



مدل سازی اثر نانولوله های کربنی عامل دار حاوی اکسیژن، اضافه شده به مخلوط سوخت دیزل، بیودیزل و بیواتانول بر عملکرد و آلاینده های یک موتور دیزل با استفاده از شبکه عصبی مصنوعی

لیلا شاکری^۱، علی اصغری^{۲*} و احمد تقی زاده علی سرایی^۳

۱- کارشناسی ارشد، مهندسی مکانیک بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، leilashakeri96@gmail.com

۲- استادیار، مهندسی مکانیک بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، aliasghari809@gmail.com

۳- دانشیار، مهندسی مکانیک بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ahmadtza@yahoo.com

* نویسنده مخاطب

(تاریخ دریافت: ۹۸/۱۰/۲۹، دریافت آخرین اصلاحات: ۹۸/۱۲/۲۰، پذیرش: ۹۹/۰۱/۱۴)

چکیده: ترکیب سوخت های زیستی مانند بیودیزل، بیواتانول و نانولوله های کربنی به عنوان کاتالیزور با سوخت دیزل سبب عملکرد بهتر موتور و کاهش آلاینده های می شود. در تحقیق حاضر، برای تهیه سوخت های مورد نیاز آزمایش، ابتدا به نسبت ۵٪ نانولوله های کربنی عامل دار حاوی اکسیژن به سوخت دیزل اضافه شد. سپس، نانولوله های کربنی عامل دار با گروه اکسیژن دار COOH (غلظت های ۳۰، ۶۰ و ۹۰ ppm) در دو سطح بیواتانول ۳ و ۶ درصد، با دیزل خالص و بیودیزل ۵٪ ترکیب شد. آزمایش ها در سه تکرار انجام شدند. در این تحقیق، مدلی با شبکه عصبی چندلایه الگوریتم یادگیری پس انتشار خطا روبه جلو (FFBP) برای تخمین عملکرد موتور ارائه شد. نوع سوخت، دور موتور، چگالی، گرانشی، ارزش حرارتی سوخت، فشار چندراهه ورودی، مصرف سوخت، دمای گازهای خروجی، دمای روغن، اکسیژن موجود در گازهای خروجی، رطوبت و فشار نسبی هوای محیط به عنوان پارامترهای لایه ورودی یا مستقل و عملکرد و آلاینده های موتور به عنوان پارامترهای لایه خروجی در نظر گرفته شدند. با توجه به نتایج به دست آمده از شبکه عصبی مصنوعی، انتشار آلاینده های CO و UHC و مصرف سوخت ویژه کاهش یافت، اما در انتشار NO_x شاهد افزایش بودیم. شبکه تشکیل شده با تابع آموزش سیگموئیدی، به دلیل اینکه میزان R² و MSE بهتری نسبت به شبکه های تشکیل شده خطی و تانژانت هیپربولیک داشت، به عنوان مدل بهینه معرفی شد. در مجموع، می توان بیان کرد که شبکه عصبی مصنوعی توانایی مناسبی را در شبیه سازی داده ها و بررسی ضریب حساسیت آن ها نشان داده است.

کلیدواژگان: عملکرد موتور، آلاینده های موتور، نانولوله کربنی، مدل سازی با شبکه عصبی مصنوعی

مقدمه

در سال های اخیر، افزایش جمعیت و مصرف زیاد سوخت های فسیلی و توسعه سریع تکنولوژی سبب شد که آلودگی محیط زیست یکی از دستاوردهای ناخواسته این توسعه صنعت باشد. کاهش استفاده از سوخت های فسیلی تا حد زیادی سبب کاهش انتشار این آلاینده های مضر می شود. منابع پایدار انرژی های تجدیدپذیر نقش مهمی در آینده انرژی جهان دارند [۱]. تجدیدپذیر بودن سوخت های زیستی سبب شد که درباره این سوخت ها و جایگزینی آن ها به جای سوخت های فسیلی تحقیقات گسترده ای صورت بگیرد. مهم ترین سوخت های زیستی مایع در جهان بیودیزل و بیواتانول هستند [۲]. بیودیزل یک سوخت جایگزین دیزل، متیل یا اتیل استری است که از اسیدهای چرب حیوانی یا گیاهی به دست می آید. این سوخت اکسیژنه قابل تجزیه و تجدیدپذیر است. بیواتانول یا اتانول زیستی الکی است دارای دو کربن با فرمول شیمیایی C₂H₅OH. این سوخت نسبت به

بنزین عدد اکتان بالایی دارد و دارای یک اتم اکسیژن در مولکول خود است که به همین دلیل دارای قابلیت سوختن بهتری است.

در سال‌های اخیر، نانولوله‌های کربنی (CNT)؛^۱ به دلیل ویژگی‌های منحصر به فرد الکتریکی، مقاومت و رسانایی حرارتی بالا توجه زیادی را به عنوان پایه کاتالیست در فرایندهای کاتالیستی ناهمگن، به خود جلب کرده‌اند. نانولوله‌های کربنی با داشتن ساختار شبکه‌های لوله‌ای شکل و حفره‌های مزو، نقل و انتقال مواد واکنشگر و فراورده‌ها را آسان تر می‌کنند. همچنین، این پایه‌ها نسبت به محیط‌های اسیدی و بازی و تشکیل کک نیز مقاوم‌اند، اما، به دلیل آنکه ماهیت ذاتی نانولوله‌های کربنی آب‌گریز است، به منظور افزایش پراکندگی پایه، در حلال‌های قطبی استفاده می‌شوند. در فرایند ساخت کاتالیست، انتظار می‌رود که ایجاد گروه‌های عاملی اکسیژن‌دار بر روی سطح نانولوله‌ها نقش بسزایی در توزیع یکنواخت فاز فعال بر روی سطوح پایه ایفا کرده و مکان‌هایی برای شروع هسته‌زایی و رشد ذرات فاز فعال ایجاد شود. در حین خالص‌سازی شیمیایی، نانولوله‌های کربنی عامل‌دار نیز می‌شوند. عامل‌داری نانولوله‌ها را می‌توان به دو دسته روش‌های کووالانسی و غیر کووالانسی طبقه‌بندی کرد. برای ایجاد گروه‌های عاملی اکسیژن‌دار اکسیداسیون شیمیایی متداول‌ترین روش است. عواملی از جمله دما، زمان، نوع و غلظت اکسندرها و روش اکسیداسیون بر گروه‌های عاملی ایجاد شده تأثیرگذارند.

در سال‌های اخیر، برای مسائلی که راه‌حل‌های مشخص و واضحی ندارند، سیستم‌های هوشمند به‌طور فزاینده‌ای مورد توجه قرار گرفت که شبکه‌های عصبی از این مجموعه‌اند. این شبکه‌ها با پردازش اطلاعات، روابط نهفته در این اطلاعات را نتیجه‌گیری می‌کنند. روش شبکه‌های عصبی مزایایی نسبت به استفاده از روش‌های آماری معمولی و قطعی دارد. مثلاً، در مدل رگرسیون خطی مقادیر ملزوم به قرارگیری در اطراف یک مقدار میانگین‌اند، اما در شبکه عصبی این‌طور نیست. به همین دلیل، تغییرات واقعی داده‌ها را حفظ می‌کند. از آنجایی که فاکتورهای زیادی بر روی عملکرد و آلاینده‌های موتور اثر می‌گذارد و امکان انجام آزمایش در تمام حالات وجود ندارد، از مدل‌های شبکه عصبی استفاده می‌شود. تحقیقات زیادی در ارتباط با عملکرد و آلاینده‌های موتور با استفاده از شبکه‌های عصبی صورت گرفته است، به طوری که ورودی اندکی به شبکه عصبی داده شده است. اما، واضح است که مواردی مانند چگالی، گرانش، ارزش حرارتی سوخت، فشار مجرای ورودی، دماهای گازهای خروجی، اکسیژن موجود در گازهای خروجی و غیره بر عملکرد و آلاینده‌های موتور مؤثر است که این عیب‌ها با استفاده از شبکه عصبی برطرف می‌شود. شبکه‌های عصبی مصنوعی و سری‌های زمانی برای شبیه‌سازی و پایش وضعیت سیستم استفاده می‌شوند [۵-۳]. شبکه‌های عصبی مصنوعی برای حل انواع گسترده‌ای از مشکلات در علوم مهندسی، به‌ویژه برای برخی از مسائل که در آن روش‌های مدل‌سازی متعارف قادر به پاسخگویی نیست، مورد استفاده قرار گرفته‌اند و توانایی پیش‌بینی یک شبکه عصبی مصنوعی نتیجه آموزش داده‌های تجربی و سپس اعتبارسنجی با استفاده از داده‌های مستقل است [۶،۷]. یکی از ویژگی‌های شبکه‌های عصبی توانایی آن‌ها در استخراج روابط بین ورودی و خروجی‌های یک فرایند، بدون نیاز به شرایط پیچیده فیزیکی است. آن‌ها قادرند یک فضای چندبعدی را با فضای دیگری مرتبط کنند، حتی اگر این اطلاعات ناقص و دارای خطا باشند. این خصوصیات سبب شده که برای مسائل مربوط به برآورد و پیش‌بینی در کشاورزی و صنعت مناسب باشد و همچنین در مواردی که روابط غیرخطی است شبکه عصبی کارایی خوبی دارد [۸،۹].

