

## مدل سازی اثر نanolوله‌های کربن اضافه شده به مخلوط سوخت دیزل-بیودیزل بر عملکرد و آلایندگی یک موتور دیزل با استفاده از شبکه عصبی

سید حسن حسینی<sup>۱</sup>، احمد تقی‌زاده علی‌سرابی<sup>۲\*</sup>، برات قبادیان<sup>۳</sup> و احمد عباس‌زاده مایوان<sup>۴</sup>

۱- کارشناس ارشد، مهندسی مکانیک بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، ho3eini1991@gmail.com

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

۳- استاد، مهندسی مکانیک بیوسیستم، دانشگاه تربیت مدرس تهران، ghobadiab@modares.ac.ir

۴- استادیار، مهندسی مکانیک بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، abbaszadeh62@gmail.com

\* نویسنده مخاطب

(تاریخ دریافت: ۱۳۹۶/۴/۸، دریافت آخرین اصلاحات: ۱۳۹۶/۴/۱۷، پذیرش: ۱۳۹۶/۶/۱)

**چکیده:** بیودیزل و همچنین برخی نانوکاتالیست‌ها به عنوان افزودنی به سوخت دیزل می‌تواند باعث بهبود عملکرد و کاهش آلایندگی موتور شود. در تحقیق حاضر، بیودیزل با نسبت ۵ و ۱۰ درصد (B5 و B10) در مخلوط با سوخت دیزل استفاده شد. سپس نanolوله‌های کربن با غلظت ۳۰، ۶۰ و ۹۰ ppm به مخلوط سوخت برای ارزیابی عملکرد، آلایندگی و ارتعاش موتور دیزل استفاده شد. از شبکه عصبی چندلایه با قاعده یادگیری پس‌انتشار خطا رو به جلو (FFBP) برای مدل سازی استفاده شد. نوع سوخت، دور موتور، چگالی، گرانزوی و ارزش حرارتی سوخت، فشار چندراده ورودی، مصرف سوخت، دمای گازهای خروجی، اکسیژن موجود در گازهای خروجی، دمای رون، رطوبت و فشار نسبی هواي محیط به عنوان پارامترهای لایه ورودی یا مستقل درنظر گرفته شدند. عملکرد، آلایندگی و ارتعاش موتور به عنوان پارامترهای لایه خروجی در نظر گرفته شدند. نتایج نشان داد که مصرف سوخت ویژه موتور و آلایندگی‌های CO و UHC کاهش یافته، در حالی که آلایندگی NO<sub>x</sub> افزایشی بوده است. همچنین، مدل شبکه عصبی با الگوی آموزش پس‌انتشار خطا با ۲۰-۲۰ نرون در لایه‌های مخفی سیگموئیدی-سیگموئیدی توانایی پیش‌بینی پارامترهای مختلف را با عملکرد و دقیق خوبی دارد. مقادیر عددی ضریب رگرسیونی (R) آموزش، ارزیابی و آزمون مدل بهینه شبکه به ترتیب ۰/۹۹۸۵، ۰/۹۹۹۹ و ۰/۹۹۹۴ به دست آمد.

**کلیدواژگان:** بیودیزل، نanolوله‌های کربن، آلایندگی، ارتعاش، شبکه عصبی

### مقدمه

کاهش استفاده از سوخت‌های فسیلی به طور قابل توجهی می‌تواند انتشار آلایندگی‌های مضر را کاهش دهد که این امر می‌تواند با جایگزینی سوخت‌های تجدیدپذیر محقق شود. منابع پایدار انرژی‌های تجدیدپذیر نقش مهمی در آینده انرژی جهان دارند[۱]. بیودیزل به عنوان سوخت زیستی پایدار و تجدیدپذیر است که می‌تواند از رونق‌های گیاهی، چربی‌های حیوانی و رون حاصل از میکروجلبک‌ها تولید شود. این سوخت می‌تواند به جای سوخت دیزل بدون هیچ‌گونه تغییرات ویژه‌ای در موتورها استفاده شود[۲،۳]. عملکرد، آلایندگی، احتراق و ارتعاش موتورهای اشتعال تراکمی و جرقه‌ای در تحقیقات مختلف بررسی شده است[۴،۵]. تحقیقات اخیر نشان داده است که استفاده از بیودیزل میزان هیدروکربن‌های نسوخته، دی‌اکسیدکربن، مونوکسیدکربن، اکسیدهای گوگرد و ذرات جامد خروجی از اگزوز موتور را کاهش می‌دهد و تنها مقدار اکسیدهای نیتروژن (NO<sub>x</sub>) را افزایش داده که می‌تواند از طریق تنظیم زمان پاشش سوخت کاهش یابد[۵].

از سوی دیگر، افروden نانوذرات و یا نانوکاتالیزور به مخلوط سوخت دیزل-بیودیزل باعث بهبود عملکرد، آلایندگی موتور و خواص فیزیکی-حرارتی سوخت مانند افزایش نسبت سطح به حجم، هدایت حرارتی و بهبود نفوذ توده سوخت شده است [۶]. تحقیقات مختلف نشان می‌دهد که افروden مواد نانو به سوخت دیزل، بیودیزل و مخلوط سوخت دیزل-بیودیزل باعث افزایش نقطه اشتعال، گرانروی سینماتیکی و ویژگی‌های دیگر آن شده است [۷]. از نظر اثرات مکانیکی، ارتعاش ناشی از فرایند احتراق در موتور می‌تواند اثرات مستقیم بر دوام و سایش قطعات موتور داشته باشد. پاشش انژکتور، زمان پاشش، مقدار، نوع سوخت [۸،۹] و دینامیک احتراق [۱۰] در موتورهای احتراق اشتعال تراکمی و جرقه‌ای بر ارتعاش بدن موتور مؤثر است [۱۰،۱۱]. به عنوان مثال، افروden بیودیزل به مخلوط سوخت دیزل-بیودیزل، به دلیل احتراق و نوسانات فشار داخل سیلندر، باعث تغییر در ارتعاش بدن موتور می‌شود [۱۱،۱۲].

شبکه‌های عصبی مصنوعی [۱۲] و سری‌های زمانی [۱۳-۱۵] برای شبیه‌سازی و پایش وضعیت سیستم استفاده می‌شوند. شبکه‌های عصبی مصنوعی برای حل انواع گسترهای از مشکلات در علوم و مهندسی، به ویژه برای برخی از مسائل که در آن روش‌های مدل‌سازی متعارف قادر به پاسخ‌گویی نیست، مورد استفاده قرار گرفته‌اند. توانایی پیش‌بینی یک شبکه عصبی مصنوعی نتیجه آموزش داده‌های تجربی و سپس اعتبارسنجی با استفاده از داده‌های مستقل است. اگر داده‌های جدید در دسترس باشد، یک شبکه عصبی مصنوعی توانایی دوباره یادگیری برای بهبود عملکرد خود را دارد [۱۶،۱۷]. مدل‌های شبکه عصبی می‌توانند متغیرهای ورودی متعدد را برای پیش‌بینی متغیرهای خروجی متعدد تطبیق دهند. مدل‌سازی شبکه عصبی با روش‌های متعارف دیگر متفاوت است و توانایی یادگیری درباره سیستم را بدون داشتن اطلاعات قبلی از آن دارد [۱۷]. چند نمونه از پژوهش‌های انجام شده در مورد کاربرد شبکه عصبی در تحلیل پارامترهای موتور در زیر آمده است.

