licuado (%)	GNL
Gas natural comprimido (%)	GNC
Régimen de giro del motor (rpm)	n
Rendimiento efectivo (%)	η_{ef}
Carga (%)	-
Consumo específico (g/kWh)	g_{ef}
Relación de compresión	r_c
Potencia efectiva (kW)	Ne
Par (Nm)	-
Presión media efectiva (bar)	pme
Velocidad media del pistón (m/s)	Cm
Dosado	F
Lambda	λ
Flujo másico de combustible (kg/s)	Mf
Flujo másico de aire (kg/s)	Ma
Rendimiento volumétrico (%)	η_{vol}
Cilindrada (cm ³)	V _T
Cilindros	z
Relación carrera-diámetro	S/D

Tabla 5.2: Entradas de las RNA base.

SALIDAS DE LA RNA BASE (UNIDADES)	Abreviaturas utilizadas
Óxidos de nitrógeno (g/kWh)	NO _x
Monóxido de carbono (g/kWh)	CO
Hidrocarburos sin quemar (g/kWh)	HC
Dióxido de carbono (g/kWh)	CO ₂

Tabla 5.3: Salidas de las RNA base.

Se ha elegido implementar diferentes RNA para cada una de las salidas a predecir en lugar de utilizar una RNA global más compleja para todas ellas. Esto permite un mejor ajuste de las RNA para cada salida y evita que la calidad final de la red se reduzca a la peor de las predicciones.

La arquitectura de las RNA seleccionada es la del perceptrón multicapa que es en la actualidad de las más utilizadas debido, principalmente, su fácil uso y aplicabilidad, a la vez, que es una de las redes más potentes y con mejores resultados en sus diferentes espacios de aplicación. Dentro de esta estructura se han elegido redes de una sola capa (oculta) para evitar problemas de estancamiento en mínimos locales más comunes en redes multicapa y simplificar su estructura.




Figura 5.2: Perceptrón multicapa con una capa oculta. (Fuente: sacada de [20]).

El número inicial de neuronas de la capa oculta es igual al de entradas (23). Al ser RNA específicas para cada emisión la red tendrá una única salida. Las funciones de activación seleccionadas son: la sigmoide binaria para la capa oculta y la lineal para la capa de salida. La inicialización de los pesos será de forma aleatoria entre un rango distribuido entre [-1, 1]. La implementación del algoritmo Backpropagation es la de Levenberg-Marquardt, recomendado para trabajos de este tipo. La función de coste, que tienen como objetivo la minimización del error entre el valor real y predicho, es el error cuadrático medio (MSE), que es la utilizada normalmente para este tipo de entrenamientos. La estrategia batch será la utilizada para la actualización de los pesos durante el entrenamiento. Dentro del algoritmo de entrenamiento hay que destacar el parámetro de regulación μ (o Mu), término de penalización en la función de error a minimizar. Su valor depende del punto donde se encuentre el entrenamiento y va cambiando a partir de un valor inicial μ_{in} mediante la tasa de incremento μ_{inc} y la tasa de decrecimiento μ_{dec} . Los valores de estos parámetros para la RNA base son los recomendados por la bibliografía, que a su vez, son los que están por defecto en el programa utilizado ($\mu_{in}=0.001$, $\mu_{inc}=10$, $\mu_{dec}=0.1$).

Los criterios de parada utilizados en la primera fase son un número máximo de iteraciones (300 épocas) y un valor mínimo del error de entrenamiento ($MSE=10^{-5}$). En la segunda fase los criterios fueron el error de parada y para evitar el

sobreentrenamiento cuando la red no es capaz de alcanzar ese error, se ha añadido la condición de que pare cuando pasen 6 épocas sin reducir ese error.

Entradas	combustibles, n , η_{ef} , carga, g_{ef} , r_c , N_e , p_{me} , C_m , F , λ , M_f , M_a , η_{vol} , V_T , z , S/D
Salidas (una para cada RNA)	NO_x , CO , HC , CO_2
Preprocesado	Normalización entre $[-1, 1]$
Arquitectura	Perceptrón multicapa
Capas Ocultas	1
Número de neuronas de la capa oculta	23
Número de neuronas de la capa de salida	1
Algoritmo de entrenamiento	Levenberg- Marquardt
Parámetros del algoritmo	$\mu_{in}=0.001$, $\mu_{inc}=10$, $\mu_{dec}= 0.1$
Inicialización	Aleatoria entre $[-1,1]$
Actualización de los pesos	Batch
Función de coste del error	MSE
Estrategia	Fase1 + Fase2
Condiciones de parada: Fase 1	Épocas $_{Max}=300$, $MSE=10^{-5}$
Condiciones de parada: Fase 2	$MSE=$ error de parada, Validation checks = 6

Tabla 5.4: Resumen de las características de las RNA base.

5.5 PREDICCIONES DE LAS RNA BASE

Tras presentar las características de las RNA base se va a proceder a mostrar los resultados de las predicciones para las emisiones de NO_x , CO , HC , CO_2 . Para cada predicción se muestran en una tabla los criterios de calidad comentados al principio de la sección, las diferentes inicializaciones (las filas de las tablas recogen los resultados para las diferentes inicializaciones I) y sus promedios. Asimismo se representaran los datos de la mejor predicción en una gráfica donde se incluyen su recta de regresión y su coeficiente de correlación R^2 .

Mientras que la tabla muestra la variabilidad de las predicciones con respecto a las inicializaciones, la gráfica proporciona información visual del resultado obtenido.

Predicciones NOx

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	22,98	45,96	0,947	47,80	0,724
I2	26,38	43,83	0,927	48,20	0,818
I3	26,38	44,26	0,918	48,10	0,830
I4	28,51	44,68	0,954	50,08	0,695
I5	22,55	44,26	0,925	46,55	0,771

Media	25,36	44,60	0,934	48,15	0,768
-------	-------	-------	-------	-------	-------

Tabla 5.5: Resultados de la RNA base de NOx

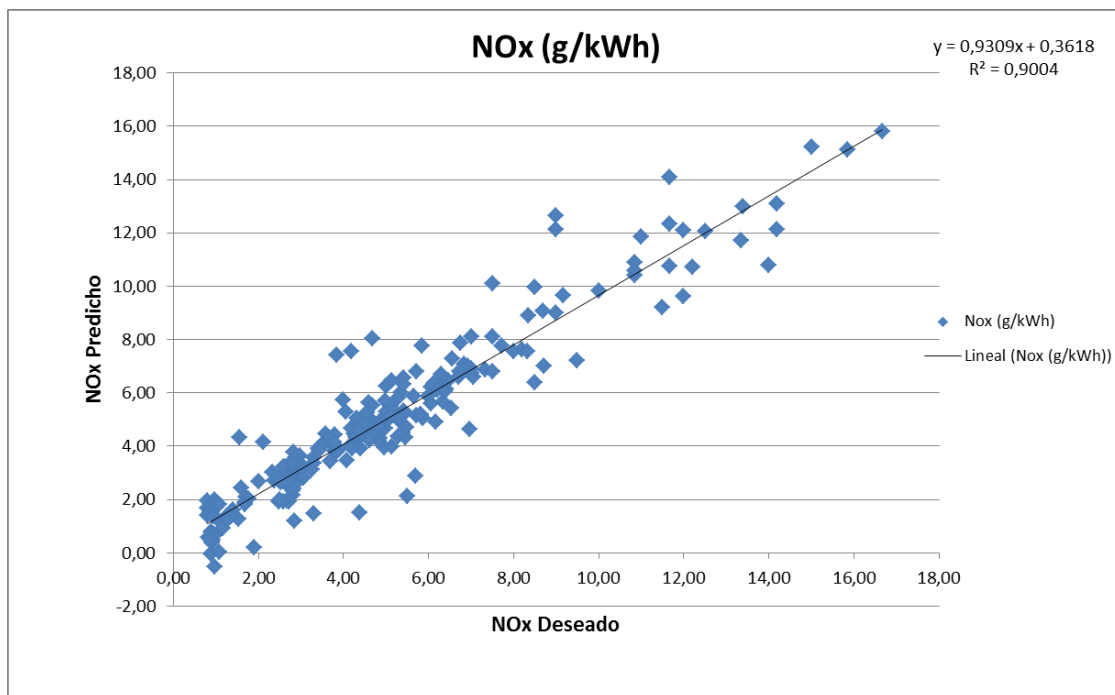


Figura 5.3: Resumen de las predicciones de NOx para la RNA base.

Análisis de resultados

Las diferentes inicializaciones no presenta grandes diferencias, siendo el rango de variación de la calidad de la red inferior a cuatro puntos, consecuentemente tampoco hay grandes diferencias en el valor del error absoluto

De la gráfica cabe destacar que para algunos valores pequeños la red neuronal ha devuelto valores negativos.

Predicciones CO

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	24,68	36,60	0,988	46,79	12,443
I2	16,60	31,49	0,993	41,74	12,029
I3	9,79	20,00	0,992	35,21	15,646
I4	14,47	20,43	0,992	37,44	15,604
I5	20,00	31,49	0,993	43,27	10,922

Media	17,11	28,00	0,992	40,89	13.329
-------	-------	-------	-------	-------	--------

Tabla 5.6: Resultados de la RNA base de CO




Figura 5.4: Resumen de las predicciones de CO para la RNA base.

Análisis de resultados

Las diferentes inicializaciones presentan bastante variabilidad siendo la diferencia entre la mejor y peor inicialización de más de diez puntos.

La grafica también nos muestra la presencia de predicciones negativas en valores próximos a cero. Comentar que para estas emisiones entre los patrones a predecir hay algunos que tienen con valor nulo. La grafica muestra la dificultad que tiene la RNA a

la hora de predecir estos valores, observando en algún caso grandes valores negativos en la predicción.

Predicciones HC

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	12,34	25,96	0,980	37,84	0,771
I2	11,06	22,13	0,974	35,97	1,097
I3	12,77	21,70	0,991	37,03	0,908
I4	16,17	26,38	0,964	39,29	1,002
I5	11,49	22,98	0,989	36,79	

Media	12,77	23,83	0,980	37,38	0,946
-------	-------	-------	-------	-------	-------

Tabla 5.7: Resultados de la RNA base de HC




Figura 5.5: Resumen de las predicciones de HC para la RNA base.

Análisis de resultados

En la tabla superior se puede apreciar la poca variabilidad de las diferentes inicializaciones, también muestra un valor elevado del error absoluto teniendo en cuenta

que la mayoría de predicciones no superan los 20 g/kW, aunque sin duda tienen gran influencia en esto las peores predicciones de los valores más elevados, como se puede ver en la gráfica. También comentar la presencia de valores negativos en la predicción de patrones nulos o próximos a cero.

Predicciones CO₂

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	65,96	74,47	0,977	76,45	26,967
I2	62,13	71,49	0,981	73,93	27,632
I3	69,36	73,62	0,986	77,95	22,640
I4	59,15	70,64	0,977	72,24	35,452
I5	58,72	72,77	0,975	72,63	10,922

Media	63,06	72,60	0,979	74,64	28,92
-------	-------	-------	-------	-------	-------

Tabla 5.8: Resultados de la RNA base de CO₂




Figura 5.6: Resumen de las predicciones de CO₂ para la RNA base.

Análisis de resultados

La tabla muestra un buen factor de calidad que en el mejor caso está cerca del 80% y poca variabilidad entre las diferentes inicializaciones. Los errores absolutos presentan valores elevados, consecuencia en parte de que la predicción se hace sobre grandes valores también.

Como ha ocurrido en las dos predicciones anteriores donde había que predecir valores nulos, la red neuronal vuelve a demostrar la dificultad que le supone dichas aproximaciones.

5.6 CONCLUSIONES DE LA RNA BASE

La dificultad en la predicción de contaminantes dadas las complejas relaciones entre los parámetros de entrada y las emisiones provoca que sea complicado obtener valores altos en sus predicciones.

De entre todas las predicciones, las de CO₂ presentan el mejor resultado con un factor de calidad realmente alto, más aun tratándose de las predicciones iniciales, y muy por encima del resto de emisiones. Las peores predicciones son las de CO y HC, lo que concuerda con lo leído en la bibliografía que señala lo complicado de obtener buenos resultados en estos casos.

Un problema a tener en cuenta, especialmente en las predicciones de CO, HC y CO₂, son las predicciones con valores negativos que carecen de sentido físico. El motivo por el que se producen en los casos antes nombrados y no, de forma tan importante, con las emisiones de NO_x es porque cuando el combustible está únicamente compuesto por hidrógeno no presenta emisiones de CO, HC y CO₂. Estos valores nulos son difíciles de modelar para las RNA obteniéndose peores predicciones en estos casos y en su mayoría valores negativos.

5.7 OPTIMIZACIÓN 1: PARAMETROS DE ENTRENAMIENTO

Con la intención de mejorar el algoritmo de entrenamiento se va a reparar en sus parámetros modificables, que son: μ_{in} , μ_{inc} , μ_{inc} y épocas máximas.

Según los estudios realizados en la bibliografía seguida los cambios en las predicciones al variar μ_{inc} , μ_{inc} y épocas máximas no han supuesto ninguna mejora de su calidad. Sin embargo, la variación del parámetro μ_{in} a la unidad sí conlleva una mejora de la calidad de las RNA. Por lo tanto se ha procedido a modificar este parámetro. A continuación se muestran los resultados obtenidos para esta primera optimización.

Predicciones NOx

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	21,70	40,85	0,936	45,42	0,821
I2	25,53	44,26	0,945	48,39	0,730
I3	24,68	44,26	0,952	48,18	0,740
I4	25,53	43,83	0,916	47,54	0,824
I5	23,83	44,68	0,935	47,50	0,720

Media	24,25	43,58	0,937	47,41	0,767
-------	-------	-------	-------	-------	-------

Tabla 5.9: Resultados de la Optimización 1 (Mu=1) de NOx




Figura 5.7: Resumen de las predicciones de NOx para la Optimización 1 (Mu=1).

Análisis de resultados

Tras realizar la primera optimización la tabla muestra unas predicciones ligeramente peores que las de la RNA base tanto en la mejor inicialización como en la media de todas. La poca variabilidad entre las diferentes inicializaciones se mantiene y la media

de los errores absolutos apenas cambia. De todos modos esta optimización no consigue mejorar las predicciones de la RNA base.