شبکه‌های عصبی مصنوعی (ANNs) تکنیک‌های مدل‌سازی قدرتمند هستند که به‌طور خلاصه با آرایه‌هایی از نورون‌ها در حافظه و یادگیری بیولوژیک کار می‌کنند. شبکه‌های عصبی مصنوعی مزایای متعددی نسبت به تکنیک‌های مدل‌سازی معمولی ارائه می‌دهند، زیرا می‌توانند براساس هیچ فرضیه‌ای درباره ماهیت مکانیسم‌های پدیده‌شناسی و درک زمینه‌های ریاضی مشکل اصلی فرایند و توانایی یادگیری روابط خطی و غیرخطی بین متغیرها به‌طور مستقیم، از مجموعه‌ای از نمونه‌ها، مدل ارائه دهند [۱۰، ۱۱]. همچنین، شبکه‌های عصبی مصنوعی یکی از کارآمدترین روش‌ها برای پردازش اطلاعات زیادی هستند که باعث

1 Carbon nanotubes

2 Artificial neural Networks

چالش در جنبه‌های مختلف شده است. روند توسعه آن‌ها نشان‌دهنده اهمیت استفاده از این روش برای پردازش اطلاعات است، زیرا در بررسی داده‌ها بسیار موفق بوده‌اند و توانسته‌اند در زمینه‌های مختلف گسترش یابند. تحقیقات زیادی در مورد کاربرد شبکه عصبی برای تحلیل رفتار موتور انجام شده است. کاناکسی و همکاران کاربرد شبکه عصبی مصنوعی با مخلوط سوخت دیزل و بیودیزل بر عملکرد و آلاینده‌گی در یک موتور دیزل را بررسی کردند. در شبکه مورد نظر، میانگین وزن مولکولی، حرارت خالص احتراق، وزن مخصوص، گرانیوی سینماتیکی، نسبت کربن به هیدروژن (C/H) و عدد ستان هر سوخت به‌عنوان پارامترهای خروجی در نظر گرفته شدند. مقدار R برای عملکرد ۰/۹۹ و مقدار میانگین خطاهای داده‌های آموزشی کمتر از ۴/۲ درصد به‌دست آمد. برای داده‌های ارزیابی، مقدار R برابر ۰/۹۹ و میانگین خطاها کمتر از ۵/۵ درصد محاسبه شد [۱۲].

دهقانی و همکاران عملکرد و آلاینده‌گی موتور اشتعال جرقه‌ای دوزمانه را با استفاده از بیوروانکارها به کمک شبکه عصبی مصنوعی ارزیابی کردند. نوع روانکار و سرعت موتور پارامترهای ورودی موتور را تشکیل دادند. توان ترمزی موتور، گشتاور، مصرف سوخت ویژه و گازهای خروجی به‌عنوان پارامترهای خروجی مدل استفاده‌شده در نظر گرفته شدند. شبکه چندلایه (MLP) با ساختار ۸-۲۵-۳ (۸ نورون در لایه‌های خروجی، ۲۵ نورون در لایه‌های مخفی، ۳ نورون در لایه‌های ورودی) برای عملکرد و آلاینده‌گی ایجاد شد. نتایج نشان داد که روش شبکه عصبی مصنوعی مسائل موتورهای احتراق داخلی را با دقت خوبی پیش‌بینی می‌کنند [۱۳].

حسینی و همکاران نیز بر روی مدل‌سازی اثر نانولوله‌های کربن اضافه‌شده به مخلوط سوخت دیزل-بیودیزل بر عملکرد و آلاینده‌گی یک موتور دیزل با استفاده از شبکه عصبی مصنوعی تحقیقی را انجام دادند که مدل شبکه عصبی با الگوی آموزش پس از انتشار خطا با ۲۰-۲۰ نورون در لایه‌های مخفی ورودی و خروجی سیگموئیدی توانایی پیش‌بینی پارامترهای مختلف را با عملکرد و دقت خوبی داشته است [۱۴].

هدف از انجام تحقیق حاضر، معرفی یک مدل شبکه عصبی برای پیش‌بینی پارامترهایی مانند توان، گشتاور و آلاینده‌گی موتور است. متغیرهای ورودی این شبیه‌سازی عبارت‌اند از: نوع سوخت، دور موتور، چگالی، گرانیوی، ارزش حرارتی سوخت، فشار چندراهه ورودی، مصرف سوخت، دمای گازهای خروجی، دمای روغن، اکسیژن موجود در گازهای خروجی، رطوبت و فشار نسبی هوای محیط. در تحقیقات گذشته، اغلب، نوع سوخت و بار و دور موتور به‌عنوان متغیر ورودی معرفی می‌شد که محدودند، اما در این تحقیق تمامی پارامترهای مؤثر بر عملکرد موتور به‌عنوان ورودی شبکه عصبی در نظر گرفته شدند. همچنین، در این تحقیق، توانایی شبکه عصبی مصنوعی در پیش‌بینی داده‌های میزان آلودگی و عملکرد موتور بررسی شده است.

مواد و روش‌ها

نصب و راه‌اندازی تجهیزات آزمایشگاهی و داده‌برداری

جدول ۱ دستگاه‌های آزمایشگاهی و داده‌برداری که در این تحقیق مورد استفاده قرار گرفته را نشان می‌دهد. در این پژوهش از موتور تک‌سیلندر، چهارزمانه، هواخنک استفاده شد. از یک دینامومتر جریان گردابی برای اندازه‌گیری بار و گشتاور موتور استفاده شد. برای اندازه‌گیری آلاینده‌گی موتور از یک دستگاه آلاینده‌سنج استفاده شد. در نهایت کابل داده‌های خروجی به پورت USB یارانه متصل شد و داده‌ها ثبت شد. دامنه و دقت دستگاه‌ها و محاسبات انجام‌شده در جدول ۲ آمده است.

جدول ۱- مشخصات دستگاه‌ها و تجهیزات استفاده‌شده در این آزمایش
Table 1- Specifications of all equipment and devices used in this experiments

Test Engine: Lombardini Model 3LD510, single-cylinder, four-stroke, direct injection, air-cooled, common rail fuel system (pump-line-nozzle) with a governor controlled, cylinder volume of 510 cm ³ , 9 kW power at 3000rpm, rated speed 3000 rpm, 32.8 Nm peak torque at 1800 rpm, compression ratio 17.5:1, nozzle operation pressure 200 bar, fuel injection timing 60° bTDC, emission standard EURO 2.
Dynamometer: Model WE400, Eddy current dynamometer, Maximum torque of 80Nm, Maximum speed of 10000 rpm.
Emission Analyzer: AVL DITEST GAS 1000, Mobile petrol/gas emission tester, Emission diagnostics of HC, CO, CO ₂ , O ₂ , NO _x , and lambda.
Accelerometers: Multi-Purpose Accelerometers, CTC AC102-1A, Frequency Response (±3dB) 0.5-15000 Hz, Dynamic Range ± 50 g peak, Resonant Frequency 23000 Hz.
A/D converter: Advantech USB-4711A, 16 Single input channels A/D, Converting 12 bit A/D, Maximum sampling frequency of 150 kHz.
Other Devices and Sensors: -Ultrasonic homogenizer: Hielscher UP400S, Germany-Fuel flow meter: volumetric type, brand OVAL, made in Japan-Exhaust gas temperature sensor: thermocouple type K (0 to 1000°C)-Humidity measurement sensor: (3% to 99%)-Ambient air pressure: (700 to 1100 mbar)-Ambient temperature sensor: PT100 (-10 to 60°C).