کاتانکسی و همکاران کاربرد شبکه عصبی مصنوعی با مخلوط سوخت بیودیزل و دیزل را بر عملکرد و آلایندگی در یک موتور دیزل بررسی کردند. در شبکه مورد نظر، میانگین وزن مولکولی، حرارت خالص احتراق، وزن مخصوص، گرانروی سینماتیکی، نسبت کربن به هیدروژن ( $C/H$ ) و عدد ستان‌هر سوخت به عنوان لایه ورودی استفاده شدند. در حالی که مصرف سوخت ویژه، دمای گازهای خروجی و آلایندگی موتور به عنوان پارامترهای خروجی در نظر گرفته شدند. مقدار  $R$  برای عملکرد ۰/۹۹ و مقدار میانگین خطاهای داده‌های آموزش کمتر از  $4/2$  درصد به دست آمد. برای داده‌های ارزیابی، مقدار  $R$  برابر با  $0/99$  و میانگین خطاهای کمتر از  $5/5$  درصد محاسبه شد [۱۸]. دهقانی و همکاران عملکرد و آلایندگی موتور اشتعال جرقه‌ای دوزمانه را با استفاده از بیوروانکارها به کمک شبکه عصبی مصنوعی ارزیابی کردند. نوع روانکار، لامبادا و سرعت موتور پارامترهای ورودی مدل را تشکیل دادند. توان ترمیزی موتور، گشتاور، مصرف سوخت ویژه و گازهای خروجی به عنوان پارامترهای خروجی مدل استفاده شده در نظر گرفته شدند. شبکه چندلایه (MLP)<sup>۱</sup> با ساختار  $8-25-3$  نرون در لایه‌های خروجی-۲۵ نرون در لایه‌های مخفی-۳ نرون در لایه‌های ورودی برای عملکرد و آلایندگی ایجاد شد. نتایج نشان داد که روش شبکه عصبی مصنوعی مسائل موتورهای احتراق داخلی را با دقت خوبی پیش‌بینی می‌کند [۱۹].

پژوهش دیگری توسط قبادیان و همکاران به منظور پیش‌بینی عملکرد و آلایندگی یک موتور دیزل دوسیلندر چهارزمانه با استفاده از بیودیزل حاصل از روغن پسماند خوارکی صورت گرفت [۱۷]. کاپوسوز و همکاران از شبکه عصبی برای پیش‌بینی گشتاور، توان ترمیزی و مصرف سوخت ویژه در موتور اشتعال جرقه‌ای استفاده کردند. نتایج نشان داد که مقدار  $R$  برای گشتاور، توان ترمیزی و مصرف سوخت ویژه به ترتیب  $0/9906$ ،  $0/9912$  و  $0/9312$  به دست آمد [۲۰]. اسماعیل و همکاران یک موتور دیزل را با استفاده مخلوط سوخت دیزل و بیودیزل ارزیابی کردند. سرعت موتور، نوع سوخت، گشتاور، جرم سوخت و نرخ جریان به عنوان پارامتر ورودی شبکه عصبی در نظر گرفته شدند. پارامترهایی مانند انواع آلایندگی‌ها، فشار و نرخ حرارت آزادشده به عنوان خروجی‌های اصلی شبکه در نظر گرفته شدند. آن‌ها گزارش کردند که شبکه عصبی با قاعده یادگیری پس-

1. Artificial Neural Network  
2. Multi-Layer Perceptron

انتشار خطا رو به جلو (FFBP)<sup>۱</sup> با تابع انتقال ترکیبی لگاریتمی/خطی، الگوریتم آموزش لونبرگ مارکوارت (trainlm)<sup>۲</sup> با تعداد نرون‌های ده عدد به عنوان شبکه بهینه برای پیش‌بینی داده‌های خروجی موتور است[۲۱]. پژوهش دیگری، که توسط جاوید و همکاران صورت گرفت، نشان داد که شبکه عصبی با قاعده یادگیری پسانشتر (BP) و الگوریتم آموزش لونبرگ مارکوارت (trainlm) با تابع انتقال سیگموئید و لگاریتمی بهترین مدل برای پیش‌بینی عملکرد و آلایندگی است[۲۲]. ده‌کیانی و همکاران از شبکه عصبی مصنوعی برای پیش‌بینی آلایندگی، توان ترمزی موتور، گشتاور اشتعال جرقه‌ای با ترکیب سوخت‌های اتانول-بنزین استفاده کردند. نتایج نشان داد که مدل شبکه عصبی مصنوعی براساس الگوریتم پسانشتر، دارای بهترین دقت با ضریب همبستگی ۰/۹۸، ۰/۹۶ و ۰/۹۰ و ۰/۷۱، بهترتبیب برای مونوکسیدکربن (CO)، دی‌اکسیدکربن ( $\text{CO}_2$ )، هیدروکربن‌ها (HC) و اکسیدهای نیتروژن ( $\text{NO}_x$ ) است. همچنین، ضریب همبستگی برای گشتاور و توان بهترتبیب ۰/۹۹ و ۰/۹۶ به دست آمد[۲۳]. در پژوهشی دیگر، اوزون اثر زاویه میل لنگ، سرعت و بار موتور را بر روی عملکرد موتور دیزل با استفاده از شبکه عصبی مصنوعی پیش‌بینی کرد[۲۴].

یوسف و همکاران به بررسی مدل‌سازی با استفاده از شبکه عصبی مصنوعی برای پیش‌بینی توان ترمزی، گشتاور، مصرف سوخت ویژه و آلایندگی یک موتور دیزل اصلاح شده با ترکیبی از گاز طبیعی فشرده (CNG) و سوخت دیزل پرداختند. ضریب همبستگی برای پارامترهای گشتاور، مصرف سوخت ویژه، اکسیدهای نیتروژن ( $\text{NO}_x$ ) و دمای گازهای خروجی اگزوژن بهترتبیب ۰/۹۸۴، ۰/۹۸۳۸، ۰/۹۵۷۰۷ و ۰/۹۹۳۴ به دست آمد[۲۵]. شارما و همکاران از شبکه عصبی مصنوعی برای پیش‌بینی پارامترهای عملکرد و آلایندگی یک موتور دیزل با استفاده از مخلوط‌های سوخت بیودیزل و دیزل در فشار پاشش‌های مختلف سوخت استفاده کردند[۲۶]. کای و همکاران مدل شبکه عصبی مصنوعی را برای پیش‌بینی مصرف سوخت ویژه، توان مؤثر، فشار مؤثر متوسط و دمای گازهای خروجی برای سوخت مтанول به کار برند. نتایج برای مدل بهینه ضریب همبستگی نزدیک به یک را برای داده‌های آموزش و آزمایش نشان داد[۲۷]. اوگز و همکاران از شبکه عصبی مصنوعی برای پیش‌بینی عملکرد موتور دیزل با استفاده از سوخت‌های زیستی استفاده کردند. نتایج نشان داد که شبکه‌های عصبی مصنوعی یک مدل مناسب برای تخمین عملکرد موتور است[۲۸].