Predicciones CO

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	19,57	36,17	0,994	44,51	10,32
I2	28,94	42,13	0,992	50,46	9,75
I3	19,15	34,89	0,993	43,91	10,95
I4	21,28	40,85	0,995	46,71	9,43
I5	224,68	39,15	0,991	47,63	10,18

Media	21,72	38,64	0,993	46,64	10,12
-------	-------	-------	-------	-------	-------

Tabla 5.10: Resultados de la Optimización 1 (Mu=1) de CO.




Figura 5.8: Resumen de las predicciones de CO para la Optimización 1 (Mu=1).

Análisis de resultados

La tabla muestra unas mejores predicciones tras la optimización aumentando en casi cuatro puntos la calidad de la mejor predicción y en casi seis el promedio de las inicializaciones. También se ve como se ha reducido el promedio del error absoluto en más de tres puntos. Sin embargo el problema de las predicciones negativas se mantiene.

Predicciones HC

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	20,85	31,06	0,994	43,55	0,658
I2	15,74	26,81	0,988	39,83	0,637
I3	19,57	33,19	0,994	43,61	0,612
I4	11,91	21,28	0,984	36,34	0,842
I5	10,21	17,02	0,976	34,1	1,106

Media	15,66	25,87	0,987	39,49	0,771
-------	-------	-------	-------	-------	-------

Tabla 5.11: Resultados de la Optimización 1 (Mu=1) de HC.




Figura 5.9: Resumen de las predicciones de HC para la Optimización 1(Mu=1).

Análisis de resultados

En esta predicción se mejora la calidad de la mejor inicialización y del promedio de todas. En el primer caso el factor de calidad aumenta en cuatro puntos y en el segundo caso en dos. También se reduce el promedio del error absoluto y como era de esperar se mantienen las predicciones negativas de los valores próximos a cero.

Predicciones CO₂

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	63,83	73,19	0,982	75,23	28,24
I2	59,15	74,04	0,982	73,38	29,26
I3	65,11	72,77	0,988	75,83	22,79
I4	62,98	69,79	0,982	73,83	27,52
I5	61,70	74,47	0,980	74,61	30,10

Media	62,55	72,85	0,983	74,58	27,58
-------	-------	-------	-------	-------	-------

Tabla 5.12: Resultados de la Optimización 1 (Mu=1) de CO₂.




Figura 5.10: Resumen de las predicciones de CO₂ para Optimización 1 (Mu=1).

Análisis de resultados

En este caso no se logra superar las mejores predicciones anteriores, ni el promedio del conjunto de las inicializaciones, hay que decir no representa un empeoramiento claro de la RNA puesto que las diferencias son mínimas, sobretodo en el caso del promedio. No obstante aunque presenta un promedio de los errores absolutos ligeramente inferior, no se puede afirmar que esta optimización mejore la calidad de las predicciones anteriores.

Conclusiones sobre la optimización 1 (Mu=1)

	NOx	CO	HC	CO ₂
RNA base	48,15	40,89	37,38	74,64
Opt. 1 (MU=1)	47,41	46,64	39,49	74,58

Tabla 5.13: Comparativa de la calidad media de las RNA base y la optimización 1 (Mu=1)

Después de analizar los resultados de las predicciones al variar el parámetro Mu a la unidad se ha llegado a la conclusión de implementar este cambio únicamente para las RNA de los contaminantes CO y HC pues son los únicos casos donde se obtienen mejoras de la calidad de las predicciones. Para el resto de los contaminantes se mantendrá el parámetro Mu inicial.

5.8 OPTIMIZACIÓN 2: VARIACION DE LA ARQUITECTURA.

Siguiendo con la metodología establecida en la bibliografía seguida se procederá a determinar la arquitectura óptima para las RNA. Los cambios a realizar pueden ser la variación del número de neuronas de la capa oculta y la variación del número de capas ocultas de la estructura de la RNA. Esta última variación no se va a llevar a cabo dado que las conclusiones obtenidas de la bibliografía resaltan los problemas que presentan las redes multicapa, ya comentados en capítulos anteriores, además de no presentar mejoras en las predicciones. Por lo tanto esta optimización consistirá en variar el número de neuronas de la capa oculta. La mejor forma de obtener el número de neuronas óptimo sería realizando un barrido desde una capa oculta con una única neurona hasta un elevado número de neuronas en dicha capa (29 neuronas en el caso de la bibliografía utilizada) para cada RNA. Dada la imposibilidad de abordar los cuantiosos entrenamientos que conlleva dicha metodología en el tiempo establecido para este trabajo, se ha optado por realizar una única variación, modificando el número de neuronas de las veintitrés iniciales a diez. Los motivos por los que se ha seleccionado este número son:

- Por una parte el número de neuronas en la capa oculta elegido inicialmente ya es un número relativamente alto y aumentarlo implicaría tiempos de cálculo más largos, superficies de error complejas y además requeriría un número elevado

de patrones de entrenamiento, de los que no se dispone, para conseguir ajustar de forma precisa los pesos de la RNA.

- Por otra parte, aunque es importante seleccionar un número lo suficientemente distante del inicial con el fin de evaluar una arquitectura que presente un cambio significativo, un número excesivamente pequeño de neuronas tendría poca capacidad de reproducir un modelo de cierta complejidad como el de este trabajo.

Predicciones NOx

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	24,26	41,70	0,926	46,58	0,816
I2	20,00	35,74	0,943	43,30	0,783
I3	21,70	42,55	0,937	45,96	0,773
I4	31,06	46,81	0,889	50,25	0,855
I5	22,55	42,13	0,952	46,59	0,719

Media	23,91	41,79	0,929	46,53	0,789
-------	-------	-------	-------	-------	-------

Tabla 5.14: Resultados de la Optimización 2 (Neuronas=1) de NOx.




Figura 5.11: Resumen de las predicciones de NOx para Optimización 2 (Neuronas=10).

Análisis de resultados

Realizando una comparativa con las mejores predicciones hasta el momento que son las de la RNA base se puede observar que aunque consigue optimizar la mejor inicialización ligeramente, en promedio el factor de calidad se reduce de forma leve, justificado este hecho por la mayor variabilidad que presentan la inicializaciones. El promedio de errores absolutos también presenta un ligero empeoramiento a la vez que aumentan las predicciones negativas, aunque este problema siga siendo de menor importancia que en los demás contaminantes

Predicciones CO

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	22,98	37,07	0,996	46,36	8,90
I2	16,17	33,19	0,991	42,01	12,67
I3	22,98	40,85	0,996	47,50	8,36
I4	28,51	40,85	0,995	49,96	8,85
I5	20,43	34,89	0,995	44,54	10,55

Media	22,21	37,37	0,995	46,07	9,86
-------	-------	-------	-------	-------	------

Tabla 5.15: Resultados de la Optimización 2 (Neuronas=1) de CO.

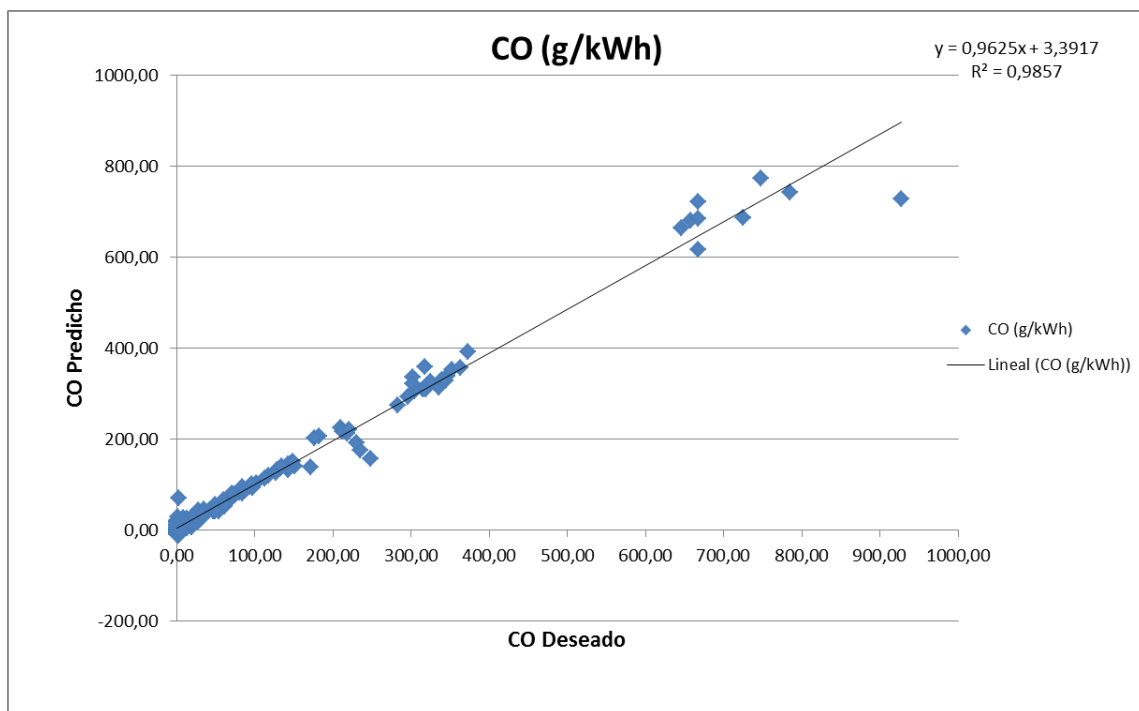


Figura 5.12: Resumen de las predicciones de CO para Optimización 2 (Neuronas=10).

Análisis de resultados

Esta RNA, comparada con la mejor hasta este momento para este tipo de emisiones presenta peores valores para la mejor inicialización y el promedio de todas, aunque en ambos casos la diferencia es mínima. La media del error absoluto es ligeramente inferior. Se reducen los casos de predicciones negativas pero sigue mostrando dificultad a la hora de predecir los valores nulos.

Predicciones HC

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	20,43	31,49	0,993	43,46	0,656
I2	16,17	29,79	0,985	40,84	0,761
I3	18,30	29,79	0,990	41,92	0,727
I4	9,36	22,55	0,994	35,83	0,716
I5	14,89	20,85	0,990	37,71	0,822

Media	15,83	26,89	0,990	39,95	0,736
-------	-------	-------	-------	-------	-------

Tabla 5.16: Resultados de la Optimización 2 (Neuronas=1) de HC.

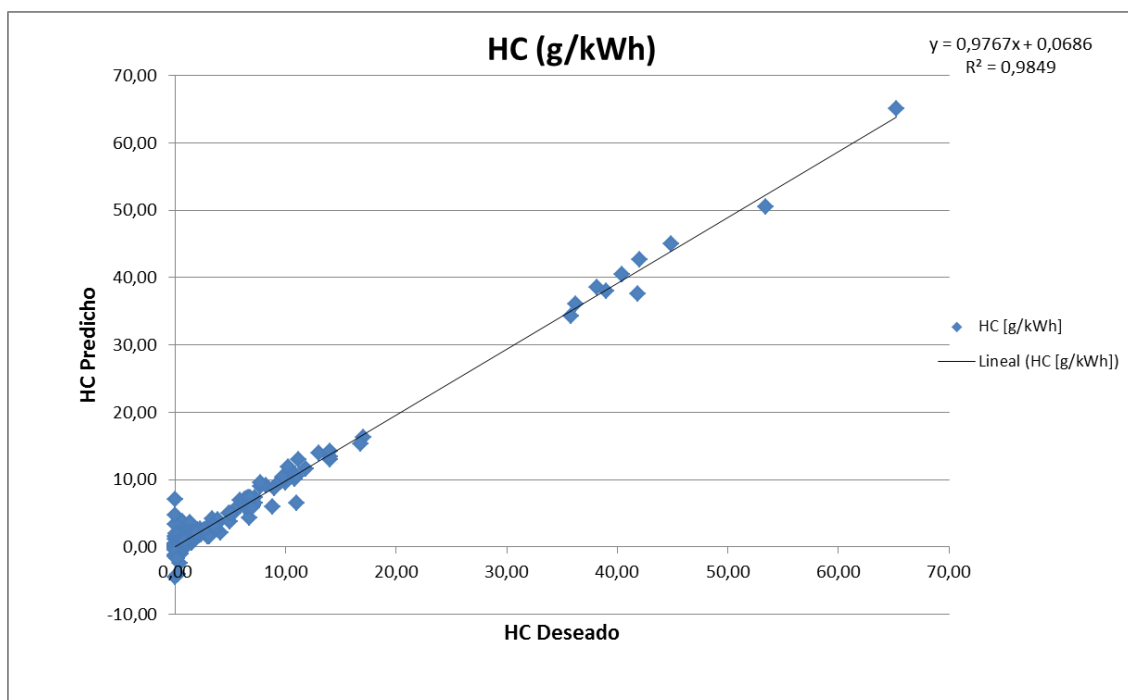


Figura 5.13: Resumen de las predicciones de HC para Optimización 2 (Neuronas=10).

Análisis de resultados

Al comparar esta predicción con su homóloga de mejor calidad hasta el momento, se observa que presenta una ligera mejoría además de una leve reducción de la media del error absoluto. Sin embargo su mejor predicción es superada por las dos mejores predicciones de la RNA optimizada (Mu=1), y el ligero empeoramiento de los promedios de calidad y del error absoluto se justifica en la presencia de una mala inicialización que influye en valores medios. Como está siendo habitual se observan predicciones negativas y peores ajustes en la predicción de valores nulos.

Predicciones CO₂

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	55,74	69,36	0,967	70,07	38,62
I2	68,09	75,32	0,982	77,79	24,25
I3	64,68	72,77	0,979	75,41	27,41
I4	63,40	71,91	0,985	74,73	28,11
I5	56,17	71,49	0,977	71,15	31,88
Media	61,62	72,17	0,978	73,83	30,05

Tabla 5.17: Resultados de la Optimización 2 (Neuronas=1) de CO₂.




Figura 5.14: Resumen de las predicciones de CO₂ para Optimización 2 (Neuronas=10).

Análisis de resultados

Esta predicción no representa ninguna mejora respecto a la RNA base (la mejor predicción de este contaminante hasta el momento), tanto su mejor inicialización como el promedio de ellas presentan factores de calidad inferiores. Además, el promedio del error absoluto también empeora y se mantienen las dificultades en la predicción de valores nulos y muy próximos a cero.

Conclusiones de la optimización (Neuronas =10)

	NOx	CO	HC	CO ₂
Mejor RNA	48,15(RNA base)	46,64(Opt.1)	39,49(Opt.1)	74,64(RNA base)
Opt. 2 (Neu=10)	46,53	46,07	39,95	73,83

Tabla 5.18: Comparativa de la calidad media de la mejor RNA hasta el momento y la optimización 2 (Neuronas=10)

Tras esta optimización no se han producidos cambios significativos en ninguna de las cuatro RNA, por lo tanto se puede afirmar que el variar el número de neuronas no ha influenciado de manera notoria en los resultados. En ningún de las RNA se ha considerado implementar esta optimización, pues no ha supuesto una mejora evidente.