جدول ۲- بازه و دقت اندازه‌گیری‌های انجام‌شده در محاسبات

Table 2- The ranges and accuracies of the measurements of the calculated results

Parameter	Measurement range	Accuracy
Speed	0- 10000 rpm	± 5 rpm
Torque	0- 80 Nm	± 0.05 Nm
Power	0-92 kW	± 0.07 kW
Flow rate	0.1-30 l/h	± 0.02 l/h
SFC	-	-
LHV	-45000	-
Kinematic Viscosity	0.2-20000 mm ² /s	-
Dynamic Viscosity	0.2-20000 mPa.s	-
Density	0.65-3.0 g/cm ³	0.0001 g/cm ³
Humidity	3-99 %	± 0.5 %
Temperatures	0-1000 °C	± 1 °C
Ambient air pressure	700-1100 mbar	± 1 mbar
CO	0-15.0 vol. %	± 0.01 vol. %
CO ₂	0-20.0 vol. %	± 0.01 vol. %
O ₂	0-25.0 vol. %	± 0.01 vol. %
HC	0-30000 ppm vol.	± 1 ppm vol.
NO _x	5000ppm vol.	± 1 ppm vol.

آماده‌سازی سوخت

در پژوهش حاضر، بیودیزل از روغن ضایعات ماهی با استفاده از واکنش ترانس‌استریفیکاسیون تولید شد و خواص آن براساس استاندارد ASTM-D6751 ارزیابی شد. جدول ۳ مشخصات سوخت دیزل و بیودیزل استفاده‌شده در این تحقیق را با اساس استاندارد ASTM نشان می‌دهد. بیواتانول نیز از شرکت کیمیا الکل زنجان با خلوص ۹۹/۸ درصد تهیه شد و در دو سطح ۳ و ۶ درصد به ترکیب سوخت اضافه شد. سپس، نانولوله‌های کربنی عامل‌دار MWCNT-COOH (شکل ۲) با غلظت‌های ۳۰ ppm، ۶۰ و ۹۰ ابتدا با سوخت بیواتانول مخلوط شد. سپس، مخلوط حاضر با استفاده از دستگاه فراصوت (Hielscher UP400S) برای به‌دست‌آوردن یک مخلوط سوخت همگن به سوخت دیزل و B5 (۵ درصد بیودیزل و ۹۵ درصد دیزل) اضافه شد. این مخلوط به مدت ۲۰ دقیقه در همزن التراسونیک قرار گرفتند. در نهایت مخلوط‌های سوخت B0 دیزل خالص، B5 (۵ درصد بیودیزل و ۹۵ درصد دیزل)، B5-E3-MWCNT-COOH30، B5-E3-MWCNT-COOH60، B5-E3-MWCNT-COOH90، B5-E6-MWCNT90، B5-E6-MWCNT60، MWCNT30 برای آزمایش‌ها آماده شد.

جدول ۳- مشخصات بیودیزل و دیزل استفاده‌شده در آزمایش

Table 3- Specifications of the tested biodiesel and diesel

Properties	Diesel	Biodiesel (tested)	biodiesel (Standard)	Units
Flashpoint	164	171	>130	°C
Kinematic viscosity at 40 °C	2.67	4.12	1.9 – 6	mm ² /s
Density	0.827	0.890	0.87-0.9	g/cm ³
Cloud point	-	+9	-3 – 12	°C
Pour point	-	-2	-15 – 10	°C

روش انجام آزمایش

آزمایش‌ها در سه دور موتور ۱۸۰۰، ۲۱۰۰ و ۲۴۰۰ دور بر دقیقه تحت بار کامل و در سه تکرار انجام شد. گشتاور، توان، مصرف سوخت، مصرف سوخت ویژه، دمای گازهای خروجی، دمای محیط و رطوبت محیط برای هر آزمون ثبت شده و تمام داده‌ها به رایانه منتقل شدند. موتور به مدت بیست دقیقه برای اطمینان از حذف سوخت باقی‌مانده در مجاری سوخت از آزمایش قبلی، کار کرد. سپس، داده‌ها برای حدود ۳ دقیقه ثبت شدند. طرحواره راه‌اندازی تجهیزات برای اندازه‌گیری و روش انجام آزمون در شکل ۱ نشان داده شده است.

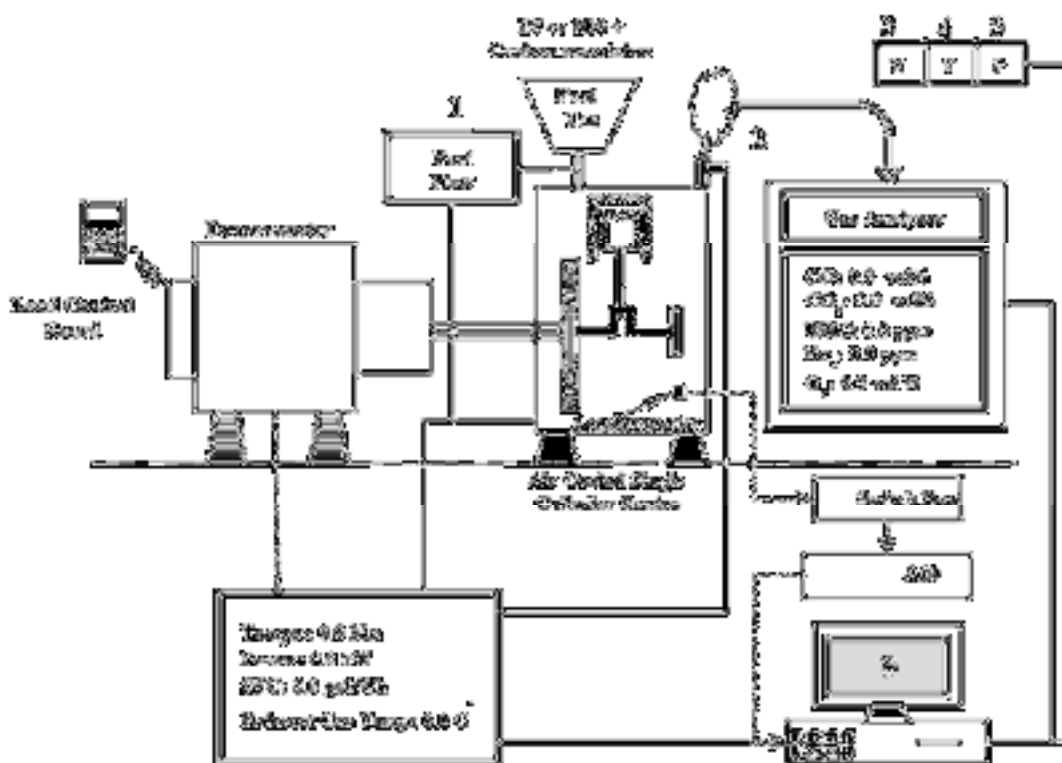


Figure 1- Scheduling of equipment for measurement and testing method: 1) Fuel consumption meter, 2) Gas temperature sensor, 3) Humidity sensor, 4) Ambient temperature sensor, 5) Ambient pressure sensor

شکل ۱- چیدمان وسایل و ابزارهای اندازه‌گیری

۱- مخزن اندازه‌گیری مصرف سوخت، ۲- حسگر دمای گاز، ۳- حسگر رطوبت، ۴- حسگر دمای محیط و ۵- حسگر فشار محیط

شبکه عصبی مصنوعی الگوریتم طبقه‌بندی یک روش پیاده‌سازی مخصوص به خود دارد. بعضی از طبقه‌بندی‌ها یک عدد را مخلوطی از چند کلاس در نظر می‌گیرند و بعضی دیگر یک عدد را فقط به یک کلاس نسبت می‌دهند که دسته اول به طبقه‌بندی کننده نرم و دسته دوم به طبقه‌بندی کننده سخت مشهورند [۱۵]. امروزه برآورد میزان ورودی و خروجی یک کار چنان اهمیتی دارد که امر برنامه‌ریزی و مدیریت آن‌ها به‌عنوان یک ضرورت برای همه کشورها تلقی می‌شود. لذا، در این راستا علوم