نتیجه حاصل از جستجوی منابع مختلف نشان می‌دهد که تاکنون پژوهشی با استفاده از نانولوله‌های کربن و افزودن آن به مخلوط سوخت دیزل و بیودیزل و تاثیر این نانولوله‌ها بر عملکرد، آلایندگی و ارتعاش موتورهای دیزل با کمک شبیه‌سازی شبکه عصبی مصنوعی انجام نشده است. بنابراین، هدف از انجام تحقیق حاضر، توسعه یک مدل شبکه عصبی برای پیش‌بینی پارامترهایی مانند توان، گشتاور، آلایندگی و ارتعاش موتور است. متغیرهای ورودی این شبیه‌سازی عبارت‌اند از مخلوط سوخت دیزل-بیودیزل همراه با نانولوله‌های کربن، سرعت موتور، چگالی سوخت، گرانروی سوخت، ارزش حرارتی پایین، دمای روغن، محتوای اکسیژن موجود در اگزوژن و غیره. در تمامی تحقیقات گذشته، معمولاً نوع سوخت، دور موتور و بار به عنوان ورودی انتخاب می‌شوند، که محدودند. اما، در این تحقیق، تمامی پارامترهای مؤثر بر عملکرد موتور به عنوان ورودی شبکه عصبی در نظر گرفته شدند.

## مواد و روش‌ها

### نصب و راه اندازی تجهیزات آزمایشگاهی و داده‌برداری

جدول ۱ دستگاه‌های آزمایشگاهی و داده‌برداری مورد استفاده در این پژوهش را نشان می‌دهد. در این پژوهش، از موتور دیزل تک‌سیلندر، چهارزمانه و هواخنک استفاده شد. موتور در دمای محیط ۲۲ درجه سانتی‌گراد و فشار ۸۷۸ میلی‌بار راهاندازی شد. از یک دینامومتر جریان گردابی برای اندازه‌گیری بار و گشتاور موتور استفاده شد. برای اندازه‌گیری آلایندگی موتور از یک

1. Feed Forward Back Propagation  
2. Train Levenberg-Marquardt

دستگاه آلاینده‌سنچ استفاده شده است. مشخصات دستگاه آلاینده‌سنچ در جدول ۱ آمده است. برای جمع‌آوری سیگنال‌های ارتعاش موتور از سه عدد شتاب‌سنچ استفاده شد. شتاب‌سنچ‌ها در سه جهت عمودی (x)، جانبی (y) و طولی (z) نصب شدند که در شکل ۲ نشان داده شده است. سیگنال‌های این سه شتاب‌سنچ به جعبه تبدیل منتقل شده و سپس سیگنال‌های خروجی از جعبه تبدیل به مبدل آنالوگ به دیجیتال (A/D) منتقل شدند (جدول ۱). در نهایت، کابل داده‌های خروجی به پورت USB رایانه برای ثبت داده‌ها متصل شد. دامنه و دقت اندازه‌گیری در نتایج محاسبه شده در جدول ۲ نشان داده شده است.

جدول ۱- مشخصات کلیه تجهیزات و دستگاه‌های مورد استفاده در آزمایش

Table 1: Specifications of all equipment and devices used in the experiments

Test Engine	Dynamometer	Emission Analyzer	A/D converter	Other Devices and Sensors
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 <sup>3</sup> , 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.	Model WE400, Eddy current dynamometer, Maximum torque of 80Nm, Maximum speed of 10000 rpm.	AVL DITEST GAS 1000, Mobile petrol/gas emission tester, Emission diagnostics of HC, CO, CO <sub>2</sub> , O <sub>2</sub> , NO <sub>x</sub> , and lambda.	Advantech USB-4711A, 16 Single input channels A/D, Converting 12 bit A/D, Maximum sampling frequency of 150 kHz. <b>Accelerometers:</b> Multi-Purpose Accelerometers, CTC AC102-1A, Frequency Response ( $\pm 3\text{dB}$ ) 0.5-15000 Hz, Dynamic Range $\pm 50 \text{ g}$ peak, Resonant Frequency 23000 Hz.	-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- دامنه و دقت اندازه‌گیری در نتایج محاسبه شده

Table 2: The ranges and accuracies of the measurements in the calculated results

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

## آماده‌سازی سوخت

در پژوهش حاضر، بیودیزل از روغن پسماند خوراکی با استفاده از واکنش ترانس استریفیکاسیون تولید و خواص آن براساس استاندارد ASTM-D6751 ارزیابی شد. جدول ۳ مشخصات سوخت‌های دیزل و بیودیزل را براساس استاندارد ASTM نشان می‌دهد. پس از آن، نانولوله‌های کربن (CNT)<sup>1</sup> با غلظت‌های ۳۰، ۶۰ و ۹۰ ppm با سوخت B5 (درصد بیودیزل و ۹۵ درصد دیزل) و سوخت B10 مخلوط شدند. مشخصات نانولوله‌های کربن مورد استفاده در شکل ۱ نشان داده شده است. بهمنظور

1. Carbon Nanotubes

به دست آوردن یک امولسیون همگن با اضافه کردن نانولوله‌ها به هر مخلوط سوخت، از دستگاه فراصوت (Hielscher UP400S) استفاده شد. مخلوط سوخت و نانولوله‌های کربن به منظور تولید سوخت همگن به مدت ۱۵ دقیقه در دستگاه اولتراسونیک قرار گرفتند [۲۹]. در نهایت، سوخت B0 (دیزل خالص)، B5، B10، B5CNT30 (۵ درصد بیودیزل + ۹۵ درصد دیزل و ۳۰ ppm نانولوله کربن)، B5CNT60، B5CNT90، B10CNT30، B10CNT60 و B10CNT90 برای آزمایش‌ها آماده شدند. گرانروی، چگالی سوخت، ارزش حرارتی بالا و ارزش حرارتی پایین هر مخلوط سوخت بلافاصله پس از آماده‌سازی سوخت‌ها تعیین شدند. جدول ۴ خواص تمام مخلوط‌های سوخت مورد استفاده را براساس دستورالعمل‌های استاندارد ASTM نشان می‌دهد. پایداری هر مخلوط سوخت سه ساعت پس از آماده‌سازی بود.