5.9 OPTIMIZACIÓN 3: VARIACION DEL PREPROCESADO DE PATRONES.

Con el fin de seguir optimizando las RNA se va a proceder a una variación en el preprocesado de los patrones. Un problema importante que se está observando en las sucesivas predicciones es la presencia de valores negativos en las mismas. Una solución, que indica la bibliografía seguida, es cambiar la escala de los patrones de entrenamiento de lineal a logarítmica. Por lo que añadiremos esta técnica al preprocesado ya comentado al principio de la sección. Para realizarlo de forma correcta se tiene que realizar previamente una transformación lineal que garantice que todos los patrones tienen un valor superior a la unidad. Con este fin, teniendo en cuenta la presencia de valores nulos entre los patrones de entrenamiento, ha sido necesario sumar el valor 2 a todos los patrones. Se ha elegido este número porque es el entero inmediatamente superior a 1.

Al igual que con la normalización de los datos, para obtener las predicciones en la escala original es necesario deshacer los cambios.

Predicciones NOx

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	26,81	48,09	0,953	50,32	0,655
I2	30,64	52,34	0,965	53,62	0,564
I3	31,06	53,62	0,968	54,26	0,559
I4	32,34	53,19	0,949	54,24	0,609
I5	28,09	55,32	0,968	53,44	0,527

Media	27,79	52,51	0,961	53,17	0,583
-------	-------	-------	-------	-------	-------

Tabla 5.19: Resultados de la Optimización 3 (Escala logarítmica) de NOx.




Figura 5.15: Resumen de las predicciones de NOx para la Optimización 3 (Escala logarítmica).

Análisis de resultados

Esta optimización presenta una mejora considerable en la calidad de las predicciones de este contaminante. Todas las inicializaciones presentan valores más elevados del factor de calidad que la mejor predicción anterior a esta optimización y el promedio del error absoluto también mejora. Además se ha mostrado efectiva evitando las predicciones negativas.

Predicciones CO

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	31,91	47,23	0,994	53,38	7,35
I2	42,55	62,13	0,997	62,71	5,38
I3	36,60	53,62	0,973	56,88	10,56
I4	34,04	56,60	0,994	57,15	6,86
I5	31,06	53,19	0,995	54,81	7,21

Media	35,232	54,55	0,991	56,99	7,47
-------	--------	-------	-------	-------	------

Tabla 5.20: Resultados de la Optimización 3 (Escala logarítmica) de CO

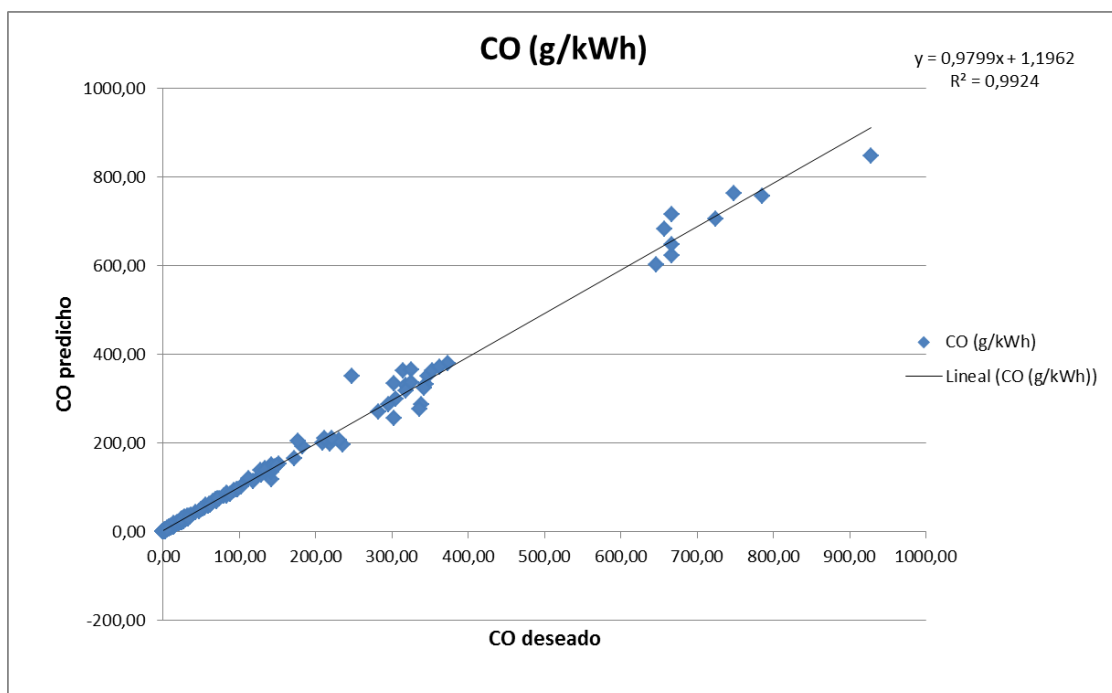


Figura 5.16: Resumen de las predicciones de CO para la Optimización 3 (Escala logarítmica).

Análisis de resultados

Los resultados obtenidos para este contaminante son bastante buenos. Se ha mejorado el factor de calidad de la mejor predicción en más de doce puntos y como en el caso anterior, todas las inicializaciones de este entrenamiento superan a esa mejor predicción de la RNA Opt.1. Además el promedio del error absoluto también muestra una mejora

considerable y las predicciones negativas aunque se mantienen en algunos casos, consecuencia de deshacer la transformación lineal, estas predicciones mejoran notablemente.

Predicciones HC

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	27,23	44,26	0,990	50,28	0,536
I2	28,09	45,11	0,998	51,12	0,289
I3	19,57	41,70	0,990	46,07	0,469
I4	24,68	45,53	0,998	49,72	0,307
I5	31,06	46,81	0,997	52,95	0,324

Media	26,13	44,68	0,995	50,03	0,385
-------	-------	-------	-------	-------	-------

Tabla 5.21: Resultados de la Optimización 3 (Escala logarítmica) de HC.




Figura 5.17: Resumen de las predicciones de NOx para la Optimización 3 (Escala logarítmica).

Análisis de resultados

Esta optimización también presenta una gran mejora en este contaminante logrando aumentar en más de nueve puntos el factor de calidad de la mejor inicialización anterior (Opt.1.) y en más de diez el promedio de las inicializaciones. El promedio del error absoluto también desciende a la mitad y en cuanto a las predicciones negativas se observa una importante mejoría. Las que persisten es por lo anteriormente comentado.

Predicciones CO₂

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	40,85	57,02	0,657	51,91	141,66
I2	32,34	57,45	0,956	55,69	56,19
I3	42,13	55,32	0,895	57,93	71,53
I4	34,89	53,19	0,851	52,93	88,84
I5	42,13	57,02	0,929	59,29	64,95

Media	38,47	56,00	0,858	55,55	84,63
-------	-------	-------	-------	-------	-------

Tabla 5.22: Resultados de la Optimización 3 (Escala logarítmica) de CO₂.

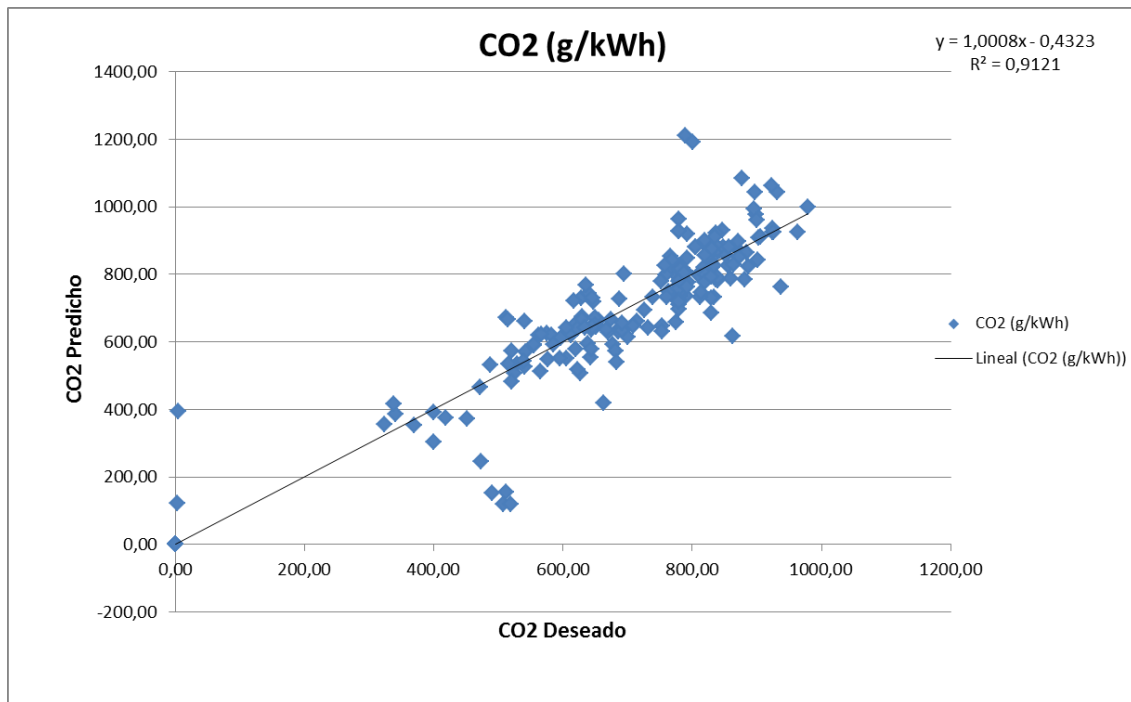


Figura 5.18: Resumen de las predicciones de CO₂ para la Optimización 3 (Escala logarítmica).

Análisis de resultados

Al contrario que en las demás predicciones, las de este contaminante muestran un empeoramiento bastante grande respecto a la RNA base (la mejor predicción hasta el momento). En el promedio de las inicializaciones el factor de calidad desciende en casi veinte puntos y la mejor predicción también empeora de forma considerable. Coherentemente con todo esto el promedio del error absoluto empeora de forma importante. Como efecto positivo las predicciones negativas siguen con la tendencia de esta optimización.

Conclusiones de la optimización (Preprocesado escala logarítmica)

	NOx	CO	HC	CO ₂
Mejor RNA	48,15(RNA base)	46,64(Opt.1)	39,49(Opt.1)	74,64(RNA base)
Opt. 3 (Esc: Log)	54,26	56,99	50,03	55,55

Tabla 5.23: Comparativa de la calidad media de la mejor RNA hasta el momento y la optimización 3 (Escala logarítmica)

Para todas las emisiones salvo la de CO₂ esta optimización presenta mejoras importantes. El hecho de que la predicción de CO₂ empeore también, de forma considerable, se justifica en que la escala logarítmica produce predicciones bastante buenas para valores numéricos bajos, de lo que se benefician las RNA de NOx, CO y HC, pero por el contrario a la hora de predecir valores numéricos altos como en el caso del CO₂ se muestra bastante ineficaz pues cualquier pequeña imprecisión en la escala logarítmica conlleva una importante variación en los valores reales.

Por consiguiente esta optimización se implementara en las RNA de NOx, CO y HC.

5.10 OPTIMIZACIÓN 4: VARIACIÓN DE LOS PARÁMETROS DE ENTRADA.

Como último factor a considerar en la optimización de las RNA se procederá a variar los patrones de entrada. Esta variación consiste en reducir el número entradas de la RNA eliminando las variables que se pueden obtener de forma indirecta, de forma que no exista información redundante que podría afectar de forma negativa al entrenamiento de las RNA. La eliminación de estas variables dejara la RNA con dieciséis entradas.

Las variables que van a ser eliminadas son: r_c , par , C_m , λ , M_f , Ma y V_T .

Predicciones NOx

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	26,38	44,68	0,922	48,33	0,817
I2	32,77	53,19	0,948	54,40	0,657
I3	25,11	46,38	0,879	47,19	0,890
I4	27,23	44,68	0,948	49,36	0,707
I5	32,77	50,64	0,950	53,69	0,645

Media	28,85	47,91	0,929	50,95	0,743
-------	-------	-------	-------	-------	-------

Tabla 5.24: Resultados de la Optimización 4 (Entradas= 16) de NOx.




Figura 5.19: Resumen de las predicciones de NOx para la Optimización 4 (Entradas=16).

Análisis de resultados

La optimización no ha provocado mejoras de las predicciones, de hecho tanto el factor de calidad de la mejor inicialización como su promedio han reducido su valor y el promedio de los errores absolutos ha empeorado.

Predicciones CO

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	31,91	50,64	0,992	54,352	8,00
I2	29,79	49,36	0,995	53,09	8,04
I3	32,77	52,34	0,990	55,12	9,22
I4	34,04	56,60	0,991	57,07	7,81
I5	27,23	49,79	0,982	51,74	11,25

Media	31,15	51,75	0,990	54,29	8,86
-------	-------	-------	-------	-------	------

Tabla 5.25: Resultados de la Optimización 4 (Entradas= 16) de CO.




Figura 5.20: Resumen de las predicciones de CO para la Optimización 4 (Entradas=16).

Análisis de resultados

Para este contaminante se ha producido un descenso de la calidad respecto a su homóloga anterior. El promedio del factor de calidad ha disminuido y ninguna

inicialización se ha acercado al valor de la mejor de la anterior RNA. El valor promedio del error absoluto ha aumentado influenciado por todo lo anterior.

Predicciones HC

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	24,26	39,15	0,998	47,61	0,331
I2	25,53	40,85	0,994	48,59	0,458
I3	25,11	41,28	0,997	48,61	0,377
I4	27,66	44,68	0,998	50,8	0,316
I5	23,40	42,55	0,998	48,25	0,326

Media	25,19	41,70	0,997	48,77	0,362
-------	-------	-------	-------	-------	-------

Tabla 5.26: Resultados de la Optimización 4 (Entradas= 16) de HC.




Figura 5.21: Resumen de las predicciones de HC para la Optimización 4 (Entradas=16).

Análisis de resultados

Para este tipo de emisiones se produce un ligero empeoramiento del facto de calidad en las inicializaciones tanto en la mejor como en el promedio. Por el contrario la media de los errores absolutos mejora de forma sutil.