سنجش از دور با تکیه بر روش‌های تشخیص الگو، گام‌های مطلوبی را برداشته‌اند [۱۶]. از طرفی، برای بررسی داده‌ها و شبیه‌سازی آن‌ها، شبکه عصبی مصنوعی (ANN) بسیار مناسب است که در واقع مجموعه‌ای از روش‌های ریاضی است که اغلب شامل هوش مصنوعی بوده که به‌نوعی تلاش می‌کند که عملکرد مغز انسان را تقلید کند. در دو دهه گذشته، شبکه عصبی پتانسیل زیادی را در بسیاری از حوزه‌های علم و مهندسی، به‌دلیل عملکرد استثنایی خود، سازمان‌دهی و خودآموزی درونی، پشت‌سرگذاشتن چالش‌ها و استحکام بالا، نشان داده است. اخیراً علاقه به استفاده از شبکه‌های عصبی به‌عنوان ابزار مدل‌سازی در صنعت افزایش یافته است [۱۷]. همچنین، شبکه‌های عصبی مصنوعی یکی از کارآمدترین روش‌ها برای پردازش اطلاعات زیادی هستند که باعث چالش در جنبه‌های مختلف شده است. روند توسعه آن‌ها نشان‌دهنده اهمیت استفاده از این روش برای پردازش اطلاعات است، زیرا در بررسی داده‌ها بسیار موفق بوده‌اند و توانسته‌اند در زمینه‌های مختلف گسترش یابند. همچنین، برای بررسی یک تحقیق که در آن روش‌های پردازش داده‌ها به سبک قدیمی ممکن است اطلاعات نادرستی را در اختیار ما بگذارد و یا هزینه‌های نسبتاً بالایی داشته باشند، استفاده از شبکه عصبی یکی از روش‌های بسیار مناسب است. دو توانایی بسیار مهم شبکه‌های عصبی، یعنی معیارهای پیش‌بینی و طبقه‌بندی، بسیار مورد توجه بوده است. با توجه به قابلیت‌های درونی شبکه عصبی مصنوعی می‌توانند در مصارف کشاورزی با موفقیت استفاده شوند [۱۸]. مطالعه تکنیک‌های پیش‌بینی نشان می‌دهد که اغلب شبکه‌های عصبی مصنوعی استفاده‌شده برای تحلیل متشکل از سه لایه است که شامل لایه ورودی، پنهان و خروجی است. نتیجه خروجی به وزن استفاده‌شده در ارتباط داده‌های خروجی و لایه‌های پنهان متکی است. در طول آموزش و یادگیری یک شبکه، وزن‌هایند که ارزش کار ANN را برای رسیدن به یک نتیجه بسیار نزدیک به خروجی واقعی رقم می‌زنند [۱۹].




Figure 2- Functional nanoparticle MWNT-COOH
شکل ۲- نانولوله‌های کربنی عامل‌دار

مدل‌سازی نتایج با استفاده از شبکه عصبی مصنوعی

در این پژوهش شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) برای مدل‌سازی تأثیر پارامترهای ترکیبات سوختی برای پیشگویی و ارزیابی داده‌ها و عملکرد بهینه موتور انتخاب شد. شبکه عصبی چندلایه پرسپترون یک شبکه پیش‌خور با یک ورودی، یک یا چندلایه پنهان و یک لایه خروجی است. این شبکه توسط ۱ لایه پنهان برای آزمایش انتخاب شد که در هر لایه به ترتیب تعداد ۱۰ ورودی و ۸ خروجی نورون قرار داده و شبیه‌سازی شد که این شبیه‌سازی با استفاده از نرم‌افزار NeuroSolution 5 انجام شد. همچنین، از توابع فعال‌سازی^۲ Liner, Sigmoid, TanhAxon در لایه پنهان ورودی و خروجی استفاده شد. در این

1 Feed-Forward

2 Activation function

تحقیق روش بهینه‌سازی لوببرگ-مارکوت^۱ به منظور یادگیری شبکه مورد استفاده قرار گرفت. همچنین، ۷۰٪ از داده‌ها برای آموزش، ۲۰ درصد برای ارزیابی شبکه^۲ و ۱۰٪ از داده‌ها برای آزمون شبکه^۳ استفاده شد (جدول ۴). ترکیبات سوختی، دور موتور، رطوبت نسبی، فشار محیط، دمای محیط، فشار مجرا، دمای اگزوز، مصرف سوخت، دمای روغن به‌عنوان ورودی‌های شبکه و توان موتور، گشتاور موتور، مصرف سوخت ویژه CO، CO₂، UHC، O₂ و NOx خروجی‌های شبکه مورد نظر بودند. تعداد ۵ تکرار برای شبیه‌سازی داده‌های شبکه عصبی مصنوعی برای رسیدن به حداقل میزان خطا و حداکثر پایداری شبکه به‌صورت میانگین برابر ۴۰۰۰ سیکل یادگیری^۴ برای شبیه‌سازی داده‌ها توسط شبکه عصبی منظور شد و الگوریتم برآورد خطا در شبکه‌های تشکیل شده با استفاده از الگوریتم پسانتشار خطا^۵ صورت گرفت. برای ارزیابی شبکه دو معیار ضریب تبیین (R²) و ریشه میانگین مربعات خطا^۶ استفاده شد. ضریب تبیین میزان همبستگی بین داده‌های خروجی شبکه عصبی و داده‌های مشاهده‌شده را تعیین می‌کند و از رابطه (۲) محاسبه می‌شود که مقدار ایدئال آن برابر یک است. میانگین مربعات خطا اختلاف بین داده‌های پیش‌بینی شده و داده‌های واقعی را تعیین می‌کند (رابطه (۴)) و ریشه آن از رابطه (۵) محاسبه می‌شود. هدف یک شبکه خوب این است که میزان این خطا را به کمترین مقدار برساند و مقدار ایدئال آن برابر صفر است. پارامترهای آماری شامل میانگین مربعات خطا (MSE)^۷، ریشه میانگین مربعات خطا، ضریب تبیین، میانگین خطای مطلق (MAE)^۸ برای ورودی‌ها محاسبه شد و روابط با استفاده از فرمول‌های جدول ۵ محاسبه شد.

ساختار شبکه عصبی مورد استفاده در این تحقیق در شکل ۳ نشان داده شده است.

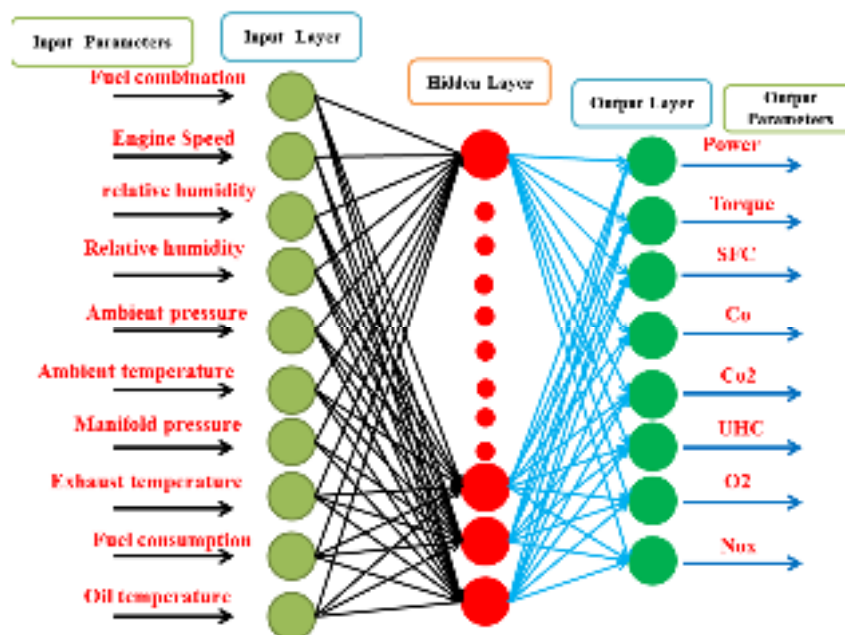


Figure 3- Schematic diagram of artificial neural network

شکل ۳- نمودار طرحواره شبکه عصبی مصنوعی

- 1Levenberg–Marquardt (LM)
- 2Validating data
- 3Testing data
- 4Epoch
- 5Back propagation error
- 6(RMSE(Root mean squared error)
- 7Mean Square Error (MSE)
- 8Mean Absolute Error (MAE)

جدول ۴- پارامترهای بهینه‌شده شبکه عصبی مصنوعی

Figure4- Optimization values for artificial neural network parameters

Number of hidden layers	Learning rule	Type of activation function	The number of hidden layer neurons	Testing data %	Validating data %	Training data %
1	Levenberg Marquardt	Hyperbolic tangent	10 -8	10%	20%	70%
1	Levenberg Marquardt	Sigmoid	10 -8	10%	20%	70%
1	Levenberg Marquardt	Liner	10 -8	10%	20%	70%