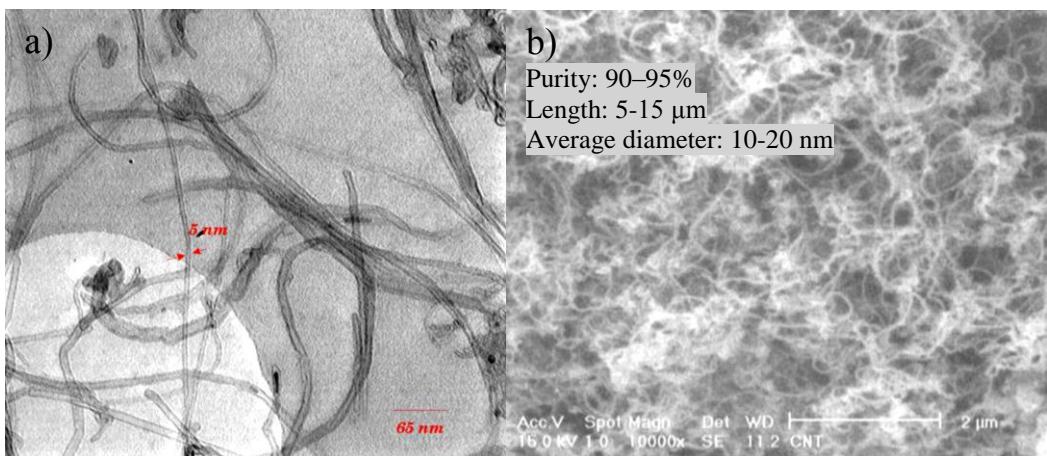


Figure 1- a) Typical TEM image b) Typical SEM image of carbon nanotubes added to diesel-biodiesel blended fuel.  
شکل ۱- (الف) تصویر TEM<sup>1</sup>، (ب) تصویر SEM<sup>2</sup> نانولوله‌های کربن اضافه شده به مخلوط سوخت دیزل و بیودیزل

جدول ۳- مشخصات اندازه‌گیری شده سوخت دیزل و بیودیزل براساس استاندارد ASTM

Table 3- The specifications measured based on ASTM standard for diesel and biodiesel fuels

Properties	Diesel	Biodiesel (tested)	biodiesel (Standard)	Units
<b>Flashpoint</b>	64	176	130 min	°C
<b>Cetane number</b>	57	62.5	47 min	-
<b>Kinematic viscosity at 40 °C</b>	3.28	4.73	1.9-6.0	mm <sup>2</sup> /s
<b>Water and sediment</b>	0.05	0.05	0.05 max	% vol.
<b>Density</b>	0.827	0.880		g/cm <sup>3</sup>
<b>Cloud point</b>	2	-1	-	°C
<b>Pour point</b>	-2	-4	-	°C
<b>Free Glycerol</b>	0.01	0.016	0.02 max	Mass%
<b>Copper corrosion</b>	1a	1a	No.3 max	-

جدول ۴- برخی از ویژگی سوخت مورد استفاده بر اساس استاندارد ASTM (در دمای ۱۵ درجه سانتیگراد)

Table 4- The some characteristics measured based on ASTM standard for tested fuels (at 15 °C)

Fuel	Kinematic viscosity (mm <sup>2</sup> /s)	Density (g/cm <sup>3</sup> )	HHV (MJ/kg)	LHV (MJ/kg)	Cetane index
B0	5.4459	0.8270	45.61	42.80	57.00
B5	5.6761	0.8297	45.56	42.76	57.210
B10	5.8481	0.8340	45.46	42.69	57.47
B5CNT30 ppm	5.6441	0.8295	45.56	42.76	57.33
B5CNT60 ppm	5.5871	0.8295	45.56	42.76	57.40
B5CNT90 ppm	5.4841	0.8295	45.56	42.76	57.53
B10CNT30 ppm	5.6949	0.8319	45.52	42.73	57.59
B10CNT60 ppm	5.6894	0.8319	45.52	42.73	57.61
B10CNT90 ppm	5.6694	0.8319	45.52	42.73	57.75

1. Transmission Electron Microscopy  
2. Scanning Electron Microscopy

## روش انجام آزمایش

برای مخلوط‌های سوخت استفاده شده، گرانروی، چگالی سوخت، ارزش حرارتی بالایی و ارزش حرارتی پایینی هر مخلوط سوخت بلا فاصله پس از آماده‌سازی سوخت تعیین شدند (جدول ۴). آزمایش‌ها در سه دور موتور ۱۸۰۰، ۲۳۰۰ و ۲۸۰۰ rpm تحت بار کامل و در سه تکرار انجام شد. گشتاور، توان، مصرف سوخت، مصرف سوخت و بیزه، دمای گازهای خروجی، دمای محیط، فشار محیط، رطوبت محیط برای هر آزمون ثبت شده و تمام داده‌ها به رایانه منتقل شدند. موتور به مدت ۱۰ دقیقه، برای اطمینان از حذف سوخت باقی‌مانده در مجاری سوخت از آزمایش قبلی، کار می‌کرد. سپس، روند ثبت داده‌ها آغاز و به مدت سه دقیقه به طول می‌انجامید. آزمون‌ها به منظور اطمینان از عدم وجود خطأ به دقت کنترل شد. پس از تجزیه و تحلیل و تشخیص خطای اولیه، برخی از تست‌ها تکرار شد. طرحواره راهاندازی تجهیزات برای اندازه‌گیری و روش انجام آزمون در شکل ۲ نشان داده شده است.

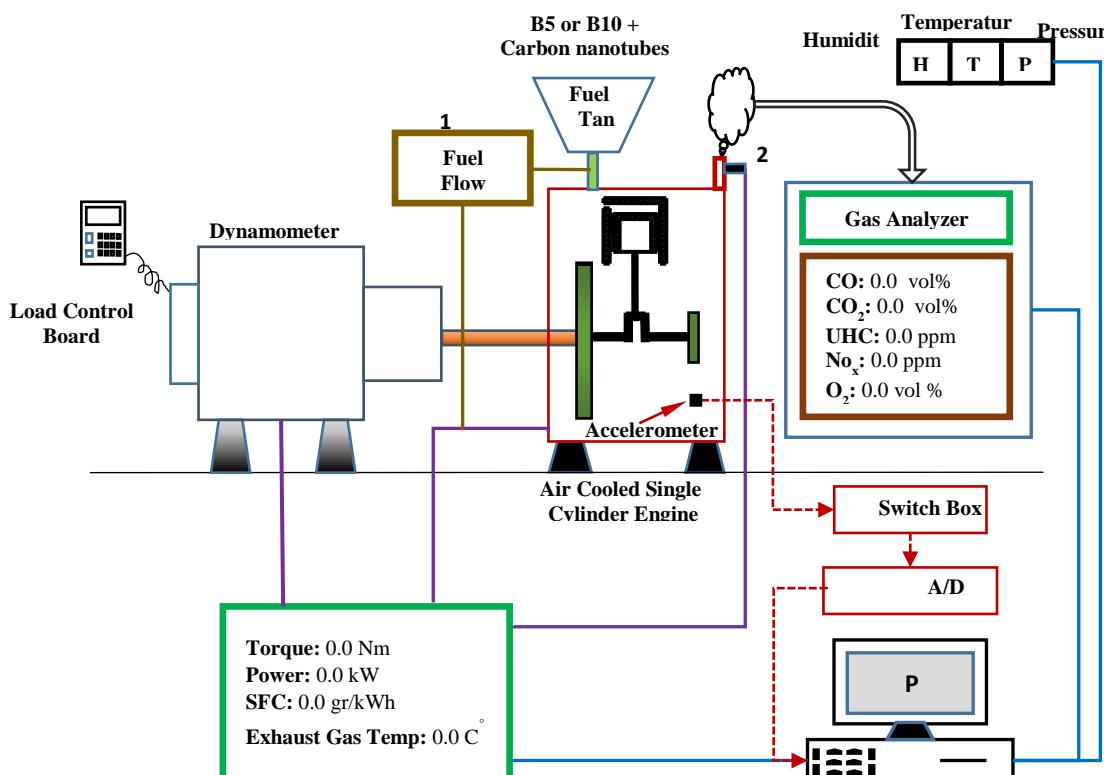


Figure 2- The schematic of equipment for of measurement and test methods [30]