Predicciones CO₂

Inicializaciones	A5%	A10%	R	Q (Calidad)	Error Absoluto
I1	66,81	72,77	0,987	76,57	24,66
I2	63,40	69,79	0,970	73,72	33,28
I3	62,98	73,19	0,969	74,52	30,73
I4	65,11	73,62	0,988	76,09	23,97
I5	65,11	71,49	0,976	75,15	29,81

Media	54,68	72,17	0,978	75,21	28,49
-------	-------	-------	-------	-------	-------

Tabla 5.27: Resultados de la Optimización 4 (Entradas= 16) de CO₂.




Figura 5.22: Resumen de las predicciones de CO₂ para la Optimización 4 (Entradas=16).

Análisis de resultados

Los resultados muestran bastante similitud con la mejor RNA para este contaminante (RNA base). El factor de calidad promedio mejora ligeramente gracias a una menor variabilidad de las inicializaciones y el promedio del error absoluto también se reduce aunque de forma marginal. No obstante la RNA base sigue teniendo la inicialización con el mayor factor de calidad. La no implementación de la mejora anterior provoca que vuelva a tener dificultad en la predicción de los valores nulos.

Conclusiones de la optimización (Entradas=16)

	NOx	CO	HC	CO ₂
Mejor RNA	54,26 (Opt.3)	56,99 (Opt.3)	50,03 (Opt.3)	74,64(RNA base)
Opt. 3 (Entr=16)	50,95	54,29	48,77	75,21

Tabla 5.28: Comparativa de la calidad media de la mejor RNA hasta el momento y la optimización 4 (Entradas= 16)

Para las emisiones de NOx, CO y HC esta optimización presenta peores resultados de forma clara. En el caso del CO₂ aunque presenta una ligera mejora de la calidad media respecto a la RNA base, por su menor variabilidad, ninguna de sus inicializaciones consigue superar la calidad de la mejor inicialización de la RNA inicial. En general esta optimización no ha mejorado las predicciones, dado que en el mejor de los casos (CO₂), no ha supuesto un avance claro y en los demás ha supuesto un empeoramiento evidente.

5.11 TABLA-RESUMEN DE LAS RNA FINALES

A continuación se presenta Tabla 5.29 con todas las características de las RNA finales:

Características	NOx	CO	HC	CO ₂
Entradas (n°)	combustibles, n, η_{ef} , carga, g_{ef} , rc, Ne, pme, Cm, F, λ , Mf, Ma, η_{vol} , V_T , z, S/D (23)			
Preprocesado	Normalización [-1,1] y escala logarítmica			Normalización [-1,1]
Arquitectura	Perceptrón Multicapa			
Capas ocultas	1			
Neuronas (capa oculta)	23			
Funciones de activación	Sigmoide binaria / Lineal			
Algoritmo de entrenamiento	Levenberg- Marquardt			
Parámetros del Algoritmo	$\mu_{in}=0.001$ $\mu_{inc}=10$ $\mu_{dec}=0.1$	$\mu_{in}=1$ $\mu_{inc}=10$ $\mu_{dec}=0.1$	$\mu_{in}=1$ $\mu_{inc}=10$ $\mu_{dec}=0.1$	$\mu_{in}=0.001$, $\mu_{inc}=10$ $\mu_{dec}=0.1$
Inicialización	Aleatoria entre [-1,1]			
Actualización de pesos	Batch			
Función del error	MSE			

Tabla 5.29: Características de las RNA optimizadas.

6. CONCLUSIÓN

La Figura 5.23 muestra la evolución seguida por las diferentes RNA al realizarles las sucesivas optimizaciones.

La red neuronal que más ha mejorado ha sido la de CO con un incremento de la calidad superior al 39%, seguida por la RNA de HC que ha mejorado su calidad un 34%. Por otro lado la RNA de NOx ha experimentado una mejora mucho más reducida, del 10.4%, no obstante partía de una calidad superior al de los anteriores contaminantes. Para el caso de la RNA de CO₂, las consecutivas optimizaciones no se han traducido en mejora alguna, si bien, hay que tener en cuenta que la calidad inicial de este tipo de emisiones presentaba un valor muy elevado.

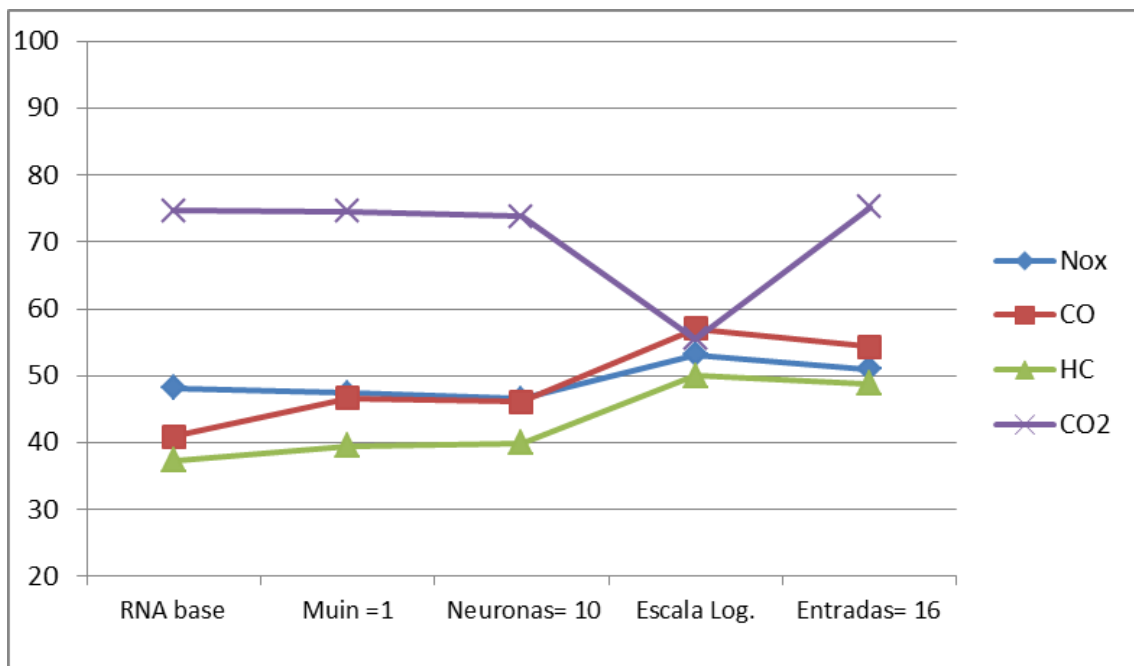


Figura 6.1: Evolución de la calidad media de las RNA.

En cuanto a las optimizaciones, la introducción de la escala logarítmica en el preprocesado ha sido la que mayores mejoras ha supuesto, salvo en el caso del CO₂. La variación del parámetro de regulación (μ_{in} o Mu_{in}) también ha supuesto un aumento de la calidad de las RNA para las emisiones de CO y HC. Por otra parte las optimizaciones en las que se ha variado el número de neuronas y el número de parámetros de entrada no han supuesto en ningún caso una mejora.

El problema de hallar el número óptimo de neuronas en cada RNA requiere de un coste temporal demasiado elevado para un TFG, de todos modos tras observar los resultados de la variación del número de neuronas se puede concluir que en estas RNA su influencia ha sido limitada pues presentan predicciones similares que en ningún momento han supuesto cambios reseñables ni positivos ni negativos. La optimización de los parámetros de entrada presenta el mismo problema pues serían necesarios multitud de entrenamientos con el fin de encontrar el conjunto de entradas óptimas para cada RNA, en este caso la variación de los parámetros de entrada si ha demostrado una

influencia negativa para todas las RNA salvo la del CO₂, que apenas ha variado respecto a su mejor RNA.

De todos modos, teniendo en cuenta el alcance de este trabajo, se puede decir que el resultado ha sido satisfactorio pues la calidad final de las RNA para los distintos contaminantes es similar a la alcanzada en la bibliografía principal que ha inspirado la metodología seguida. Los modelos finales de RNA son capaces de evaluar de forma eficaz las emisiones producidas por las diferentes mezclas y combustibles alternativos y ofrecen la posibilidad de conocer cuál sería el combustible menos contaminante para unas condiciones específicas de funcionamiento.

Las posibilidades de continuación y ampliación de este trabajo son grandes y podrían estar encaminadas a un estudio más específico y profundo de las optimizaciones que no han mejorado las RNA, así como optimizaciones complementarias o una ampliación de los patrones de entrenamiento con el fin de mostrar todo el potencial de esta herramienta en la predicción de emisiones para diferentes mezclas de combustibles y parámetros operativos del motor.

7. ANEXO A: SCRIPT DE LAS RNA EN MATLAB

7.1. PREPROCESADO RNA NO_x

```
% Script base para el desarrollo de la red neuronal de predicción de
% las emisiones de NOx.

% 1) Trasposición de los datos de entrada para que sean leídos
correctamente
% por el programa.

E1=E1'
SE1_NOx=SE1_NOx'
VT1=VT1'
SVT1_NOx=SVT1_NOx'
E2=E2'
SE2_NOx=SE2_NOx'
VT2=VT2'
SVT2_NOx=SVT2_NOx'
E3=E3'
SE3_NOx=SE3_NOx'
VT3=VT3'
SVT3_NOx=SVT3_NOx'
E4=E4'
SE4_NOx=SE4_NOx'
VT4=VT4'
SVT4_NOx=SVT4_NOx'

%Preprocesado de los datos que consiste en una normalización.

[E1N,minE1,maxE1,SE1_NOxN,minSE1_NOx,maxSE1_NOx] = premnmx(E1,SE1_NOx)
[E2N] = tramnmx(E2,minE1,maxE1)
[E3N] = tramnmx(E3,minE1,maxE1)
[E4N] = tramnmx(E4,minE1,maxE1)
[VT1N] = tramnmx(VT1,minE1,maxE1)
[VT2N] = tramnmx(VT2,minE1,maxE1)
[VT3N] = tramnmx(VT3,minE1,maxE1)
[VT4N] = tramnmx(VT4,minE1,maxE1)
[SE2_NOxN] = tramnmx(SE2_NOx,minSE1_NOx,maxSE1_NOx)
[SE3_NOxN] = tramnmx(SE3_NOx,minSE1_NOx,maxSE1_NOx)
[SE4_NOxN] = tramnmx(SE4_NOx,minSE1_NOx,maxSE1_NOx)
[SVT1_NOxN] = tramnmx(SVT1_NOx,minSE1_NOx,maxSE1_NOx)
[SVT2_NOxN] = tramnmx(SVT2_NOx,minSE1_NOx,maxSE1_NOx)
[SVT3_NOxN] = tramnmx(SVT3_NOx,minSE1_NOx,maxSE1_NOx)
[SVT4_NOxN] = tramnmx(SVT4_NOx,minSE1_NOx,maxSE1_NOx)

%Ahora se procede a diseñar y entrenar la red con la GUI de MATLAB
%para redes neuronales artificiales.

nntool
```

7.2. PREPROCESADO RNA CO

```
% Script base para el desarrollo de la red neuronal de predicción de  
% las emisiones de NOx.
```

```
% 1) Trasposición de los datos de entrada para que sean leídos  
% correctamente por el programa.
```

```
E1=E1 '  
SE1_CO=SE1_CO '  
VT1=VT1 '
```

```
E2=E2 '  
SE2_CO=SE2_CO '  
VT2=VT2 '
```

```
E3=E3 '  
SE3_CO=SE3_CO '  
VT3=VT3 '
```

```
E4=E4 '  
SE4_CO=SE4_CO '  
VT4=VT4 '
```

```
%Preprocesado de los datos que consiste en una normalización.
```

```
[E1N,minE1,maxE1,SE1_CON,minSE1_CO,maxSE1_CO] = premmx(E1,SE1_CO)  
[E2N] = tramnmx(E2,minE1,maxE1)  
[E3N] = tramnmx(E3,minE1,maxE1)  
[E4N] = tramnmx(E4,minE1,maxE1)  
[VT1N] = tramnmx(VT1,minE1,maxE1)  
[VT2N] = tramnmx(VT2,minE1,maxE1)  
[VT3N] = tramnmx(VT3,minE1,maxE1)  
[VT4N] = tramnmx(VT4,minE1,maxE1)  
[SE2_CON] = tramnmx(SE2_CO,minSE1_CO,maxSE1_CO)  
[SE3_CON] = tramnmx(SE3_CO,minSE1_CO,maxSE1_CO)  
[SE4_CON] = tramnmx(SE4_CO,minSE1_CO,maxSE1_CO)
```

```
%Ahora se procede a diseñar y entrenar la red con la GUI de MATLAB  
%para redes neuronales artificiales.
```

```
nntool
```

7.3. PREPROCESADO RNA HC

```
% Script base para el desarrollo de la red neuronal de predicción de  
% las emisiones de NOx.
```

```
% 1) Transposición de los datos de entrada para que sean leídos  
% correctamente por el programa.
```

```
E1=E1'  
SE1_HC=SE1_HC'  
VT1=VT1'
```

```
E2=E2'  
SE2_HC=SE2_HC'  
VT2=VT2'
```

```
E3=E3'  
SE3_HC=SE3_HC'  
VT3=VT3'
```

```
E4=E4'  
SE4_HC=SE4_HC'  
VT4=VT4'
```

```
% Preprocesado de los datos que consiste en una normalización.
```

```
[E1N,minE1,maxE1,SE1_HCN,minSE1_HC,maxSE1_HC] = premnmx(E1,SE1_HC)  
[E2N] = tramnmx(E2,minE1,maxE1)  
[E3N] = tramnmx(E3,minE1,maxE1)  
[E4N] = tramnmx(E4,minE1,maxE1)  
[VT1N] = tramnmx(VT1,minE1,maxE1)  
[VT2N] = tramnmx(VT2,minE1,maxE1)  
[VT3N] = tramnmx(VT3,minE1,maxE1)  
[VT4N] = tramnmx(VT4,minE1,maxE1)  
[SE2_HCN] = tramnmx(SE2_HC,minSE1_HC,maxSE1_HC)  
[SE3_HCN] = tramnmx(SE3_HC,minSE1_HC,maxSE1_HC)  
[SE4_HCN] = tramnmx(SE4_HC,minSE1_HC,maxSE1_HC)
```

```
% Ahora se procede a diseñar y entrenar la red con la GUI de MATLAB  
% para redes neuronales artificiales.
```

```
nntool
```