جدول ۵- روابط شبکه عصبی

Table 5- Neural Network Relationships

Formula	Formula Number	Reference
$\tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	(1)	[20]
$\text{sig } x = \frac{1}{1 + e^{-x}}$	(2)	[21]
$R^2 = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{(P_i - O)^2}$	(3)	[22]
$r = \sqrt{1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{(P_i - O)^2}}$	(4)	[22]
$MSE = \sum_{i=1}^n \frac{(P_i - O_i)^2}{n}$	(5)	[23]
$RMSE = \sqrt{\sum_{i=1}^n \frac{(P_i - O_i)^2}{n}}$	(6)	[23]
$MAE = \frac{\sum_{i=1}^n P_i - O_i }{n}$	(7)	[25]

نتایج و بحث

نتایج تحلیل‌های شبکه عصبی

با توجه به نتایج به‌دست‌آمده از جدول شبکه عصبی می‌توان بیان کرد که بهترین مقدار R برای توان موتور، مصرف سوخت و ویژه، مونواکسیدکربن، دی‌اکسیدکربن، اکسیژن و اکسید نیتروژن در زمانی بوده است که شبکه با تابع آموزش سیگموئیدی کار کرده است و در همین شبکه نیز کمترین مقدار برای توان مورد استفاده قرار گرفته است. برای حالت گشتاور موتور و هیدروکربن‌های نسوخته بهترین مقدار R در شبکه آموزش دیده‌شده با liner بوده است. همچنین، با توجه به جدول می‌توان بیان کرد که شبکه ایجادشده با تابع فعال‌سازی سیگموئیدی و تانژانت هیپربولیک میزان R قابل قبولی را داشته است که این مورد برای تابع فعال‌سازی Liner قابل قبول بوده است. میزان MSE در دو شبکه تشکیل‌شده با تانژانت هیپربولیک و liner بسیار بیشتر از شبکه تشکیل‌شده با تابع فعال‌سازی سیگموئیدی بوده است. در جدول ۶ میزان خروجی‌های داده‌های شبکه برای تمامی پارامترها نشان داده شده است.

همچنین، در جدول ۷ بهترین شبکه بین اطلاعات ورودی و داده‌های شبیه‌سازی‌شده توسط شبکه برای هر یک از توابع فعال‌سازی در لایه پنهان نشان داده شده است که هرچه میزان تکرار (Epoch) پایین‌تر باشد نشان‌دهنده این امر است که آن تابع فعال‌سازی توانسته است یادگیری سریع‌تری را از شبکه عصبی نسبت به توابع فعال‌سازی دیگر داشته باشد. همان‌طور که از جدول ۷ مشاهده می‌شود بهترین شبکه در داده‌های آموزش (Run=1, Epoch=16) با تابع فعال‌سازی Liner بعد از گذشت تقریباً ۱۶ نسل خطا به مقدار ثابتی می‌رسد و برای داده‌های ارزشیابی (Run=3, Epoch=8) با تابع فعال‌سازی sigmoid بعد از گذشت تقریباً ۸ نسل خطا به مقدار ثابتی می‌رسد. اما، با توجه به مقدار اجرا و سرعت یادگیری شبکه را نمی‌توان انتخاب کرد و

فاکتورهای دیگری مانند R^2 ، MSE و MAE وجود دارد که باید مورد بررسی قرار گیرد و با توجه به همین فاکتورها و جدول بالا باید شبکه سیگموئیدی را انتخاب کنیم چراکه توانسته در اجرا ۱ شبکه را ایجاد کند و فقط مقادیر تکرار آن بیشتر است و درواقع این شبکه، شبکه‌ای قابل قبول برای ما بوده است.

جدول ۵- برخی از بهترین توپولوژی‌های شبکه عصبی MLP برای پیش‌بینی مقادیر آزمون

Table 5- Some of the best MLP neural network topologies to predict train value

Sigmoid								
Performance	power	Turque	SFC	CO	CO ₂	UHC	O ₂	NO _x
MSE	0.0818	0.6689	744.9403	0.0225	0.0596	36.2330	0.0576	125.1095
NMSE	0.1456	0.1958	0.1796	0.3268	0.3268	0.1113	0.0285	0.0945
MAE	0.2215	0.6767	22.6775	0.1217	0.2051	4.6252	0.1958	9.0346
Min Abs Error	0.0131	0.0913	5.0149	0.0125	0.0025	0.2664	0.0089	0.3675
Max Abs Error	0.7999	1.6437	63.0354	0.3359	0.3855	15.9205	0.4451	21.7144
R ²	0.9494	0.9417	0.9208	0.8243	0.8400	0.9516	0.9891	0.9535
Hyperbolic tangent								
MSE	0.1551	2.4076	1034.7466	0.0728	0.1251	64.3319	0.8248	334.7495
NMSE	0.3137	0.6219	0.2268	1.2732	0.7190	0.1742	0.3737	0.2821
MAE	0.3035	1.2852	25.9557	0.1995	0.2867	6.4985	0.7014	15.1675
Min Abs Error	0.0032	0.2270	5.9458	0.0006	0.0128	0.5324	0.0061	0.2899
Max Abs Error	1.0757	3.0036	79.6401	0.6643	0.6719	15.8035	1.8537	35.3336
R ²	0.9437	0.8670	0.9174	0.3459	0.6505	0.9244	0.9188	0.9168
Liner								
MSE	0.4855	0.9272	2032.9553	0.0452	0.1144	68.3673	0.3900	837.0596
NMSE	0.8534	0.2753	0.5045	0.7212	0.7869	0.1766	0.1842	0.5632
MAE	0.5762	0.8806	37.2059	0.1765	0.2090	6.8282	0.5304	24.8656
Min Abs Error	0.0307	0.0189	4.8576	0.0124	0.0000	0.5077	0.0568	0.7154
Max Abs Error	1.1797	1.6015	103.6646	0.3870	0.8935	15.6484	1.4376	47.0640
R ²	0.5077	0.9715	0.7474	0.7535	0.6633	0.9471	0.9797	0.6665

جدول ۷- مقادیر اجرای و تکرار داده‌ها برای ایجاد شبکه.

Table 7- Values of Run and Repeat at different network types

Network type		Training	Evaluation
Sigmoid	Run	1	3
	Repeat	207	8
Tangent hyperbolic	Run	1	4
	Repeat	1163	7
Liner	Run	1	4
	Repeat	16	3

ضریب حساسیت پیش‌بینی شده توسط شبکه عصبی

در شکل ۴ نتایج حاصل از تحلیل‌های حساسیت شبکه عصبی برای پارامترهای خروجی نشان داده شده است. با توجه به نتایج به‌دست‌آمده توان موتور، گشتاور موتور، CO و O₂ بیشترین ضریب حساسیت نسبت به ترکیبات سوختی نشان داده است و از بین شبکه‌های آموزش داده‌شده شبکه‌ای با تابع فعال‌سازی Liner بیشترین مقدار را دارد. همچنین، تمامی توابع فعال‌سازی ضریب حساسیت بالاتری را به ترکیبات سوخت نسبت داده‌اند. نتایج تحلیل ضریب حساسیت برای مصرف سوخت ویژه و هیدروکربن‌های سوخته نشده نشان داد که این فاکتورها به دور موتور وابستگی بیشتری نسبت به ترکیبات سوخت داشته‌اند و تابع فعال‌سازی تانژانت هیپربولیک نیز بیشترین ضریب حساسیت را نشان داده است و در مجموع دور موتور در هر سه تابع فعال‌سازی و تحلیل شبکه بیشترین میزان ضریب حساسیت را داشته است. برای CO₂ و NO_x نیز بیشترین ضریب حساسیت برای ترکیبات سوخت بوده است که در تابع فعال‌سازی سیگموئیدی مشاهده شده است و در این فاکتورها نیز ضریب حساسیت ترکیبات سوخت در هر سه تابع فعال‌سازی تأثیر بیشتری نسبت به دور موتور داشته است.