شکل ۲- طرحواره راهاندازی تجهیزات برای اندازه‌گیری و روش انجام آزمون [۳۰]

## ارتعاشات بدنه موتور

در این پژوهش، شتاب‌سنج‌ها (مشخصات در جدول ۱) در قسمت پایین موتور برای ثبت ارتعاش نصب شدند. بسامد نمونه‌گیری شتاب‌سنج‌ها روی ۴۰ کیلوهرتز (kHz) تنظیم شده و داده‌گیری به مدت یک دقیقه بعد از پایداری موتور انجام شد [۳۱]. ثبت داده‌های ارتعاش در چندین چرخه کاری موتور انجام شد. طرحواره ذخیره‌سازی داده‌های ارتعاش موتور در شکل ۲ نشان داده شده است. برای تجزیه و تحلیل ارتعاش موتور، پارامترهای جذر میانگین مربعات شتاب<sup>۱</sup> (RMS) در موتور و کورتوسیس<sup>۲</sup> سیگنال ارتعاش به شرح زیر تعریف شده‌اند.

1. Root Mean Square  
2. Kurtosis

### جذر میانگین مربعات شتاب (RMS)

جذر میانگین مربعات شتاب توسط معادله (۱) با تعداد نقاط در حوزه زمانی ( $N$ ) و مقادیر شتاب ( $t_k$ ) در زمان  $t_k$  تعریف می‌شود.

$$x_{RMS} = \left[ \frac{1}{N} \sum_{k=1}^N x^2(t_k) \right]^{1/2} \quad (1)$$

از این پارامتر به عنوان معیاری برای مقایسه ارتعاش در شرایط مختلف استفاده می‌شود. جذر میانگین مربعات شتاب با محتوای انرژی سیگنال ارتعاش مناسب است که وابسته به دامنه آن است. جذر میانگین مربعات شتاب با به توان ۲ رساندن داده‌های ارتعاش محاسبه می‌شود. بنابراین، وزن بیشتری به طور خودکار به پیک‌های ناگهانی<sup>۱</sup> داده می‌شود.

### کورتوسیس سیگنال ارتعاش

مقدار کورتوسیس نیز توسط معادله (۲) برای ارزیابی عملکرد موتور با استفاده از سیگنال ارتعاش استفاده شد. مقدار کورتوسیس به نویز بسیار حساس است و بهمنظور بهره‌مندی کامل از این شاخص پیش‌پردازش سیگنال از قبیل فیلتر کردن ضروری است [۳۲-۳۴]. کورتوسیس، به عنوان شاخص سنجش تیزی سیگنال، وجود بیشینه و کمینه سیگنال را به خوبی نشان می‌دهد. مقدار کورتوسیس بیشتر نشان می‌دهد که سیگنال داری پالس بزرگتر، واضح‌تر و دارای دامنه بیشتری است. کورتوسیس تفاوت بین دو سیگنال را به صورت واضح‌تر نشان می‌دهد.

$$Kurt = \frac{\left[ \frac{1}{N} \sum_{k=1}^N x^4(t_k) \right]}{\left[ \frac{1}{N} \sum_{k=1}^N x^2(t_k) \right]^2} \quad (2)$$

### مدل‌سازی شبکه‌های عصبی مصنوعی

هدف اصلی تحقیق حاضر، پیش‌بینی عملکرد (قدرت و گشتاور)، آلایندگی (CO<sub>2</sub>, CO, NO و UHC) و ارتعاش موتور (RMS<sub>x</sub>, RMS<sub>y</sub>, RMS<sub>z</sub>, Kurtosis<sub>x</sub>, Kurtosis<sub>y</sub>, Kurtosis<sub>z</sub>) با افزودن نانولوله‌های کربن به مخلوط سوخت دیزل و بیو دیزل توسط شبکه عصبی مصنوعی است. RMS و کورتوسیس ارتعاش توسط معادلات (۱) و (۲) محاسبه شدند. از نرم‌افزار متلب (نسخه ۸.۳.۰.۵۳۲) برای پیش‌بینی عملکرد، انتشار و ارتعاشات موتور احتراق اشتعال تراکمی در شرایط مختلف استفاده شد. ساختار شبکه عصبی مورد استفاده در شکل ۳ نشان داده شده است. نوع سوخت، دور موتور، چگالی سوخت، گرانروی سوخت، ارزش حرارتی سوخت، فشار چندراهه<sup>۲</sup> ورودی، مصرف سوخت، دمای گازهای خروجی، اکسیژن موجود در گازهای خروجی، دمای روغن، رطوبت نسبی هوای محیط و فشار نسبی هوای محیط به عنوان پارامترهای لایه ورودی در نظر گرفته شدند. گشتاور، توان، CO<sub>2</sub>, CO, NO, UHC, RMS<sub>x</sub>, RMS<sub>y</sub>, RMS<sub>z</sub>, Kurtosis<sub>x</sub>, Kurtosis<sub>y</sub> و Kurtosis<sub>z</sub> به عنوان پارامترهای لایه خروجی انتخاب شدند. تعداد نرون‌های لایه ورودی برابر تعداد متغیرهای مستقل (۱۲ عدد) و تعداد نرون‌های لایه خروجی برابر با تعداد پارامترهای وابسته (۱۲ عدد) است.