7.4. PREPROCESADO RNA CO₂

```
%Script base para el desarrollo de la red neuronal de predicción de  
%las emisiones de NOx.
```

```
%1) Trasposición de los datos de entrada para que sean leídos  
%correctamente por el programa.
```

```
E1=E1'  
SE1_CO2=SE1_CO2'  
VT1=VT1'
```

```
E2=E2'  
SE2_CO2=SE2_CO2'  
VT2=VT2'
```

```
E3=E3'  
SE3_CO2=SE3_CO2'  
VT3=VT3'
```

```
E4=E4'  
SE4_CO2=SE4_CO2'  
VT4=VT4'
```

```
%Preprocesado de los datos que consiste en una normalización.
```

```
[E1N,minE1,maxE1,SE1_CO2N,minSE1_CO2,maxSE1_CO2] = prenmnx(E1,SE1_CO2)  
[E2N] = tramnmnx(E2,minE1,maxE1)  
[E3N] = tramnmnx(E3,minE1,maxE1)  
[E4N] = tramnmnx(E4,minE1,maxE1)  
[VT1N] = tramnmnx(VT1,minE1,maxE1)  
[VT2N] = tramnmnx(VT2,minE1,maxE1)  
[VT3N] = tramnmnx(VT3,minE1,maxE1)  
[VT4N] = tramnmnx(VT4,minE1,maxE1)  
[SE2_CO2N] = tramnmnx(SE2_CO2,minSE1_CO2,maxSE1_CO2)  
[SE3_CO2N] = tramnmnx(SE3_CO2,minSE1_CO2,maxSE1_CO2)  
[SE4_CO2N] = tramnmnx(SE4_CO2,minSE1_CO2,maxSE1_CO2)
```

```
%Ahora se procede a diseñar y entrenar la red con la GUI de MATLAB  
%para redes neuronales artificiales.
```

```
nntool
```


7.5. EJEMPLO DE POSTPROCESADO DE LAS RNA (SIMILAR EN TODAS)

`%Postprocesado de la RNA ya entrenada.`

```
>> [PrediccionesOP1I1E2] =postmnmx(I1E2NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I1E3] =postmnmx(I1E3NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I1E4] =postmnmx(I1E4NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I2E1] =postmnmx(I2E1NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I2E2] =postmnmx(I2E2NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I2E3] =postmnmx(I2E3NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I2E4] =postmnmx(I2E4NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I3E1] =postmnmx(I3E1NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I3E2] =postmnmx(I3E2NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I3E3] =postmnmx(I3E3NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I3E4] =postmnmx(I3E4NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I4E1] =postmnmx(I4E1NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I4E2] =postmnmx(I4E2NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I4E3] =postmnmx(I4E3NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I4E4] =postmnmx(I4E4NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I5E1] =postmnmx(I5E1NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I5E2] =postmnmx(I5E2NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I5E3] =postmnmx(I5E3NOxOP1Predic,minSE1_NOx,maxSE1_NOx);  
>> [PrediccionesOP1I5E4] =postmnmx(I5E4NOxOP1Predic,minSE1_NOx,maxSE1_NOx);
```

`%Transposición delos resultados de las predicciones a su forma
%original.`

```
>> PrediccionesOP1I1E1=PrediccionesOP1I1E1';  
>> PrediccionesOP1I1E2=PrediccionesOP1I1E2';  
>> PrediccionesOP1I1E3=PrediccionesOP1I1E3';  
>> PrediccionesOP1I1E4=PrediccionesOP1I1E4';  
>> PrediccionesOP1I2E1=PrediccionesOP1I2E1';  
>> PrediccionesOP1I2E2=PrediccionesOP1I2E2';  
>> PrediccionesOP1I2E3=PrediccionesOP1I2E3';  
>> PrediccionesOP1I2E4=PrediccionesOP1I2E4';  
>> PrediccionesOP1I3E1=PrediccionesOP1I3E1';  
>> PrediccionesOP1I3E2=PrediccionesOP1I3E2';  
>> PrediccionesOP1I3E3=PrediccionesOP1I3E3';  
>> PrediccionesOP1I3E4=PrediccionesOP1I3E4';  
>> PrediccionesOP1I4E1=PrediccionesOP1I4E1';  
>> PrediccionesOP1I4E2=PrediccionesOP1I4E2';  
>> PrediccionesOP1I4E3=PrediccionesOP1I4E3';  
>> PrediccionesOP1I4E4=PrediccionesOP1I4E4';  
>> PrediccionesOP1I5E1=PrediccionesOP1I5E1';  
>> PrediccionesOP1I5E2=PrediccionesOP1I5E2';  
>> PrediccionesOP1I5E3=PrediccionesOP1I5E3';  
>> PrediccionesOP1I5E4=PrediccionesOP1I5E4';
```

8. ANEXO B: Fase 1 + Fase 2 de los entrenamientos

8.1. RNA BASE NO_x

		Error val min	Error Val Global	0,00841			
1	E1	0,00443	Error de Parada	0,00673			
2	E2	0,0137					
3	E3	0,00606					
4	E4	0,00845					
5	E1	0,00598					
6	E2	0,00292	Inicialización	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
7	E3	0,00148	1 E1	0,00673	0,00654	6	0,93692
8	E4	0,0000262	1 E2	0,00673	0,00717	3	0,96523
9	E1	0,0338	1 E3	0,00673	0,00651	1	0,97337
10	E2	0,00235	1 E4	0,00673	0,00523	1	0,97697
11	E3	0,00239	2 E1	0,00673	0,00333	8	0,95412
12	E4	0,0216	2 E2	0,00673	0,0079	4	0,96802
13	E1	0,00000984	2 E3	0,00673	0,00746	2	0,97126
14	E2	0,0044	2 E4	0,00673	0,0055	1	0,97367
15	E3	0,00749	3 E1	0,00673	0,00793	7	0,95762
16	E4	0,0043	3 E2	0,00673	0,0035	3	0,96295
17	E1	0,0012	3 E3	0,00673	0,00408	1	0,97146
18	E2	0,00199	3 E4	0,00673	0,00141	2	0,97631
19	E3	0,00738	4 E1	0,00673	0,00588	8	0,95407
20	E4	0,000871	4 E2	0,00673	0,00665	2	0,97628
21	E1	0,00105	4 E3	0,00673	0,00747	1	0,9783
22	E2	0,00974	4 E4	0,00673	0,0057	1	0,98192
23	E3	0,0215	5 E1	0,00673	0,00641	8	0,94514
24	E4	0,00855	5 E2	0,00673	0,0083	4	0,96597
25	E1	0,023	5 E3	0,00673	0,00443	2	0,97757
26	E2	0,00122	5 E4	0,00673	0,00365	1	0,98778
27	E3	0,00989					
28	E4	0,00295					
29	E1	0,00115					
30	E2	0,00829					
31	E3	0,0022					
32	E4	0,0344					
33	E1	0,000591					
34	E2	0,000277					
35	E3	0,00372					
36	E4	0,00126					
37	E1	0,0104					
38	E2	0,00786					
39	E3	0,0554					
40	E4	0,00213					

Figura 8.1: Resultados del entrenamiento Fase 1 + Fase 2 para la RNA base NO_x.

8.2. RNA BASE CO

		Error val min		Error Val Global	0,00226			
1	E1	0,00274		Error de Parada	0,00181			
2	E2	0,00000155						
3	E3	0,000174						
4	E4	0,000407						
5	E1	0,00000866						
6	E2	0,00168	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
7	E3	0,0000495	1	E1	0,00181	0,00294	5	0,99233
8	E4	0,000395	1	E2	0,00181	0,00185	1	0,99555
9	E1	0,00775	1	E3	0,00181	0,0000839	2	0,99522
10	E2	0,00552	1	E4	0,00181	0,00192	1	0,99175
11	E3	0,000249	2	E1	0,00181	0,000952	6	0,99301
12	E4	0,00634	2	E2	0,00181	0,00191	1	0,99269
13	E1	0,000681	2	E3	0,00181	0,00033	1	0,9971
14	E2	0,0103	2	E4	0,00181	0,00135	0	0,99575
15	E3	0,0000207	3	E1	0,00181	0,00151	5	0,98711
16	E4	0,00384	3	E2	0,00181	0,00045	2	0,99636
17	E1	0,000593	3	E3	0,00181	0,00262	1	0,99472
18	E2	0,00178	3	E4	0,00181	0,00243	1	0,99398
19	E3	0,000105	4	E1	0,00181	0,00167	4	0,98973
20	E4	0,00000698	4	E2	0,00181	0,00125	1	0,99401
21	E1	0,00146	4	E3	0,00181	0,00185	1	0,9946
22	E2	0,00155	4	E4	0,00181	0,00205	1	0,99638
23	E3	0,000114	5	E1	0,00181	0,000557	10	0,99502
24	E4	0,00359	5	E2	0,00181	0,00272	1	0,99505
25	E1	0,000773	5	E3	0,00181	0,000447	1	0,99761
26	E2	0,000651	5	E4	0,00181	0,000536	0	0,99715
27	E3	0,000054						
28	E4	0,00135						
29	E1	0,00014						
30	E2	0,0268						
31	E3	0,00356						
32	E4	0,000107						
33	E1	0,0000168						
34	E2	0,000495						
35	E3	0,0051						
36	E4	0,0000202						
37	E1	0,00000656						
38	E2	0,000584						
39	E3	0,00000243						
40	E4	0,00124						

Figura 8.2: Resultados del entrenamiento Fase 1 + Fase 2 para la RNA base CO.

8.3. RNA BASE HC

		Error val min		Error Val Global	0,00295			
1	E1	0,000101		Error de Parada	0,00236			
2	E2	0,0000214						
3	E3	0,00000694						
4	E4	0,0081						
5	E1	0,0000678						
6	E2	0,00502	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
7	E3	0,000463	1	E1	0,00236	0,000495	5	0,99035
8	E4	0,00000195	1	E2	0,00236	0,000309	1	0,99667
9	E1	0,0000085	1	E3	0,00236	0,00193	0	0,99246
10	E2	0,0000265	1	E4	0,00236	0,00197	0	0,99193
11	E3	0,000125	2	E1	0,00236	0,00112	3	0,95307
12	E4	0,00000689	2	E2	0,00236	0,00214	1	0,98526
13	E1	0,000778	2	E3	0,00236	0,00128	1	0,98933
14	E2	9,26E-06	2	E4	0,00236	0,00306	1	0,99032
15	E3	3,57E-06	3	E1	0,00236	0,00218	3	0,96526
16	E4	2,60E-06	3	E2	0,00236	0,000558	1	0,99462
17	E1	2,26E-05	3	E3	0,00236	0,00111	0	0,99396
18	E2	0,000655	3	E4	0,00236	0,00103	0	0,99482
19	E3	0,00513	4	E1	0,00236	0,000423	4	0,9453
20	E4	4,15E-07	4	E2	0,00236	0,00264	1	0,98016
21	E1	1,47E-05	4	E3	0,00236	0,00196	1	0,97652
22	E2	0,000163	4	E4	0,00236	0,00147	1	0,99153
23	E3	0,00642	5	E1	0,00236	0,00195	9	0,98594
24	E4	0,000243	5	E2	0,00236	0,000747	1	0,99491
25	E1	5,80E-08	5	E3	0,00236	0,000807	0	0,99539
26	E2	0,000884	5	E4	0,00236	0,000759	0	0,99553
27	E3	6,44E-06						
28	E4	1,16E-05						
29	E1	8,88E-07						
30	E2	0,000519						
31	E3	0,0496						
32	E4	3,37E-06						
33	E1	0,000631						
34	E2	0,0217						
35	E3	6,17E-05						
36	E4	0,00357						
37	E1	0,00464						
38	E2	0,00804						
39	E3	0,000795						
40	E4	1,07E-07						

Figura 8.3: Resultados del entrenamiento Fase 1 + Fase 2 para la RNA base HC.

8.4. RNA BASE CO₂

		Error val min		Error Val Global	0,01195			
				Error de Parada	0,00956			
1	E1	0,00294						
2	E2	0,0042						
3	E3	0,029						
4	E4	0,000164						
5	E1	5,22E-06						
6	E2	0,00551	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
7	E3	0,00933	1	E1	0,00956	0,00307	6	0,97927
8	E4	0,00522	1	E2	0,00956	0,0068	1	0,98847
9	E1	0,00657	1	E3	0,00956	0,00659	1	0,9824
10	E2	0,0109	1	E4	0,00956	0,00628	1	0,99137
11	E3	0,000164	2	E1	0,00956	0,00454	7	0,98399
12	E4	0,004	2	E2	0,00956	0,00357	1	0,97963
13	E1	0,00126	2	E3	0,00956	0,00695	1	0,9873
14	E2	0,000252	2	E4	0,00956	0,00802	1	0,99163
15	E3	0,00921	3	E1	0,00956	0,0015	5	0,98551
16	E4	0,013	3	E2	0,00956	0,00632	1	0,98892
17	E1	0,00591	3	E3	0,00956	0,00733	0	0,98869
18	E2	0,00178	3	E4	0,00956	0,00877	0	0,99121
19	E3	0,159	4	E1	0,00956	0,00442	4	0,98511
20	E4	0,00558	4	E2	0,00956	0,00806	1	0,98204
21	E1	0,0306	4	E3	0,00956	0,0056	1	0,98182
22	E2	0,000294	4	E4	0,00956	0,00815	2	0,99252
23	E3	0,0102	5	E1	0,00956	0,00564	5	0,98492
24	E4	0,00659	5	E2	0,00956	0,00951	0	0,98121
25	E1	0,00293	5	E3	0,00956	0,0115	2	0,98644
26	E2	0,00392	5	E4	0,00956	0,00738	1	0,98959
27	E3	0,00401						
28	E4	0,0341						
29	E1	7,49E-07						
30	E2	0,00712						
31	E3	0,02						
32	E4	0,00278						
33	E1	0,00091						
34	E2	0,00214						
35	E3	0,00738						
36	E4	0,00471						
37	E1	4,59E-08						
38	E2	0,0104						
39	E3	0,0424						
40	E4	0,0135						

Figura 8.4: Resultados del entrenamiento Fase 1 + Fase 2 para la RNA base CO₂.