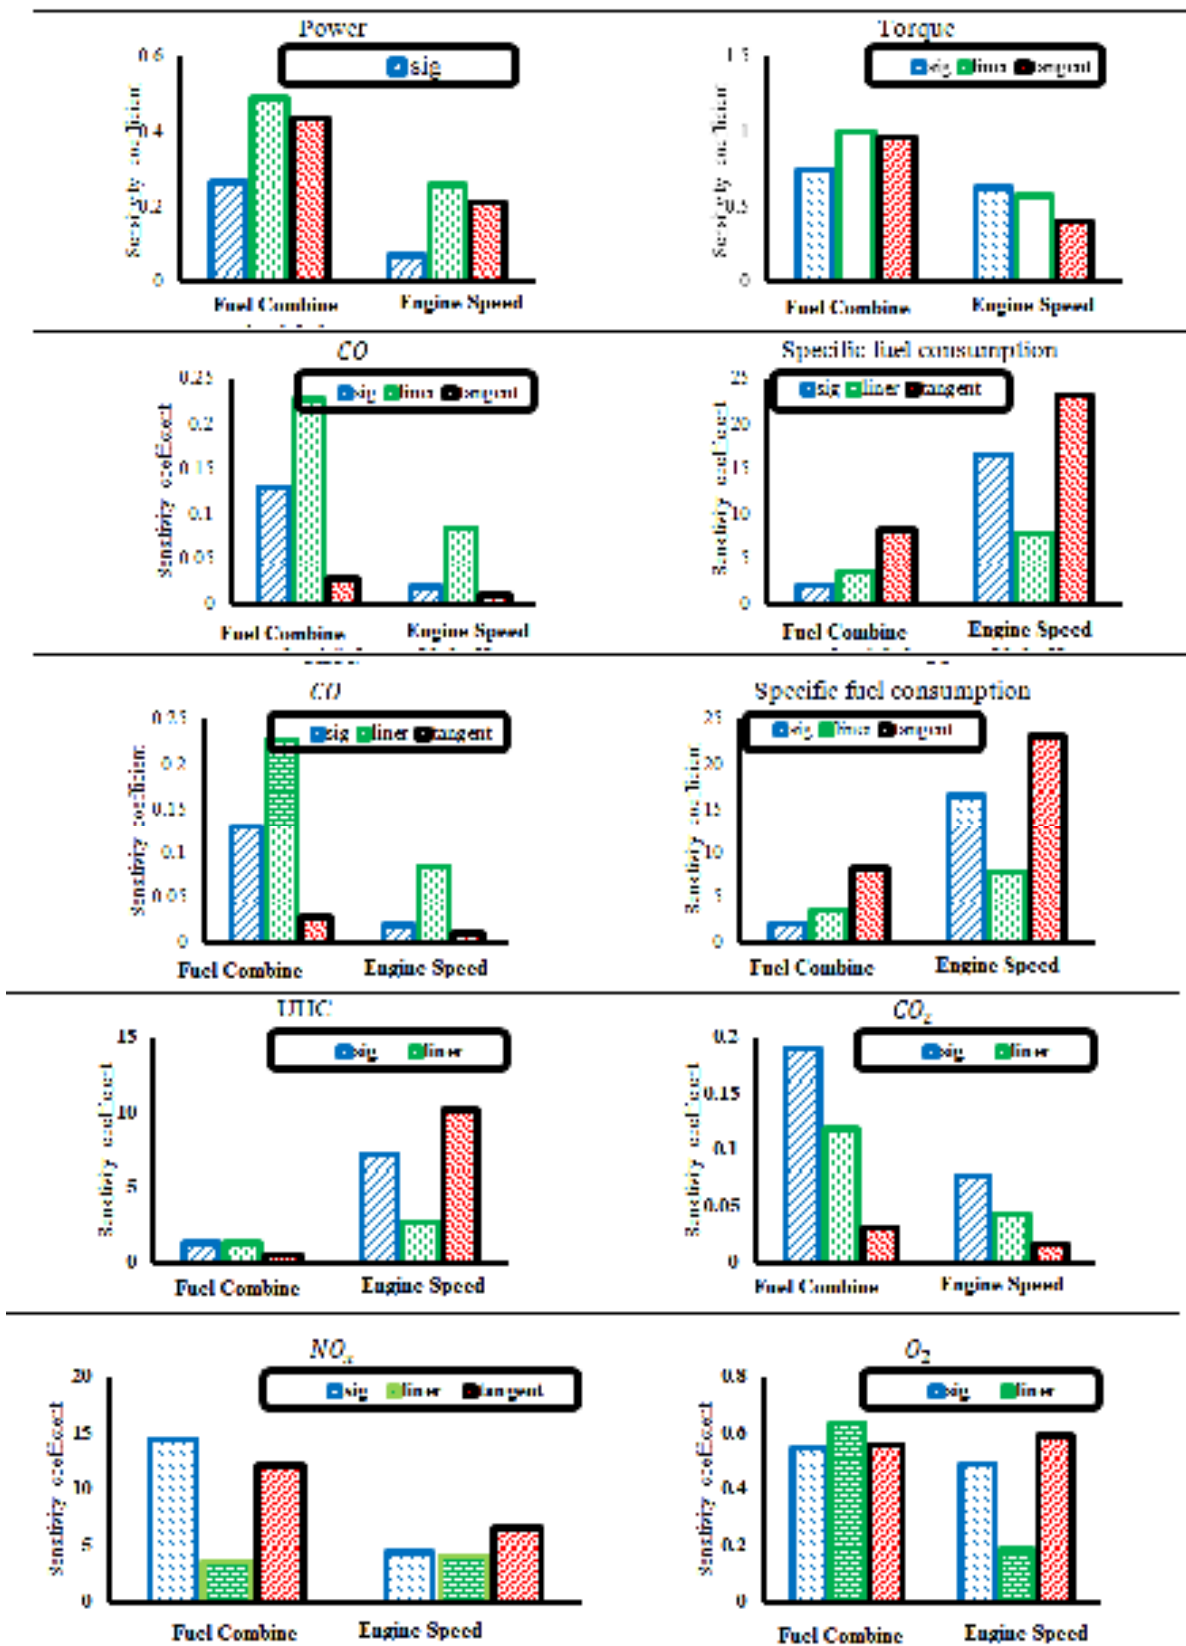


Figure 4- Sensitivity coefficient of output parameters relative to fuel combinations and engine speeds

شکل ۴- ضریب حساسیت بررسی شده پارامترهای خروجی نسبت به ترکیبات سوخت و دور موتور

علاوه بر این، شکل ۵، ۶ و ۷ مقادیر خروجی بین داده‌های واقعی و پیش‌بینی شده را نشان می‌دهد. می‌توان مشاهده کرد که براساس این داده‌ها شبکه عصبی به‌خوبی قادر به پیش‌بینی و مقایسه اعداد واقعی است. همچنین، می‌توان اظهار داشت که با توجه به نزدیکی و شباهت اعدادی که از شبکه عصبی مصنوعی به‌دست می‌آید با داده‌های واقعی، در تحلیل‌های بعدی، از شبکه عصبی مصنوعی استفاده کرد. علاوه بر این، با توجه به مقدار R^2 ، شبکه با تابع فعال‌سازی سیگموئید دارای بهترین همپوشانی با داده‌های واقعی است.

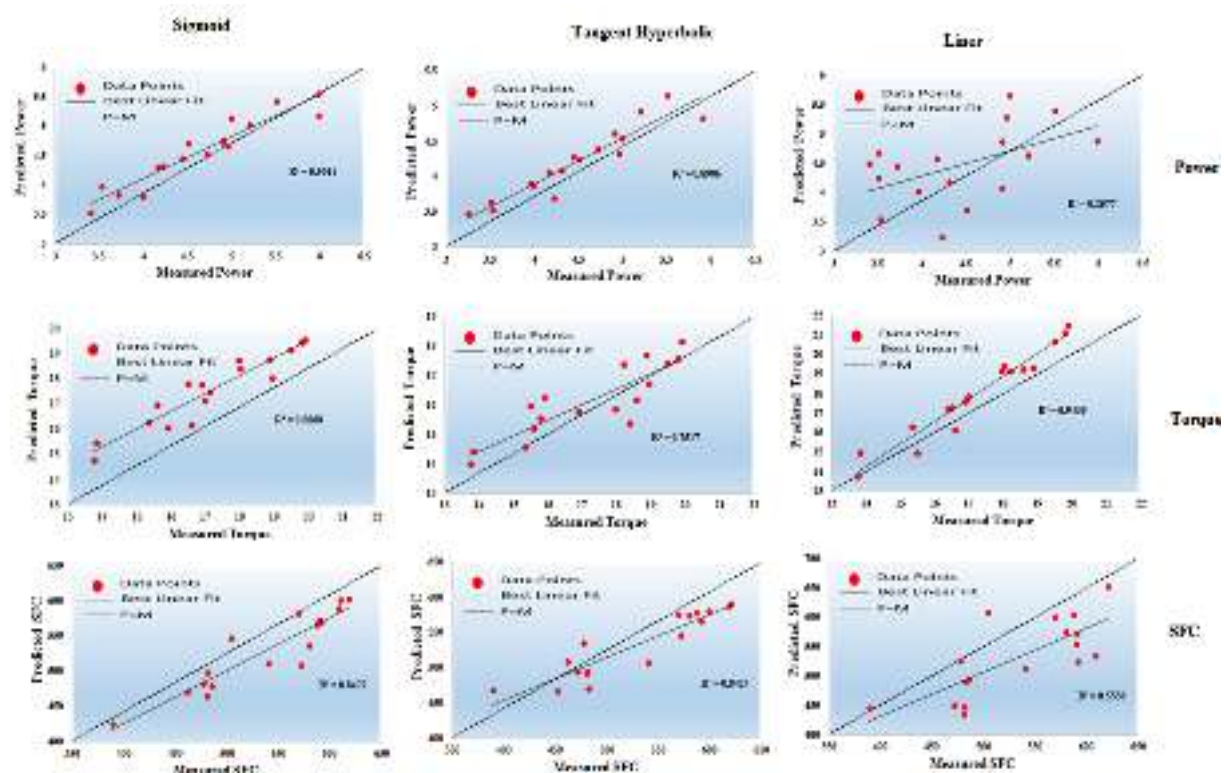


Figure 5- Comparison of predicted and actual data for engine power, torque and specific fuel consumption