در مدل‌سازی شبکه عصبی مصنوعی پژوهش حاضر، ۷۰ درصد داده‌ها برای آموزش، ۲۰ درصد داده‌ها برای ارزیابی و ۱۰ درصد داده‌ها برای آزمون استفاده شدند. از مجموعه ۳۲۴ داده موجود در مدل، ۲۲۷ داده بهمنظور آموزش شبکه، ۶۵ داده بهمنظور ارزیابی و ۳۲ داده به منظور آزمون شبکه عصبی در نظر گرفته شدند. در این مطالعه از شبکه‌های چندلایه با قاعده یادگیری پس انتشار خطای روبه جلو استفاده شد. این نوع شبکه ساده است، ولی در عین حال، به علت دقت بالا، کاربرد زیادی دارد. از توابع انتقال مختلفی مانند سیگموئیدی (logsig)، لگاریتمی (tansig) و خطی (purelin) استفاده شد که این رابطه‌ها در

1. Shocks  
2. Manifold

معادلات (۳) و (۴) نشان داده شده‌اند. قاعده آموزش همراه با ناظارت، لونبرگ-مارکوارت (trainlm) استفاده شد. نتایج با هم مقایسه شد و بهترین ساختار شبکه برای پیش‌بینی پارامترهای موردنظر موتور تعیین شد. برای ساخت چنین شبکه‌ای کد موردنظر در نرم‌افزار متلب نوشته شد.

$$\text{logarithmicsigmoid} = \frac{1}{1+e^{-x}} \quad (3)$$

$$\text{tangentsigmoid} = \frac{2}{1+e^{-2x}} - 1 \quad (4)$$

در معادلات بالا،  $x$  به عنوان داده‌های ورودی است. پارامترهای ورودی و خروجی مرتب شده، محدود و نرمال‌سازی شدند. از آنجا که تابع فعال‌سازی لایه خروجی در همه ساختارها خطی است، تنها پارامترهای ورودی توسط معادله ۵ بین  $0$  و  $1$  نرمال شدند. در ابتدا وزن و مقادیر بایاس<sup>۱</sup> به صورت تصادفی معین شدند و سپس مقادیر براساس الگوریتم آموزش به روزرسانی شدند.

$$I_{\text{norm}} = \frac{I - I_{\min}}{I_{\max} - I_{\min}} \quad (5)$$

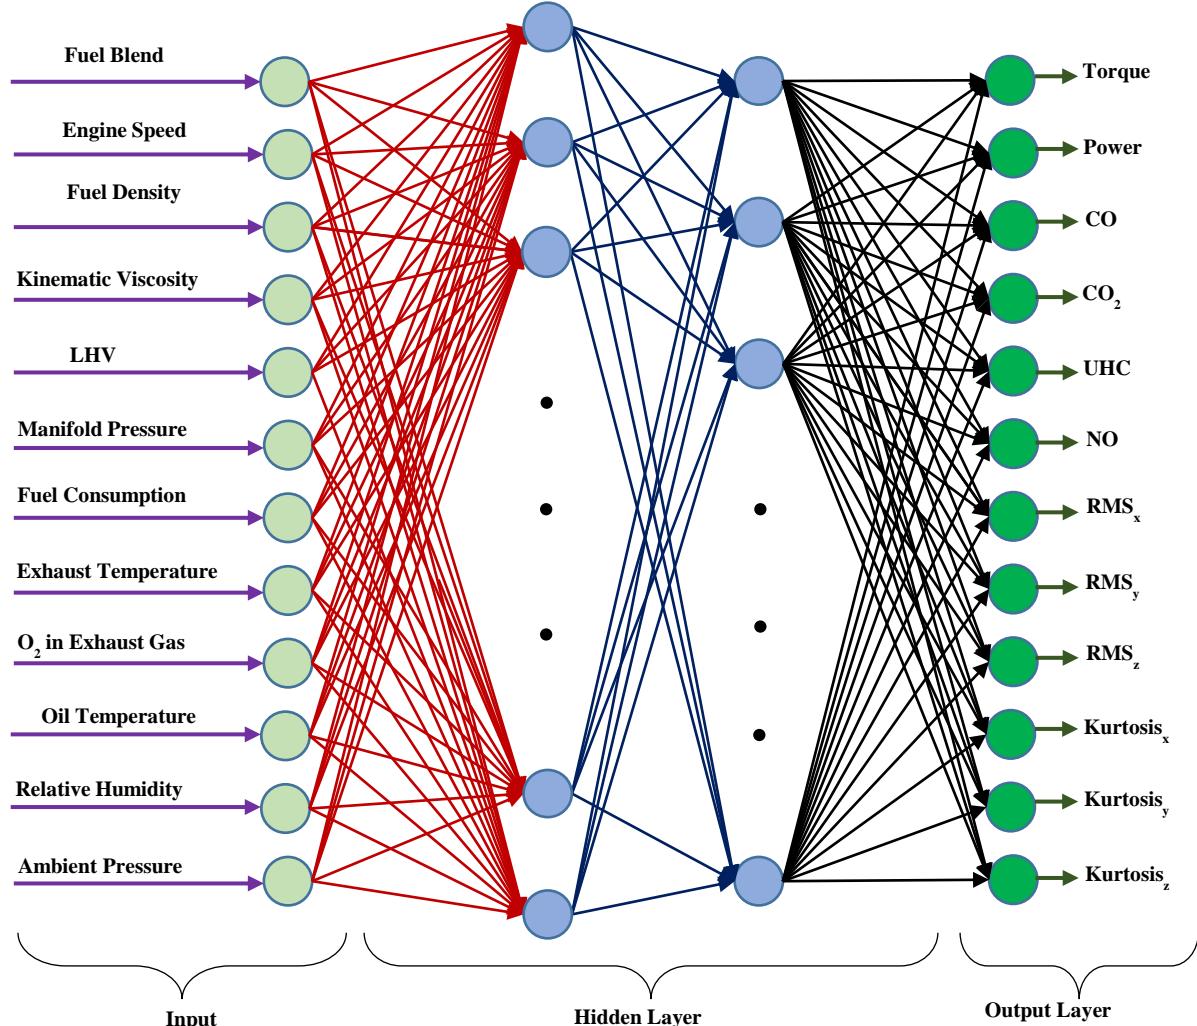


Figure 3: Neural network architecture diagram

شکل ۳- طرح‌واره ساختار شبکه عصبی مصنوعی

1. Bias

در معادله ۵،  $I_{norm}$  داده نرمال شده،  $I$  داده اندازه گیری شده مورد نظر،  $I_{min}$  کمترین داده اندازه گیری شده و  $I_{max}$  بیشترین داده اندازه گیری شده است. به منظور تعیین ساختار شبکه عصبی بهینه، شبکه های مختلف با تعداد لایه ها و نرون های لایه های مخفی استفاده شدند. جهت تعیین ساختار شبکه عصبی بهینه از پارامترهای آماری مانند بیشترین ضریب رگرسیونی ( $R$ ) و کمترین مقدار جذر میانگین مربعات خطأ ( $MSE$ ) به ترتیب توسط معادله ۶ و ۷ استفاده شد. با درنظر گرفتن پارامترهای یادشده، بهترین ساختار<sup>۱</sup> شبکه مشخص شد.

$$R = 1 - \left( \frac{\sum_{i=1}^n (T_i - O_i)^2}{\sum_{i=1}^n (T_i - \bar{O})^2} \right) \quad (6)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (T_i - O_i)^2 \quad (7)$$

در معادله ۶ و ۷،  $n$  تعداد نمونه مورد آزمایش،  $T_i$  مقادیر اندازه گیری شده (هدف)،  $O_i$  مقادیر پیش بینی شده (خروجی) و  $\bar{O}$  میانگین مقادیر پیش بینی شده است.