8.5. OPTIMIZACIÓN 1 NO_x

		Error.val.min		Error Val Global	0,00912			
1	E1	0,0219		Error de Parada	0,00729			
2	E2	0,000873						
3	E3	0,000397						
4	E4	0,00633						
5	E1	0,00407						
6	E2	0,0223	Iniciación	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
7	E3	0,00382	1	E1	0,00729	0,00721	7	0,89874
8	E4	0,0452	1	E2	0,00729	0,0107	5	0,96582
9	E1	0,00313	1	E3	0,00729	0,00968	1	0,9629
10	E2	0,00254	1	E4	0,00729	0,00632	3	0,97359
11	E3	0,000577	2	E1	0,00729	0,00782	6	0,95389
12	E4	0,00392	2	E2	0,00729	0,0157	6	0,94956
13	E1	0,00076	2	E3	0,00729	0,0126	2	0,95617
14	E2	0,0255	2	E4	0,00729	0,0161	3	0,9668
15	E3	0,00394	3	E1	0,00729	0,00612	7	0,95874
16	E4	0,00205	3	E2	0,00729	0,0175	2	0,95486
17	E1	0,00429	3	E3	0,00729	0,00939	2	0,96538
18	E2	0,00919	3	E4	0,00729	0,0122	4	0,97483
19	E3	0,00784	4	E1	0,00729	0,00737	7	0,93549
20	E4	0,0436	4	E2	0,00729	0,0146	4	0,93824
21	E1	0,00424	4	E3	0,00729	0,014	3	0,92849
22	E2	0,0058	4	E4	0,00729	0,00771	5	0,97007
23	E3	0,000196	5	E1	0,00729	0,00602	6	0,94957
24	E4	0,00261	5	E2	0,00729	0,0136	5	0,91847
25	E1	0,0105	5	E3	0,00729	0,00647	3	0,97638
26	E2	0,00648	5	E4	0,00729	0,00787	1	0,97645
27	E3	0,00278						
28	E4	0,00535						
29	E1	0,00106						
30	E2	0,0106						
31	E3	0,00292						
32	E4	0,00609						
33	E1	0,00309						
34	E2	0,0161						
35	E3	0,0111						
36	E4	0,0142						
37	E1	0,0115						
38	E2	0,00592						
39	E3	0,0221						
40	E4	0,00984						

Figura 8.5: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 1 de NO_x.

8.6. OPTIMIZACIÓN 1 CO

		Error val min		Error Val Global	0,00047			
				Error de Parada	0,00038			
1	E1	1,16E-05						
2	E2	5,18E-05						
3	E3	0,000187						
4	E4	8,08E-04						
5	E1	7,15E-05						
			Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
6	E2	0,00172						
7	E3	0,00024	1	E1	0,00038	0,000287	4	0,99587
8	E4	0,000189	1	E2	0,00038	0,000536	2	0,99545
9	E1	0,00066	1	E3	0,00038	0,000259	2	0,99615
10	E2	0,000721	1	E4	0,00038	0,00068	2	0,99652
11	E3	0,000138	2	E1	0,00038	0,000369	5	0,99191
12	E4	5,93E-05	2	E2	0,00038	0,000541	3	0,99612
13	E1	0,00267	2	E3	0,00038	0,000822	5	0,99762
14	E2	0,0021	2	E4	0,00038	0,000313	1	0,99636
15	E3	0,000875	3	E1	0,00038	0,000156	4	0,99425
16	E4	0,00122	3	E2	0,00038	0,000592	2	0,99618
17	E1	0,000154	3	E3	0,00038	0,000711	2	0,99251
18	E2	0,000188	3	E4	0,00038	0,000292	3	0,99222
19	E3	1,86E-05	4	E1	0,00038	0,000255	5	0,99658
20	E4	1,68E-05	4	E2	0,00038	0,000416	3	0,99573
21	E1	0,000153	4	E3	0,00038	0,000398	2	0,99587
22	E2	0,000356	4	E4	0,00038	0,000793	3	0,99631
23	E3	0,00144	5	E1	0,00038	0,000409	7	0,99515
24	E4	0,000129	5	E2	0,00038	0,000555	4	0,99465
25	E1	9,06E-05	5	E3	0,00038	0,000898	2	0,99447
26	E2	8,16E-06	5	E4	0,00038	0,000622	2	0,99404
27	E3	9,70E-05						
28	E4	9,73E-05						
29	E1	3,13E-05						
30	E2	2,25E-05						
31	E3	0,000115						
32	E4	0,00228						
33	E1	0,000569						
34	E2	0,000361						
35	E3	9,20E-06						
36	E4	7,89E-05						
37	E1	1,76E-05						
38	E2	3,39E-05						
39	E3	0,000204						
40	E4	7,91E-04						

Figura 8.6: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 1 de CO.

8.7. OPTIMIZACIÓN 1 HC

		Error val. min	Error Val Global	0,00096				
1	E1	6,40E-04	Error de Parada	0,00077				
2	E2	9,24E-06						
3	E3	7,08E-06						
4	E4	2,57E-04						
5	E1	2,13E-03						
6	E2	0,00137	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento R	
7	E3	0,000202	1	E1	0,00077	0,000477	6	0,99519
8	E4	6,68E-05	1	E2	0,00077	0,000652	1	0,99421
9	E1	0,000166	1	E3	0,00077	0,00083	1	0,99594
10	E2	1,19E-05	1	E4	0,00077	0,000553	1	0,99693
11	E3	0,000215	2	E1	0,00077	0,000111	6	0,99145
12	E4	2,81E-04	2	E2	0,00077	0,000661	1	0,98142
13	E1	0,000201	2	E3	0,00077	0,000842	1	0,98419
14	E2	7,32E-05	2	E4	0,00077	0,000244	2	0,99756
15	E3	8,64E-06	3	E1	0,00077	0,000487	5	0,99218
16	E4	0,000106	3	E2	0,00077	0,000594	1	0,99622
17	E1	0,000293	3	E3	0,00077	0,000648	1	0,99592
18	E2	8,34E-06	3	E4	0,00077	0,000598	0	0,99537
19	E3	1,96E-04	4	E1	0,00077	0,000371	4	0,97509
20	E4	1,29E-04	4	E2	0,00077	0,000615	2	0,98269
21	E1	3,72E-05	4	E3	0,00077	0,000705	1	0,99486
22	E2	0,00101	4	E4	0,00077	0,000497	1	0,98898
23	E3	3,81E-05	5	E1	0,00077	0,000671	7	0,98756
24	E4	4,19E-05	5	E2	0,00077	0,00178	2	0,99126
25	E1	1,22E-02	5	E3	0,00077	0,000554	3	0,99203
26	E2	2,82E-04	5	E4	0,00077	0,000685	1	0,99348
27	E3	1,85E-03						
28	E4	2,16E-04						
29	E1	4,53E-05						
30	E2	7,09E-05						
31	E3	0,000598						
32	E4	0,00186						
33	E1	0,000142						
34	E2	0,000338						
35	E3	2,38E-05						
36	E4	9,74E-06						
37	E1	2,98E-04						
38	E2	5,77E-05						
39	E3	9,00E-06						
40	E4	1,29E-02						

Figura 8.7: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 1 de HC.

8.8. OPTIMIZACIÓN 1 CO₂

		Error val mín		Error Val Global	0,00813			
1	E1	8,48E-06		Error de Parada	0,00650			
2	E2	4,07E-04						
3	E3	1,27E-02						
4	E4	6,38E-03						
5	E1	7,97E-03						
6	E2	0,00773	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
7	E3	0,00585	1	E1	0,00650	0,00353	4	0,98924
8	E4	4,03E-02	1	E2	0,00650	0,00913	1	0,98734
9	E1	0,0131	1	E3	0,00650	0,00503	1	0,98695
10	E2	7,84E-06	1	E4	0,00650	0,00643	4	0,99176
11	E3	0,00703	2	E1	0,00650	0,00322	3	0,98521
12	E4	1,28E-04	2	E2	0,00650	0,00864	2	0,98581
13	E1	0,000346	2	E3	0,00650	0,00709	5	0,98841
14	E2	8,82E-06	2	E4	0,00650	0,00786	3	0,99053
15	E3	8,32E-03	3	E1	0,00650	0,00613	7	0,99048
16	E4	8,39E-06	3	E2	0,00650	0,00637	1	0,98985
17	E1	0,000115	3	E3	0,00650	0,0075	1	0,99086
18	E2	5,46E-03	3	E4	0,00650	0,00869	3	0,99051
19	E3	4,21E-05	4	E1	0,00650	0,000855	4	0,98681
20	E4	7,89E-04	4	E2	0,00650	0,00713	2	0,99018
21	E1	6,44E-03	4	E3	0,00650	0,00611	3	0,98794
22	E2	0,00468	4	E4	0,00650	0,00867	1	0,98812
23	E3	2,14E-02	5	E1	0,00650	0,0031	3	0,98716
24	E4	9,48E-03	5	E2	0,00650	0,00194	1	0,98097
25	E1	5,16E-03	5	E3	0,00650	0,00541	2	0,98713
26	E2	1,16E-02	5	E4	0,00650	0,00213	1	0,98958
27	E3	3,33E-02						
28	E4	1,99E-02						
29	E1	3,61E-05						
30	E2	6,48E-03						
31	E3	0,0077						
32	E4	0,000468						
33	E1	2,13E-05						
34	E2	8,11E-06						
35	E3	4,48E-02						
36	E4	7,72E-03						
37	E1	6,91E-03						
38	E2	1,23E-02						
39	E3	7,97E-03						
40	E4	2,05E-03						

Figura 8.8: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 1 de CO₂.

8.9. OPTIMIZACIÓN 2 NO_x

		Error val min		Error Val Global	0,00924			
				Error de Parada	0,00739			
1	E1	3,01E-03						
2	E2	4,16E-03						
3	E3	2,40E-02						
4	E4	7,02E-05						
5	E1	6,21E-03						
			Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
6	E2	0,0104						
7	E3	0,0125	1	E1	0,00739	0,00751	9	0,95911
8	E4	3,51E-05	1	E2	0,00739	0,00911	4	0,96304
9	E1	0,0146	1	E3	0,00739	0,0153	3	0,96822
10	E2	9,29E-03	1	E4	0,00739	0,00563	2	0,97883
11	E3	0,00106	2	E1	0,00739	0,00624	11	0,93247
12	E4	2,88E-02	2	E2	0,00739	0,00505	2	0,96665
13	E1	0,00409	2	E3	0,00739	0,00657	1	0,96355
14	E2	1,28E-03	2	E4	0,00739	0,00659	1	0,97571
15	E3	5,51E-03	3	E1	0,00739	0,0052	8	0,96083
16	E4	1,76E-03	3	E2	0,00739	0,0111	2	0,95214
17	E1	0,0116	3	E3	0,00739	0,00847	2	0,95865
18	E2	1,63E-03	3	E4	0,00739	0,005	2	0,96531
19	E3	2,30E-03	4	E1	0,00739	0,00638	12	0,89246
20	E4	1,33E-02	4	E2	0,00739	0,00917	2	0,93108
21	E1	4,44E-03	4	E3	0,00739	0,00346	2	0,97159
22	E2	0,00987	4	E4	0,00739	0,0092	1	0,93742
23	E3	4,80E-03	5	E1	0,00739	0,00685	10	0,96135
24	E4	2,03E-02	5	E2	0,00739	0,0085	4	0,9711
25	E1	3,76E-02	5	E3	0,00739	0,00553	1	0,96831
26	E2	3,82E-03	5	E4	0,00739	0,00539	2	0,97691
27	E3	8,69E-03						
28	E4	1,05E-04						
29	E1	1,81E-04						
30	E2	1,96E-02						
31	E3	0,000289						
32	E4	0,00518						
33	E1	1,38E-02						
34	E2	3,60E-02						
35	E3	3,34E-02						
36	E4	6,95E-03						
37	E1	4,66E-04						
38	E2	4,73E-03						
39	E3	3,83E-03						
40	E4	5,16E-05						

Figura 8.9: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 2 de NO_x.

8.10. OPTIMIZACIÓN 2 CO

		Error val min	Error Val Global	0,00056				
1	E1	4,94E-04	Error de Parada	0,00045				
2	E2	1,58E-04						
3	E3	5,49E-05						
4	E4	7,25E-04						
5	E1	1,66E-05						
6	E2	9,34E-05	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
7	E3	3,75E-05	1	E1	0,00045	0,000353	5	0,99362
8	E4	0,000698	1	E2	0,00045	0,00042	3	0,99764
9	E1	0,000689	1	E3	0,00045	0,000438	4	0,99726
10	E2	0,000137	1	E4	0,00045	0,000948	3	0,99819
11	E3	0,00012	2	E1	0,00045	0,000281	6	0,98869
12	E4	6,26E-04	2	E2	0,00045	0,000586	4	0,99504
13	E1	0,000226	2	E3	0,00045	0,000689	3	0,98999
14	E2	0,000413	2	E4	0,00045	0,000778	2	0,99356
15	E3	5,46E-05	3	E1	0,00045	0,000121	5	0,99588
16	E4	0,000385	3	E2	0,00045	0,000538	3	0,9971
17	E1	0,00483	3	E3	0,00045	0,000354	2	0,99648
18	E2	0,00019	3	E4	0,00045	0,000466	2	0,99702
19	E3	9,36E-06	4	E1	0,00045	0,000313	7	0,99452
20	E4	2,43E-04	4	E2	0,00045	0,000431	1	0,99659
21	E1	0,000783	4	E3	0,00045	0,000474	4	0,9969
22	E2	0,00013	4	E4	0,00045	0,000375	1	0,99697
23	E3	0,00599	5	E1	0,00045	0,000258	6	0,99459
24	E4	0,000213	5	E2	0,00045	0,000443	1	0,9957
25	E1	4,39E-04	5	E3	0,00045	0,000436	4	0,99445
26	E2	2,47E-04	5	E4	0,00045	0,000629	3	0,99625
27	E3	1,89E-05						
28	E4	1,57E-05						
29	E1	4,79E-04						
30	E2	8,97E-06						
31	E3	0,000193						
32	E4	0,00223						
33	E1	5,66E-05						
34	E2	0,000121						
35	E3	2,71E-04						
36	E4	8,69E-05						
37	E1	6,66E-05						
38	E2	8,10E-04						
39	E3	0,000112						
40	E4	5,54E-05						

Figura 8.10: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 2 de CO.