شکل ۵- مقایسه داده‌های پیش‌بینی شده و واقعی برای توان موتور، گشتاور و مصرف سوخت ویژه

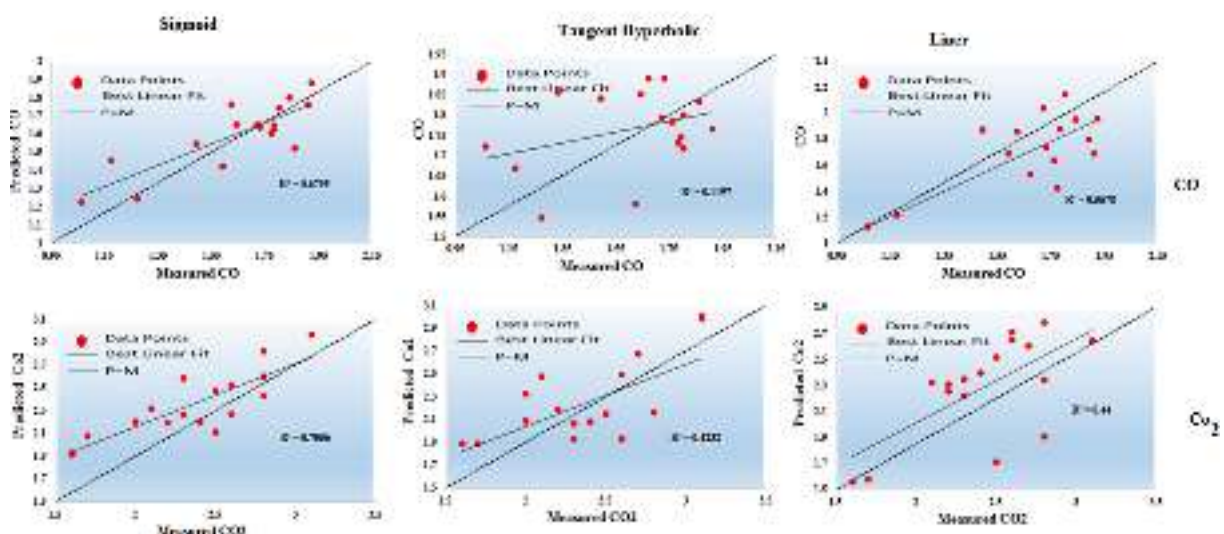


Figure 6- Comparison of predicted and actual data for CO, CO2 and UHC

شکل ۶- مقایسه داده‌های پیش‌بینی شده و واقعی برای CO_2 ، CO و UHC

شکل ۸ نشان‌دهنده نمودار روند آموزش با استفاده از سه تابع فعال‌سازی Sigmoid، Tangent hyperbolic و Liner است. روند آموزش هنگام استفاده از هر سه تابع همگرا شده‌اند.

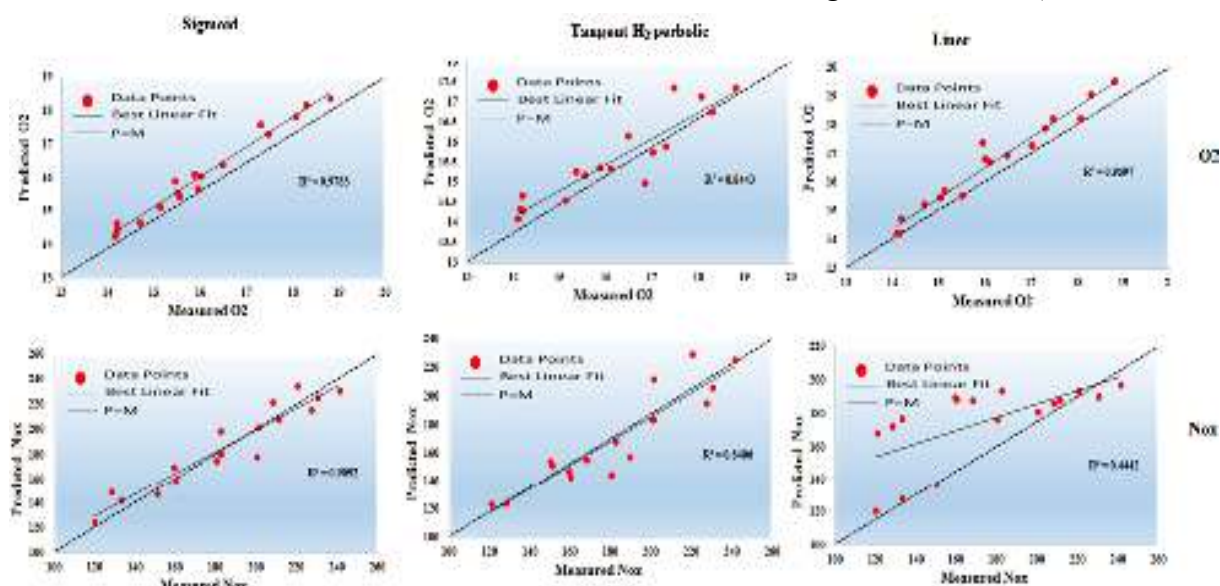



Figure 7- Comparison of predicted and actual data for O₂ and Nox
شکل ۷- مقایسه داده‌های پیش‌بینی شده و واقعی برای O₂ و NOx



تابع فعال سازی Liner

تابع فعال سازی Tangent hyperbolic

تابع فعال سازی Sigmoid

Figure 8- Training process diagram using Sigmoid, Tangent hyperbolic and Liner activation functions

شکل ۸- نمودار روند آموزش با استفاده از سه تابع فعال‌سازی Sigmoid، Tangent hyperbolic و Liner

نتیجه‌گیری

با توجه به نتایج به‌دست‌آمده از شبکه عصبی مصنوعی، شبکه تشکیل شده با تابع آموزش سیگموئیدی، به دلیل اینکه میزان R^2 و MSE بهتری نسبت به شبکه‌های تشکیل شده خطی و تانژانت هیپربولیک دارد، بهترین شبکه بوده است و با توجه به اینکه میزان R این شبکه برای همه خروجی‌ها بالای 0.80 بوده است می‌توان آن را یک شبکه مناسب برای تشکیل و بررسی داده‌ها معرفی کرد و شبکه‌ای قابل قبولی بوده است. همچنین، با توجه به نتایج یادگیری شبکه عصبی مصنوعی و ایجاد شبکه در کمترین میزان تکرار، شبکه با تابع آموزش خطی توانسته کمترین میزان تکرار در ایجاد شبکه را داشته باشد، اما با توجه به اینکه میزان R^2 و MSE این شبکه نامناسب بوده است از تشکیل سریع این شبکه صرف‌نظر شده است. تحلیل ضریب حساسیت نیز نشان داد که تأثیر نوع ترکیبات سوخت از دور موتور برای فاکتورهای خروجی مورد نظر بیشتر بوده و فقط در بین فاکتورها نتیجه‌ای عکس برای هیدروکربن‌های سوخته‌نشده مشاهده شده است. در مجموع شبکه عصبی مصنوعی سیگموئیدی بهترین شبکه از بین شبکه‌های تشکیل شده بوده است.