## نتایج و بحث

جدول ۵ خلاصه ای از نتایج تحقیق را نشان می دهد (سطر اول). خود بیودیزل، به دلیل وجود اکسیژن در ساختارش و کمک به بهبود احتراق، آلایندگی های موتو را کاهش می دهد [۳۵]. به طور کلی، افزودن نانولوله های کربن به سوخت B5 و B10، باعث افزایش توان و گشتاور (۳/۶۷ درصد)، کاهش مصرف سوخت ویژه (۷/۱۲ درصد)، کاهش آلایندگی های متوكسید کربن و هیدروکربن های نسوخته، به ترتیب به میزان ۶۵/۷۰ و ۴۴/۹۸ درصد، می شود. از طرفی، میزان اکسیدهای نیتروژن به مقدار ۲۷/۴۹ درصد افزایش می یابد. با توجه به نتایج به دست آمده مشخص شد که سوخت B5CNT90 دارای شرایط بهینه از لحاظ کمترین مصرف سوخت ویژه و کمترین آلایندگی هاست. خلاصه ای از تغییرات نسبت به سوخت دیزل خالص و مقایسه با تحقیقات دیگر محققان در جدول ۵ آمده است. با اضافه کردن نانولوله های کربن به مخلوط سوخت دیزل- بیودیزل (B5) ارزش حرارتی سوخت افزایش، گرانروی کاهش و چگالی آن افزایش می یابد [۳۰]. کاهش گرانروی منجر به بهبود پاشش و پودرشدن<sup>۲</sup> سوخت داخل سیلندر می شود که در نتیجه باعث افزایش توان موتو می شود [۳۰, ۶]. طبق تحقیقات گذشته، کاتالیست نانولوله کربن تاخیر در اشتعال را کاهش می دهد و به فشار پیک بالاتر در داخل سیلندر و نرخ آزادسازی گرمای بیشتری منجر می شود [۳۷, ۳۶, ۶]. نتایج کامل افزودن نانولوله های کربن به مخلوط های سوخت B5 و B10 در مرجع شماره [۳۰] ارائه شده است.

مدل شبکه عصبی مصنوعی در این مطالعه برای پیش بینی عملکرد، آلایندگی و ارتعاشات موتو اشتعال تراکمی برای مخلوط های سوخت آزمایش شد. برای انجام بهترین پیش بینی پارامترهای موردنظر توسط شبکه، ساختارهای مختلف شبکه استفاده شد. فهرستی از شبکه های عصبی مختلف ارزیابی شده در جدول ۶ ارائه شده است. در جدول ۶، الگوریتم لونبرگ- مارکوارت با ترکیبتابع انتقال سیگموئیدی- سیگموئیدی (log-sig, log-sig) برای لایه های مخفی ۱ و ۲ و تابع انتقال خطی برای لایه خروجی مورد استفاده قرار گرفت. شبکه بهینه دارای ساختار ۱۲-۲۰-۲۰-۱۲ (دو لایه مخفی با تعداد نرون های ۲۰ برای هر لایه) است. خطای شبکه (MSE)<sup>۳</sup> برای این ساختار برای الگوهای آموزش، ارزیابی و آزمون به ترتیب ۰/۰، ۷۳/۲۲ و ۴۶/۵۵ است. این شبکه در مدت ۴ تکرار از یک ثانیه با خطای یادگیری ۲۱/۴۸ همگرا می شود. عملکرد مدل بهینه

1. Topology

2. Atomized

3. Mean Square Error

شبکه عصبی در شکل ۴ نشان داده شده است. تحلیل رگرسیونی نشان داد، ضریب رگرسیونی (R) برای الگوهای آموزش، ارزیابی و آزمون به ترتیب  $0.9994$ ،  $0.9985$  و  $0.9999$  است.

در مقایسه با کارهای دیگران برای شبکه عصبی، سلبی و همکاران نتایج مشابهی را برای تحلیل ارتعاشات یک موتور دیزل با استفاده از مخلوط سوخت‌های دیزل، بیودیزل و گاز طبیعی با ضریب رگرسیونی  $0.9859$ ،  $0.9874$  و  $0.9859$  به ترتیب برای آموزش، ارزیابی و آزمون شبکه به دست آوردند [۴۳].

جدول ۵- خلاصه نتایج به دست آمده از عملکرد و آلایندگی موتور در تحقیق حاضر و مقایسه آن با کارهای دیگران [۳۰]

Table 5- A brief comparison of performance and emission characteristics resulted from present study with other research works[30]

Type of fuel with additives	Performance				Emissions			Ref
	Power	Torque	BTE	SFC	CO	UHC	NO <sub>x</sub>	
Fuel blend of B5CNT90	3.67%↑	3.67%↑	8.12%↑	7.12%↓	65.7%↓	44.98%↓	27.49%↑	Present study
Diesel with the addition of CuO	1.0%↑	1.0%↑	-	0.5%↓	5%↓	8%↓	2%↓	[41]
Amide-functionalized MWCNTs-CeO <sub>2</sub> catalyst on diesel-biodiesel blends (B5 and B20)	7.81%↑	4.91%↑	-	-	38.8%↓	71.4%↓	18.9%↓	[38]
Nano-aluminum oxide additive (ANP) mixed with the biodiesel	-	-	7.34%↑	7.66%↓	48%↓	26.04%↓	7.95%↑	[36]
Nano-organic additives on emulsion fuels with different water concentrations (10% and 15%)	-	-	14.2%↑	-	-	-	30.6%↓	[42]
Ferric chloride (FeCl <sub>3</sub> ) added on biodiesel	-	-	6.3%↑	8.6%↓	52.6%↓	26.6%↓	4.1%↑	[40]
CERIA+ CNTs added to E20 blend	-	-	7.5%↑	7.69%↓	22.2%↑	7.2%↓	0%	[39]
Diesel with the addition of Al <sub>2</sub> O <sub>3</sub>	3.28%↑	3.28%↑	-	1.2%↓	11%↓	13%↓	6%↓	[41]

جدول ۶- خلاصه‌ای از شبکه‌های مختلف مورد ارزیابی برای معیارهای عملکرد شبکه عصبی

Table 6: Summary of different networks evaluated to yield the criteria of network performance