8.11. OPTIMIZACIÓN 2 HC

		Error val min	Error Val Global	0,00112				
1	E1	3,21E-03	Error de Parada	0,00090				
2	E2	1,51E-02						
3	E3	2,31E-04						
4	E4	3,25E-04						
5	E1	9,76E-06						
6	E2	8,65E-06	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento R	
7	E3	0,000117	1	E1	0,00090	0,0007	7	0,98936
8	E4	3,53E-03	1	E2	0,00090	0,000864	1	0,99508
9	E1	9,06E-06	1	E3	0,00090	0,00092	1	0,99567
10	E2	3,79E-05	1	E4	0,00090	0,000901	1	0,99702
11	E3	4,70E-05	2	E1	0,00090	0,000613	5	0,97458
12	E4	5,41E-05	2	E2	0,00090	0,000592	3	0,99397
13	E1	9,78E-06	2	E3	0,00090	0,000678	9	0,98221
14	E2	6,08E-04	2	E4	0,00090	0,000947	5	0,98604
15	E3	2,69E-03	3	E1	0,00090	0,000355	7	0,99035
16	E4	1,51E-05	3	E2	0,00090	0,000584	1	0,98934
17	E1	0,00016	3	E3	0,00090	0,00061	2	0,99533
18	E2	4,49E-05	3	E4	0,00090	0,00102	1	0,99595
19	E3	5,27E-05	4	E1	0,00090	0,000338	7	0,99233
20	E4	9,77E-04	4	E2	0,00090	0,000753	1	0,99306
21	E1	3,54E-04	4	E3	0,00090	0,000801	2	0,99502
22	E2	0,0017	4	E4	0,00090	0,000802	1	0,99595
23	E3	2,27E-05	5	E1	0,00090	0,000804	6	0,99147
24	E4	2,25E-04	5	E2	0,00090	0,000704	2	0,9939
25	E1	2,20E-04	5	E3	0,00090	0,00106	1	0,99506
26	E2	1,37E-03	5	E4	0,00090	0,000775	1	0,99482
27	E3	4,24E-04						
28	E4	4,24E-05						
29	E1	1,36E-04						
30	E2	3,10E-03						
31	E3	9,88E-06						
32	E4	0,00672						
33	E1	8,45E-06						
34	E2	0,000127						
35	E3	3,09E-04						
36	E4	2,06E-04						
37	E1	4,17E-05						
38	E2	3,99E-04						
39	E3	1,57E-03						
40	E4	6,27E-04						

Figura 8.11: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 2 de HC.

8.12. OPTIMIZACIÓN 2 CO₂

		Error val min	Error Val Global	0,00626				
1	E1	8,96E-04	Error de Parada	0,00501				
2	E2	9,16E-03						
3	E3	1,29E-02						
4	E4	4,84E-03						
5	E1	2,90E-04						
6	E2	0,000314	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
7	E3	0,00103	1	E1	0,00501	0,00464	4	0,97432
8	E4	2,01E-03	1	E2	0,00501	0,00562	4	0,98213
9	E1	0,00928	1	E3	0,00501	0,0184	2	0,97824
10	E2	1,07E-02	1	E4	0,00501	0,00657	6	0,98809
11	E3	0,0178	2	E1	0,00501	0,00496	9	0,98372
12	E4	3,04E-03	2	E2	0,00501	0,00574	7	0,98431
13	E1	4,96E-05	2	E3	0,00501	0,00953	2	0,97599
14	E2	7,62E-04	2	E4	0,00501	0,00497	2	0,99421
15	E3	1,16E-02	3	E1	0,00501	0,00163	5	0,98581
16	E4	0,00383	3	E2	0,00501	0,0047	5	0,98925
17	E1	0,00676	3	E3	0,00501	0,00904	8	0,9911
18	E2	6,99E-06	3	E4	0,00501	0,00679	2	0,9834
19	E3	1,40E-03	4	E1	0,00501	0,00453	8	0,99065
20	E4	9,92E-06	4	E2	0,00501	0,00239	1	0,98649
21	E1	4,26E-03	4	E3	0,00501	0,00524	2	0,98901
22	E2	0,00659	4	E4	0,00501	0,00532	2	0,99123
23	E3	3,60E-03	5	E1	0,00501	0,00194	7	0,97984
24	E4	1,19E-02	5	E2	0,00501	0,00828	11	0,97984
25	E1	8,06E-03	5	E3	0,00501	0,00739	6	0,98458
26	E2	5,31E-03	5	E4	0,00501	0,00179	2	0,98515
27	E3	2,41E-02						
28	E4	7,17E-03						
29	E1	9,78E-06						
30	E2	2,10E-04						
31	E3	0,0213						
32	E4	0,00112						
33	E1	0,000244						
34	E2	0,0114						
35	E3	1,29E-02						
36	E4	7,04E-03						
37	E1	8,06E-03						
38	E2	1,47E-02						
39	E3	8,66E-05						
40	E4	5,86E-03						

Figura 8.12: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 2 de CO₂.

8.13. OPTIMIZACIÓN 3 NO_x

		Error val min	Error Val Global	0,00683				
1	E1	1,47E-02	Error de Parada	0,00546				
2	E2	9,56E-03						
3	E3	1,48E-04						
4	E4	1,32E-03						
5	E1	7,01E-03						
6	E2	7,54E-05	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
7	E3	0,000571	1	E1	0,00546	0,00466	10	0,95561
8	E4	6,99E-03	1	E2	0,00546	0,00558	5	0,97648
9	E1	5,26E-05	1	E3	0,00546	0,00368	2	0,97603
10	E2	8,29E-03	1	E4	0,00546	0,00882	2	0,97579
11	E3	0,00387	2	E1	0,00546	0,00338	12	0,96144
12	E4	1,49E-02	2	E2	0,00546	0,0064	2	0,96219
13	E1	0,00132	2	E3	0,00546	0,00278	2	0,98437
14	E2	7,56E-03	2	E4	0,00546	0,00557	2	0,98163
15	E3	2,68E-02	3	E1	0,00546	0,00485	10	0,97522
16	E4	6,13E-03	3	E2	0,00546	0,00555	3	0,97449
17	E1	0,000609	3	E3	0,00546	0,00499	1	0,98289
18	E2	5,68E-03	3	E4	0,00546	0,00297	1	0,99051
19	E3	7,09E-04	4	E1	0,00546	0,00536	9	0,98184
20	E4	5,62E-03	4	E2	0,00546	0,00737	2	0,9791
21	E1	9,19E-03	4	E3	0,00546	0,00481	1	0,97812
22	E2	0,00863	4	E4	0,00546	0,00188	2	0,98772
23	E3	5,12E-03	5	E1	0,00546	0,00487	12	0,98104
24	E4	1,20E-03	5	E2	0,00546	0,0041	2	0,98022
25	E1	5,18E-03	5	E3	0,00546	0,00488	1	0,98145
26	E2	3,45E-04	5	E4	0,00546	0,00985	1	0,9839
27	E3	2,04E-03						
28	E4	6,19E-04						
29	E1	3,78E-02						
30	E2	2,24E-03						
31	E3	0,00241						
32	E4	5,67E-05						
33	E1	6,37E-03						
34	E2	3,20E-03						
35	E3	8,41E-03						
36	E4	2,54E-02						
37	E1	1,23E-02						
38	E2	1,17E-04						
39	E3	2,02E-02						
40	E4	4,66E-04						

Figura 8.13: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 3 de NO_x.

8.14. OPTIMIZACIÓN 3 CO

		Error val min		Error Val Global	0,00059			
				Error de Parada	0,00047			
1	E1	9,21E-05						
2	E2	2,33E-04						
3	E3	1,29E-05						
4	E4	2,22E-04						
5	E1	6,22E-05						
6	E2	1,90E-05	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R
7	E3	8,19E-05	1	E1	0,00047	0,000322	5	0,99761
8	E4	1,65E-04	1	E2	0,00047	0,000568	3	0,99811
9	E1	0,000181	1	E3	0,00047	0,000909	3	0,9986
10	E2	2,69E-04	1	E4	0,00047	0,000297	4	0,99904
11	E3	0,000103	2	E1	0,00047	0,000187	6	0,99932
12	E4	5,29E-05	2	E2	0,00047	0,000677	2	0,9992
13	E1	0,000462	2	E3	0,00047	0,000664	1	0,99891
14	E2	2,31E-04	2	E4	0,00047	0,000357	2	0,99928
15	E3	1,21E-03	3	E1	0,00047	0,000101	6	0,99579
16	E4	9,72E-05	3	E2	0,00047	0,000449	2	0,99802
17	E1	0,000268	3	E3	0,00047	0,000559	3	0,99904
18	E2	2,08E-05	3	E4	0,00047	0,000305	3	0,99932
19	E3	2,73E-04	4	E1	0,00047	0,000194	5	0,99607
20	E4	6,45E-04	4	E2	0,00047	0,000631	3	0,99797
21	E1	1,38E-04	4	E3	0,00047	0,000677	4	0,99915
22	E2	2,52E-05	4	E4	0,00047	0,000486	2	0,99897
23	E3	1,72E-04	5	E1	0,00047	0,000437	4	0,99711
24	E4	9,49E-06	5	E2	0,00047	0,000476	6	0,99789
25	E1	1,13E-04	5	E3	0,00047	0,000668	3	0,99885
26	E2	6,96E-04	5	E4	0,00047	0,000683	3	0,99839
27	E3	1,55E-04						
28	E4	2,27E-04						
29	E1	6,07E-04						
30	E2	7,41E-05						
31	E3	0,00345						
32	E4	7,27E-05						
33	E1	7,30E-04						
34	E2	2,52E-04						
35	E3	1,02E-03						
36	E4	5,85E-03						
37	E1	9,50E-06						
38	E2	4,62E-03						
39	E3	1,44E-04						
40	E4	4,85E-04						

Figura 8.14: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 3 de CO.

8.15. OPTIMIZACIÓN 3 HC

		Error val min	Error Val Global	0,00203				
			Error de Parada	0,00163				
1	E1	4,55E-04						
2	E2	1,01E-04						
3	E3	4,20E-05						
4	E4	9,95E-06						
5	E1	9,72E-06						
6	E2	6,47E-05	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	
7	E3	0,00192	1	E1	0,00163	0,00162	5	0,99441
8	E4	3,78E-05	1	E2	0,00163	0,00105	1	0,99392
9	E1	0,000229	1	E3	0,00163	0,00123	0	0,99403
10	E2	5,17E-04	1	E4	0,00163	0,00127	0	0,99383
11	E3	2,35E-05	2	E1	0,00163	0,00155	4	0,99546
12	E4	3,92E-05	2	E2	0,00163	0,000978	1	0,99596
13	E1	0,0012	2	E3	0,00163	0,00167	1	0,99662
14	E2	2,11E-03	2	E4	0,00163	0,00136	0	0,99709
15	E3	9,10E-03	3	E1	0,00163	0,000384	4	0,99516
16	E4	7,86E-04	3	E2	0,00163	0,00126	1	0,99641
17	E1	1,27E-05	3	E3	0,00163	0,00131	1	0,99695
18	E2	2,37E-03	3	E4	0,00163	0,00147	0	0,99697
19	E3	1,55E-03	4	E1	0,00163	0,00163	4	0,99541
20	E4	9,61E-04	4	E2	0,00163	0,00088	1	0,99723
21	E1	1,03E-04	4	E3	0,00163	0,00137	0	0,99742
22	E2	2,10E-05	4	E4	0,00163	0,00127	0	0,9971
23	E3	9,20E-05	5	E1	0,00163	0,000709	7	0,99623
24	E4	1,74E-04	5	E2	0,00163	0,000911	1	0,99641
25	E1	1,42E-04	5	E3	0,00163	0,00107	0	0,99721
26	E2	2,36E-04	5	E4	0,00163	0,00109	0	0,99714
27	E3	1,82E-04						
28	E4	3,51E-04						
29	E1	1,57E-04						
30	E2	1,13E-03						
31	E3	0,000297						
32	E4	0,000181						
33	E1	5,41E-04						
34	E2	2,20E-05						
35	E3	1,16E-05						
36	E4	5,57E-02						
37	E1	2,06E-05						
38	E2	4,42E-05						
39	E3	4,33E-05						
40	E4	2,77E-04						

Figura 8.15: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 3 de HC.

8.16. OPTIMIZACIÓN 3 CO₂

		Error val min	Error Val Global		0,01517				
			Error de Parada		0,01214				
1	E1	9,04E-06							
2	E2	6,77E-06							
3	E3	1,98E-02							
4	E4	1,14E-02							
5	E1	1,18E-02							
6	E2	0,0592	Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R	
7	E3	0,00889	1	E1	0,01214	0,00912	7	0,97651	
8	E4	2,68E-02	1	E2	0,01214	0,0121	3	0,98261	
9	E1	0,0164	1	E3	0,01214	0,0172	1	0,97359	
10	E2	9,20E-02	1	E4	0,01214	0,0139	4	0,99065	
11	E3	0,0171	2	E1	0,01214	0,00155	3	0,98789	
12	E4	4,25E-03	2	E2	0,01214	0,0121	3	0,98627	
13	E1	3,44E-06	2	E3	0,01214	0,0137	2	0,98827	
14	E2	2,22E-07	2	E4	0,01214	0,012	1	0,99107	
15	E3	2,58E-02	3	E1	0,01214	0,00515	3	0,98619	
16	E4	2,35E-04	3	E2	0,01214	0,0118	2	0,98748	
17	E1	7,92E-07	3	E3	0,01214	0,0132	1	0,98764	
18	E2	8,06E-02	3	E4	0,01214	0,0125	1	0,98968	
19	E3	1,07E-02	4	E1	0,01214	0,0064	2	0,9862	
20	E4	1,19E-02	4	E2	0,01214	0,0115	6	0,98721	
21	E1	1,54E-02	4	E3	0,01214	0,199	1	0,97793	
22	E2	0,0163	4	E4	0,01214	0,0134	1	0,98973	
23	E3	3,51E-09	5	E1	0,01214	0,0033	3	0,98504	
24	E4	3,00E-05	5	E2	0,01214	0,0129	5	0,98377	
25	E1	1,46E-02	5	E3	0,01214	0,0161	1	0,98443	
26	E2	1,61E-03	5	E4	0,01214	0,014	3	0,98976	
27	E3	9,44E-03							
28	E4	1,28E-02							
29	E1	8,00E-03							
30	E2	9,58E-03							
31	E3	0,0115							
32	E4	9,26E-06							
33	E1	7,30E-03							
34	E2	9,34E-04							
35	E3	5,10E-02							
36	E4	1,20E-05							
37	E1	1,50E-02							
38	E2	1,05E-02							
39	E3	8,47E-03							
40	E4	1,75E-02							

Figura 8.16: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 3 de CO₂.