منابع

1. A. Taghizadeh-Alisaraei, H. A. Assar, B. Ghobadian and A. Motevali, "Potential of biofuel production from pistachio waste in Iran," *Renewable and Sustainable Energy Reviews*, Vol. 72, 2017, pp. 510-522.
2. A. K. Agarwal, "Biofuels (alcohols and biodiesel) applications as fuels for internal combustion engines," *Progress in Energy and Combustion Science*, Vol. 33, 2007, pp. 233-71.
3. J. Chen, R. Bond Randall and R. Bond, "Improved automated diagnosis of misfire in internal combustion engines based on simulation models," *Mechanical Systems and Signal Processing*, Vol. 64-65, 2015, pp. 58-83.
4. Z. H. U. Jian-yuan and J. Y. Zhu, "Detection of cylinder pressure in diesel engines using cylinder head vibration and time series methods," *Journal of Marine Science and Application*, Vol. 6, 2007, pp. 8-12.
5. A. Kirillov, O. Kirillova and S. Kirillov, "Algorithmic method of analysis of time series data for definition of prognostic parameters of engine fault," *3rd International Conference on Advanced Computer Control (ICACC)*, Harbin, 2011, pp. 138-142.
6. M. K. D. Kiani et al., Application of artificial neural networks for the prediction of performance and exhaust emissions in SI engine using ethanol- gasoline blends," *Energy*, Vol. 35, 2010, pp. 65-69.
7. B. Ghobadian, H. Rahimi, A. M. Nikbakht, G. Najafi and T. F. Yusaf, "Diesel engine performance and exhaust emission analysis using waste cooking biodiesel fuel with an artificial neural network," *Renewable energy*, Vol. 34, No. 4, 2009, pp. 976-982.
8. R. Beale and T. Jackson, *Neural Computing: An Introduction*, Taylor and france, CRC Press, 1998.
9. M. Menhaj, *Foundation of Artifitioal Neural Networks*, Master Section, Computer departmaent, Amir Kabir univercity, 2000.
10. M. Fathi, M. Mohebbi and S. M. A. Razavi. "Application of Image Analysis and Artificial Neural Network to Predict Mass Transfer Kinetics and Color Changes of Osmotically Dehydrated Kiwifruit," *Food and Bioprocess Technology*, Vol. 4, 2011, pp. 1357-66.
11. L. Pan, Q. Zhang, W. Zhang, Y. Sun, P. Hu and K. Tu. "Detection of cold injury in peaches by hyperspectral reflectance imaging and artificial neural network," *Food Chemistry*, Vol. 192, 2016, pp. 134-41.
12. M. Canakci, A. Erdil and E. Arcaklioglu, "Performance and exhaust emissions of a biodiesel engine," *Applied Energy*, Vol. 83, 2006, pp. 594-605.
13. M. Dehghani , B. Ghobadian, Gh. Najafi, M. R. Sabzemaleki and F. Jaliliantabar, "Performance and Exhaust Emissions of a SI Two-stroke Engine with Biolubricants using Artificial Neural Network," *Energy Procedia*, Vol. 75, 2015, pp. 3-9.
14. S. H. Hoseini, A. Taghizadeh, B. Ghobadian and A. Abaszadeh, "Modeling the effects of Carbon nanotubes added to diesel-biodiesel fuel blends on performance and emissions of a diesel engine using artificial neural network," *Fuel and combisution Journal*, Vol. 10, 2017, pp. 1-16.
15. S. Das, A. Routray and A. K. Deb, "Hyperspectral Unmixing by Nuclear Norm Difference Maximization based Dictionary Pruning," *14th IEEE India Council International Conference*, Roorkee, India, (INDICON), 2017, pp. 1-5.
16. E. Johnston BAS, *Design, Optimization and Testing of a Combined Tri-Axial Polarized Energy Dispersive X-Ray Fluorescence and Energy Dispersive X-Ray Diffraction System for Biological Sample Classification*, Doctor of Philosophy section, McMaster University.
17. H. Lu, H. Zheng, H. Lou, L. Jiang, Y. Chen and S. Fang. "Using neural networks to estimate the losses of ascorbic acid, total phenols, flavonoid, and antioxidant activity in asparagus during thermal treatments," *Journal of Agricultural and Food Chemistry*, Vol. 58, 2010, pp. 2995-3001.
18. A. Hosu, C. M. Cristea, C. Cimpoiu, "Analysis of total phenolic, flavonoids, anthocyanins and tannin content in Romanian red wines: Prediction of antioxidant activities and classification of wines using artificial neural networks," *Food Chemistry*, Vol. 150, 2014, pp. 113-8.
19. W. A. Balogun, M. E. Salami, Aibinu, Y. M. Mustafah and S. SIB, "Mini Review: Artificial Neural Network Application on Fruit and Vegetables Quality Assessment," *International Journal of Scientific & Engineering Research*, Vol. 5, 2014, pp. 702-8.
20. B. Soleimanzadeh, H. Hemati, M. Yolmeh and F. Salehi, "GA-ANN and ANFIS models and salmonella enteritidis inactivation by ultrasound," *Journal of Food Safety*, Vol. 35, 2015, pp. 220-6.
21. F. Salehi, A. Gohari Ardabili, A. Nemati, "Latifi Darab R. Modeling of strawberry drying process using infrared dryer by genetic algorithm-artificial neural network method," *Journal Food Science and Technology*, Vol. 14, 2017, pp. 105-14.
22. M. Azadbakht, M. Vahedi Torshizi and A. Ziaratban, "Application of Artificial Neural Network (ANN) in predicting mechanical properties of canola stem under shear loading," *Agricultural Engineering International: CIGR Journal*, Vol. 18, 2016, pp. 413-24.
23. F. Salehi and S. M. A. Razavi. "Dynamic modeling of flux and total hydraulic resistance in nanofiltration treatment of regeneration waste brine using artificial neural networks," *Desalination and Water Treatment*, Vol. 41, 2012, pp. 95-104.
24. B. Khoshnevisan, Sh. Rafiee and M. Omid. "Prediction of environmental indices of Iran wheat production using artificial neural networks," *International Journal of Energy and Environment*, Vol. 4, 2013, pp. 339-48.
25. M. Azadbakht, H. Aghili, A. Ziaratban and M. Vehedi Torshizi. "Application of artificial neural network method to exergy and energy analyses of fluidized bed dryer for potato cubes," *Energy*, Vol. 120, 2017, pp. 947-58.

English Abstract

Modeling the effect of adding oxygen functionalized multi-walled carbon nanotube to diesel, biodiesel, and bioethanol fuel blends on performance and emission of a diesel engine using artificial neural network

Leila Shakeri¹, Ali Asghari^{2*} and Ahmad Taghizadeh-Alisaraei³

1- Biosystems Engineering Dept., Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran, leilashakeri96@gmail.com

2- Biosystems Engineering Dept., Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran, aliasghari809@gmail.com

3- Biosystems Engineering Dept., Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran, ahmadtza@yahoo.com

*Corresponding author

(Received: 2020.1.19, Received in revised form: 2020.3.10, Accepted: 2020.4.2)

Blended biofuels such as biodiesel and bioethanol besides adding carbon nanotubes as catalyst to diesel fuel significantly improve the engine performance and reduce emissions. In this study, biodiesel (5%) was initially added to the diesel fuel to evaluate engine performance and its emissions. The studied fuels were prepared as MWENT-COOH nanoparticles (30, 60, and 90 ppm) were added to the fuels of B5 (5% biodiesel and 95% diesel) and E6 (6% bioethanol and 94% diesel) and E3 (3% bioethanol and 97% diesel). Experiments were performed in triplicates and a multilayer feed-forward back-propagation (FFBP) artificial neural network (ANN) was used for modeling the obtained results. Fuel type, engine speed, density, viscosity, the thermal value of the fuel, inlet manifold pressure, fuel consumption, exhaust gas temperature, oil temperature, oxygen in the exhaust gases, relative humidity and pressure of inlet air were considered as independent or inlet layer parameters. Output layer parameters included engine performance and emission. The results represented the decrease in emissions of CO and unburned hydrocarbons and specific fuel consumption as well as an increase in nitrogen oxides emissions. Considering the regression coefficient (R^2) and MSE, the ANN model based on the sigmoid learning function was introduced as the optimal one in comparison to the linear and hyperbolic tangent networks. The values of R^2 were also obtained for training, evaluation, and testing of the optimal network model. In conclusion, it can be mentioned that ANN was the most effective model in simulating the obtained data and investigating the sensitivity coefficient.

Keywords: Engine performance, Engine emissions, Carbon nanotubes, Artificial neural network modeling