8.17. OPTIMIZACIÓN 4 NO_x

		Error val min		Error Val Global	0,01355			
				Error de Parada	0,01084			
1	E1	8,89E-03						
2	E2	1,61E-03						
3	E3	1,23E-02						
4	E4	5,14E-02						
5	E1	4,48E-03						
			Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epoocas de Entrenamiento	R
6	E2	1,15E-02						
7	E3	0,00731	1	E1	0,0108	0,0103	7	0,93451
8	E4	3,42E-02	1	E2	0,0108	0,0157	4	0,94263
9	E1	3,93E-02	1	E3	0,0108	0,0113	4	0,95918
10	E2	7,87E-03	1	E4	0,0108	0,00974	2	0,96957
11	E3	0,037	2	E1	0,0108	0,0103	14	0,95232
12	E4	1,42E-02	2	E2	0,0108	0,0074	3	0,95608
13	E1	3,84E-05	2	E3	0,0108	0,0102	1	0,96827
14	E2	1,12E-02	2	E4	0,0108	0,0183	2	0,97188
15	E3	3,64E-03	3	E1	0,0108	0,00927	12	0,94053
16	E4	3,64E-02	3	E2	0,0108	0,0103	4	0,91234
17	E1	0,00486	3	E3	0,0108	0,007	6	0,90966
18	E2	2,65E-02	3	E4	0,0108	0,0104	1	0,95673
19	E3	3,28E-03	4	E1	0,0108	0,0105	9	0,92839
20	E4	1,90E-03	4	E2	0,0108	0,0147	6	0,95485
21	E1	7,43E-04	4	E3	0,0108	0,0134	8	0,96542
22	E2	0,0163	4	E4	0,0108	0,0094	5	0,97208
23	E3	7,38E-03	5	E1	0,0108	0,0105	6	0,93773
24	E4	4,40E-03	5	E2	0,0108	0,0104	8	0,96966
25	E1	3,39E-02	5	E3	0,0108	0,0162	1	0,97477
26	E2	2,83E-02	5	E4	0,0108	0,013	1	0,9758
27	E3	2,35E-03						
28	E4	1,93E-02						
29	E1	1,21E-02						
30	E2	3,24E-03						
31	E3	0,00817						
32	E4	1,98E-02						
33	E1	2,03E-02						
34	E2	8,03E-03						
35	E3	1,29E-02						
36	E4	5,09E-03						
37	E1	2,09E-03						
38	E2	7,66E-03						
39	E3	1,21E-02						
40	E4	1,07E-04						

Figura 8.17: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 4 de NO_x.

8.18. OPTIMIZACIÓN 4 CO

		Error val min	Error Val Global	0,00068			
1	E1	4,40E-03	Error de Parada	0,00054			
2	E2	4,57E-04					
3	E3	3,57E-04					
4	E4	2,37E-04					
5	E1	2,22E-04					
6	E2	8,83E-04	Iniciaciones	Iteracciones	Error de para	MSE entrena	Epocas de Entrenamiento
7	E3	7,20E-04	1	E1	0,00054	0,00042	4
8	E4	2,69E-04	1	E2	0,00054	0,000681	3
9	E1	0,00069	1	E3	0,00054	0,000704	2
10	E2	6,24E-05	1	E4	0,00054	0,000503	2
11	E3	9,23E-05	2	E1	0,00054	0,000537	6
12	E4	2,57E-04	2	E2	0,00054	0,000512	2
13	E1	0,000115	2	E3	0,00054	0,000709	3
14	E2	1,36E-04	2	E4	0,00054	0,000505	3
15	E3	4,29E-04	3	E1	0,00054	0,00025	6
16	E4	2,64E-04	3	E2	0,00054	0,000359	3
17	E1	0,000106	3	E3	0,00054	0,000507	1
18	E2	2,59E-05	3	E4	0,00054	0,000632	1
19	E3	1,22E-04	4	E1	0,00054	0,000394	6
20	E4	9,51E-05	4	E2	0,00054	0,000905	3
21	E1	2,51E-04	4	E3	0,00054	0,000857	3
22	E2	4,11E-04	4	E4	0,00054	0,000838	2
23	E3	8,14E-05	5	E1	0,00054	0,000233	10
24	E4	6,71E-04	5	E2	0,00054	0,000616	2
25	E1	9,16E-06	5	E3	0,00054	0,000533	2
26	E2	1,20E-04	5	E4	0,00054	0,000815	2
27	E3	2,96E-05					
28	E4	4,12E-04					
29	E1	3,94E-05					
30	E2	5,47E-03					
31	E3	1,76E-05					
32	E4	8,32E-05					
33	E1	1,51E-03					
34	E2	1,13E-04					
35	E3	1,12E-04					
36	E4	6,15E-04					
37	E1	2,10E-03					
38	E2	7,65E-05					
39	E3	9,37E-04					
40	E4	4,09E-03					

Figura 8.18: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 4 de CO.

8.19. OPTIMIZACIÓN 4 HC

		Error val min	Error Val Global		0,00082				
1	E1	2,31E-05	Error de Parada		0,00065				
2	E2	2,31E-05							
3	E3	1,22E-04							
4	E4	8,79E-05							
5	E1	1,01E-03							
			Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epocas de Entrenamiento	R	
6	E2	1,04E-02							
7	E3	2,16E-05	1	E1	0,00065	0,000367	5	0,99621	
8	E4	4,40E-04	1	E2	0,00065	0,000488	2	0,99767	
9	E1	1,04E-03	1	E3	0,00065	0,000573	3	0,99773	
10	E2	7,79E-05	1	E4	0,00065	0,000923	4	0,99739	
11	E3	0,000262	2	E1	0,00065	0,000229	7	0,99463	
12	E4	1,71E-04	2	E2	0,00065	0,000643	3	0,99626	
13	E1	0,000729	2	E3	0,00065	0,000755	3	0,99671	
14	E2	1,06E-04	2	E4	0,00065	0,000629	2	0,99701	
15	E3	4,43E-04	3	E1	0,00065	0,000477	6	0,99328	
16	E4	3,40E-05	3	E2	0,00065	0,00059	2	0,99661	
17	E1	0,000734	3	E3	0,00065	0,000633	2	0,99507	
18	E2	9,13E-05	3	E4	0,00065	0,000869	3	0,99762	
19	E3	1,38E-04	4	E1	0,00065	0,000368	5	0,99473	
20	E4	5,09E-04	4	E2	0,00065	0,000871	6	0,99634	
21	E1	5,25E-04	4	E3	0,00065	0,00076	6	0,99745	
22	E2	0,00262	4	E4	0,00065	0,00065	1	0,99707	
23	E3	9,46E-05	5	E1	0,00065	0,000489	4	0,99684	
24	E4	1,75E-03	5	E2	0,00065	0,000675	1	0,99689	
25	E1	1,45E-03	5	E3	0,00065	0,000374	2	0,99727	
26	E2	1,52E-04	5	E4	0,00065	0,000686	2	0,9981	
27	E3	5,60E-04							
28	E4	8,22E-04							
29	E1	9,57E-05							
30	E2	5,03E-04							
31	E3	4,90E-05							
32	E4	9,90E-05							
33	E1	3,30E-05							
34	E2	3,47E-03							
35	E3	1,99E-05							
36	E4	2,67E-03							
37	E1	5,43E-05							
38	E2	5,92E-04							
39	E3	1,78E-04							
40	E4	5,23E-04							

Figura 8.19: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 4 de HC.

8.20. OPTIMIZACIÓN 4 CO₂

		Error val min		Error Val Global	0,00898			
1	E1	8,89E-06		Error de Parada	0,00718			
2	E2	3,88E-03						
3	E3	6,60E-03						
4	E4	4,78E-02						
5	E1	5,22E-03						
6	E2	1,18E-04		Inicialización	Conjunto	Error de parada	MSE entrenamiento	Epoas de Entrenamiento
7	E3	9,78E-06		1	E1	0,00718	0,0051	6
8	E4	7,98E-03		1	E2	0,00718	0,00665	1
9	E1	0,0527		1	E3	0,00718	0,00606	1
10	E2	1,84E-03		1	E4	0,00718	0,00789	1
11	E3	5,79E-03		2	E1	0,00718	0,00397	9
12	E4	1,24E-02		2	E2	0,00718	0,00589	1
13	E1	0,00268		2	E3	0,00718	0,00259	1
14	E2	1,23E-02		2	E4	0,00718	0,00217	1
15	E3	9,98E-06		3	E1	0,00718	0,00404	4
16	E4	4,52E-03		3	E2	0,00718	0,00623	1
17	E1	4,64E-03		3	E3	0,00718	0,00522	1
18	E2	6,94E-06		3	E4	0,00718	0,00509	1
19	E3	2,73E-05		4	E1	0,00718	0,00506	5
20	E4	7,61E-05		4	E2	0,00718	0,00768	1
21	E1	1,04E-02		4	E3	0,00718	0,00307	1
22	E2	1,23E-03		4	E4	0,00718	0,005	1
23	E3	8,64E-03		5	E1	0,00718	0,00548	6
24	E4	7,47E-06		5	E2	0,00718	0,0031	2
25	E1	6,68E-06		5	E3	0,00718	0,00986	1
26	E2	7,04E-06		5	E4	0,00718	0,00979	1
27	E3	3,16E-02						
28	E4	5,05E-03						
29	E1	8,75E-03						
30	E2	6,78E-03						
31	E3	0,0115						
32	E4	4,35E-05						
33	E1	1,77E-04						
34	E2	1,26E-05						
35	E3	5,36E-03						
36	E4	6,37E-03						
37	E1	9,06E-02						
38	E2	9,52E-06						
39	E3	4,01E-03						
40	E4	9,39E-06						

Figura 8.20: Resultados del entrenamiento Fase 1 + Fase 2 para Optimización 4 de CO₂.

9. REFERENCIAS

- [1] Leonor Hernandez López, F. Payri y J. M^a. Desantes.”*Predicción y optimización de emisiones y consumo mediante redes neuronales en motores diésel*”. Temas avanzados en motores de combustión interna. Editorial Reverté S. A., 2006.
- [2] J.L. Osorio Tejada, E. Llera, S. Scarpellini. “*LNG: an alternative fuel for road freight transport in Europe*”. WIT Transactions on the Built Environment. Sustainable Development 2015; 168(1): 235 - 246
- [3] IDAE. “*Combustibles y vehículos alternativos*”. Proyecto TREATISE de la Comisión Europea
- [4] IDAE, FITSA. “*NUEVOS COMBUSTIBLES Y TECNOLOGÍAS DE PROPULSIÓN*”. Fundación Instituto Tecnológico Para la Seguridad del Automóvil –FITSA.
- [5] “REGLAMENTO (UE) N°459/2012 DE LA COMISIÓN de 29 de mayo de 2012 por el que se modifican el Reglamento (CE) no 715/2007 del Parlamento Europeo y del Consejo y el Reglamento (CE) n° 692/2008 de la Comisión en lo que respecta a las emisiones procedentes de turismos y vehículos comerciales ligeros (Euro 6)”. Diario oficial de la Unión Europea.
- [6] C. Sopena, P.M. Diéguez, D. Sáinz, J.C. Urroz, E. Guelbenzu, L.M. Gandía. Conversion of a commercial spark ignition engine to run on hydrogen: Performance comparison using hydrogen and gasoline. *Hydrogen energy* 35 (2010) 1420 – 1429.
- [7] Shivaprasad K Va, *, Raviteja Sa, Parashuram Chitragara Kumar G N. Experimental Investigation of the Effect of Hydrogen Addition on Combustion Performance and Emissions Characteristics of a Spark Ignition High Speed Gasoline Engine. *Procedia Technology* 14 (2014) 141 – 148
- [8] Y. Karagöz , T. Sandalcı, L. Yüksek, A.S. Dalkılıç. Engine performance and emission effects of diesel burns enriched by hydrogen on different engine loads. *Hydrogen energy* 4 0 (20 15) 6702-6713.
- [9]Seung Hyun Yoon, Chang Sik Lee. Effect of undiluted bioethanol on combustion and emissions reduction in a SI engine at various charge air conditions. *Fuel* 97 (2012) 887–890.
- [10] Cheolwoong Park, Young Choi, Changgi Kim, Seungmook Oh, Gihun Lim, Yasuo Moriyoshi. Performance and exhaust emission characteristics of a spark ignition engine using ethanol and ethanol-reformed gas. *Fuel* 89 (2010) 2118–2125.
- [11] Mustafa Koç, Yakup Sekmen, Tolga Topgül, Hüseyin Serdar Yücesu. The effects of ethanol–unleaded gasoline blends on engine performance and exhaust emissions in a spark-ignition engine. *Renewable Energy* 34 (2009) 2101–2106
- [12] Kraipat Cheenkachorn, Chedthawut Poompipatpong, Choi Gyeong Ho. Performance and emissions of a heavy-duty diesel engine fuelled with diesel and LNG (liquid natural gas). *Energy* 53 (2013) 52-57.

- [13] M.I. Jahirul, H.H. Masjuki, R. Saidur, M.A. Kalam, M.H. Jayed, M.A. Wazed. *Comparative engine performance and emission analysis of CNG and gasoline in a retrofitted car engine*. Applied Thermal Engineering 30 (2010) 2219-2226.
- [14] M. Muñoz, F. Payri. “*Motores de combustión interna alternativos*”. Sección de Publicaciones de la E.T.S. de Ingenieros Industriales. Fundación General-UPM
- [15] Mariano Muñoz Rodríguez, Francisco Moreno Gómez, Jesús F. Morea Roy. “*Motores alternativos de combustión interna*”. Pressas Universitarias de Zaragoza.
- [16] Haykin S. *Neural networks: a comprehensible foundation*. Prencite-Hall Inc., ISBN. 0-13-908385-5, 1994.
- [17] Kröse B.J.A. y der Smagt P.P. Van. *An introduction to neural networks*. University of Amsterdam, 1996.
- [18] Jesús D. Villalba, Iván D. Gómez, José E. Laier. “*Detección de daño en vigas utilizando redes neuronales artificiales y parámetros dinámicos*” Revista de la Facultad de Ingeniería de la Universidad de Antioquia. <http://www.scielo.org.co/img/revistas/rfiua/n63/n63a13i02.gif> (Acceso: Septiembre de 2016)
- [19] Joanna Collantes Duarte, Gerardo Colmenares La Cruz, Giampaolo Orlandoni Merli y Franklin Rivas Echeverría. “A comparison of time series forecasting between artificial neural networks and box and jenkins methods”. Revista Técnica de la Facultad de Ingeniería Universidad del Zulia. <http://www.scielo.org.ve/img/fbpe/rftiuz/v27n3/art02img01.gif> (Acceso: Septiembre de 2016)
- [20] Dr. Quiliano Isaac Moro, Dra. Aranzazu Simón Hurtado. *Capítulo 3: Redes Neuronales Artificiales*. Introducción al Diseño de Experimentos para el Reconocimiento de Patrones.