Activation function	Training rule	Neurons in hidden layers		MSE			R			Epoch	Time (s)
		Layer 1	Layer 2	Training	Validation	Testing	Training	Validation	Testing		
Log/Pur	trainlm	15	-	0.0005	102.5115	80.6567	0.9999	0.9976	0.9984	5	0
Log/Pur	trainlm	20	-	0.0000	92.4811	45.1581	0.9999	0.9982	0.9986	4	0
Log/Pur	trainlm	25	-	0.0000	103.4039	32.2409	0.9999	0.9975	0.9994	3	0
Log/Pur	trainlm	30	-	0.0000	118.6550	46.8883	0.9997	0.9973	0.9994	2	0
Tan/Pur	trainlm	20	-	0.0000	95.0538	34.9387	0.9999	0.9978	0.9993	5	0
Tan/Pur	trainlm	25	-	0.0000	37.1392	125.9905	0.9999	0.9992	0.9972	4	0
Tan/Pur	trainlm	30	-	0.0000	74.4718	86.3081	0.9999	0.9984	0.9975	7	0
Tan/Tan/Pur	trainlm	20	10	0.0109	132.2933	168.2283	0.9999	0.9976	0.9931	7	0
Tan/Tan/Pur	trainlm	20	15	0.0024	127.8106	57.2299	0.9999	0.9976	0.9983	8	1
Tan/Tan/Pur	trainlm	20	20	0.0000	157.0597	11.3877	0.9999	0.9959	0.9973	5	1
Log/Log/Pur	trainlm	20	15	0.0084	28.9931	233.8780	0.9999	0.9992	0.9936	6	1
<b>Log/Log/Pur</b>	<b>trainlm</b>	<b>20</b>	<b>20</b>	<b>0.0000</b>	<b>73.2181</b>	<b>46.5543</b>	<b>0.9999</b>	<b>0.9985</b>	<b>0.9994</b>	<b>4</b>	<b>1</b>
Log/Log/Pur	trainlm	20	10	0.0110	232.9992	24.7820	0.9999	0.9946	0.9945	35	2
Log/Log/Pur	trainlm	15	15	0.0065	67.1109	65.5810	0.9999	0.9988	0.9989	6	0
Log/Tan/Pur	trainlm	25	25	0.0000	41.3771	99.1907	0.9999	0.9990	0.9979	8	1
Log/Log/Pur	trainlm	25	25	0.0000	159.3914	49.8249	0.9998	0.9964	0.9985	3	1
Tan/Log/Pur	trainlm	25	25	0.0000	143.5292	37.8593	0.9999	0.9965	0.9990	5	1
Tan/Log/Pur	trainlm	20	20	0.0000	149.4408	18.7637	0.9997	0.9972	0.9997	5	1

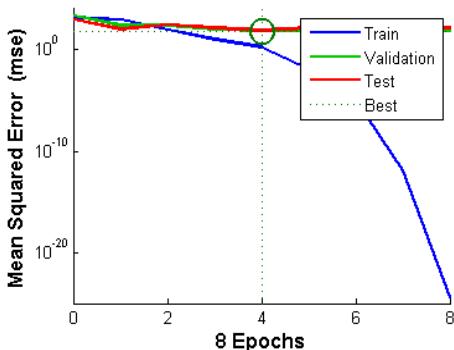


Figure 3- The performance of the optimum ANN model

شکل ۴- عملکرد مدل بهینه شبکه عصبی

تجزیه و تحلیل رگرسیونی برای راستی آزمایی داده‌های هدف و خروجی بهمنظور بررسی پاسخ شبکه با جزئیات بیشتر انجام شد. نتایج نشان داد که مدل ساخته شده عملکرد، آلایندگی و ارتعاش موتور دیزل را با دقت کافی در دورهای مختلف موتور پیش‌بینی می‌کند. مقادیر پیش‌بینی شده یا خروجی شبکه عصبی در مقابل داده‌های اندازه‌گیری شده (هدف) برای عملکرد، آلایندگی و ارتعاش موتور در شکل‌های ۵ و ۶ نشان داده شده است. مقادیر عددی ضرایب رگرسیونی (R) مدل بهینه برای پارامترهای گشتاور، توان، CO<sub>2</sub>, NO و HC به ترتیب ۰/۹۳، ۰/۹۸، ۰/۹۷، ۰/۹۸ و ۰/۹۵ به دست آمده است. برای این پارامترها، نمودار رگرسیونی پارامترهای عملکرد و آلایندگی بین داده‌های اندازه‌گیری شده (هدف) و پیش‌بینی شده (خروجی) توسط مدل بهینه در شکل ۵ نشان داده شده است. در تحقیقی سید و همکاران یک موتور دیزلی سوخت دوگانه هیدروژنی را با استفاده از شبکه عصبی بررسی کردند. ضرایب رگرسیونی (R) برای بازده حرارتی ترمزی (BTE)<sup>۱</sup>، مصرف سوخت ویژه، CO، UHC، NO<sub>x</sub> پیش‌بینی شده به ترتیب ۰/۹۹۹۶، ۰/۹۹۶۸، ۰/۹۹۷۵، ۰/۹۹۹۶ و ۰/۹۸۹۸ به دست آمد[۴۴]. در تحقیقی دیگر، که توسط سوخت‌سراپی و همکاران بر روی اضافه کردن نانوذرات سریم به سوخت دیزل انجام شده بود، ضرایب رگرسیونی برای توان، CO، UHC، و NO پیش‌بینی شده به ترتیب ۰/۹۹۹۵، ۰/۹۹۸۹، ۰/۹۹۸۹ و ۰/۹۹۸۹ به دست آمد[۴۵]. نمودار رگرسیونی داده‌های اندازه‌گیری شده و پیش‌بینی شده توسط مدل بهینه برای پارامترهای ارتعاش و کورتوسیس در جهت‌های مختلف در شکل ۶ نشان داده شده است. مقادیر عددی ضرایب رگرسیونی (R) ارتعاش با استفاده از شبکه عصبی برای Kurtosis<sub>x</sub>, RMS<sub>x</sub>, Kurtosis<sub>y</sub>, RMS<sub>y</sub> به ترتیب برابر ۰/۹۱، ۰/۹۸، ۰/۹۹، ۰/۹۱ و ۰/۹۴ به دست آمد. بنابراین، بین تمامی داده‌های هدف و خروجی شبکه عصبی تطابق خوبی وجود دارد. عملکرد، آلایندگی و ارتعاش بدنه موتور دیزل نسبت به پارامترهای کنترلی موتور، مانند دور موتور، نوع سوخت، خواص سوخت، رطوبت نسبی، دما و فشار هوای ورودی و غیره، حساس است. بنابراین، زمانی که پارامترهای مختلف زیادی در استراتژی‌های کنترل موتور دخالت دارند، شبکه‌های عصبی مصنوعی روش مفیدی در کاهش زمان و هزینه مورد نیاز برای سنجش و کنترل وضعیت موتورند[۲۱]. مدل پیشنهادی شبکه عصبی مصنوعی (ANN)<sup>۲</sup> تنها به مقدار محدودی از داده‌ها برای آموزش در مقایسه با روش‌های متداول مورد استفاده در جدول محاسبات<sup>۳</sup> واحد کنترل الکترونیکی (ECU)<sup>۴</sup> در موتورهای احتراق داخلي نیاز دارد که در آن مقدار زیادی از داده‌های تجربی برای پیش‌بینی و یا کالیبره کردن عملکرد موتور، کنترل آلایندگی و کاهش کوبش موتور با استفاده از سیگنال ارتعاش<sup>۵</sup> مورد نیاز است[۴۶]. مدل شبکه عصبی مصنوعی پیشنهادی در این تحقیق می‌تواند برای کاهش زمان محاسبه ECU و هزینه کالیبراسیون استفاده شود.

1. Brake Thermal Efficiency

2. Artificial Neural Network

3. Look-up table

4. Electronic Control Unit

5. knock sensor

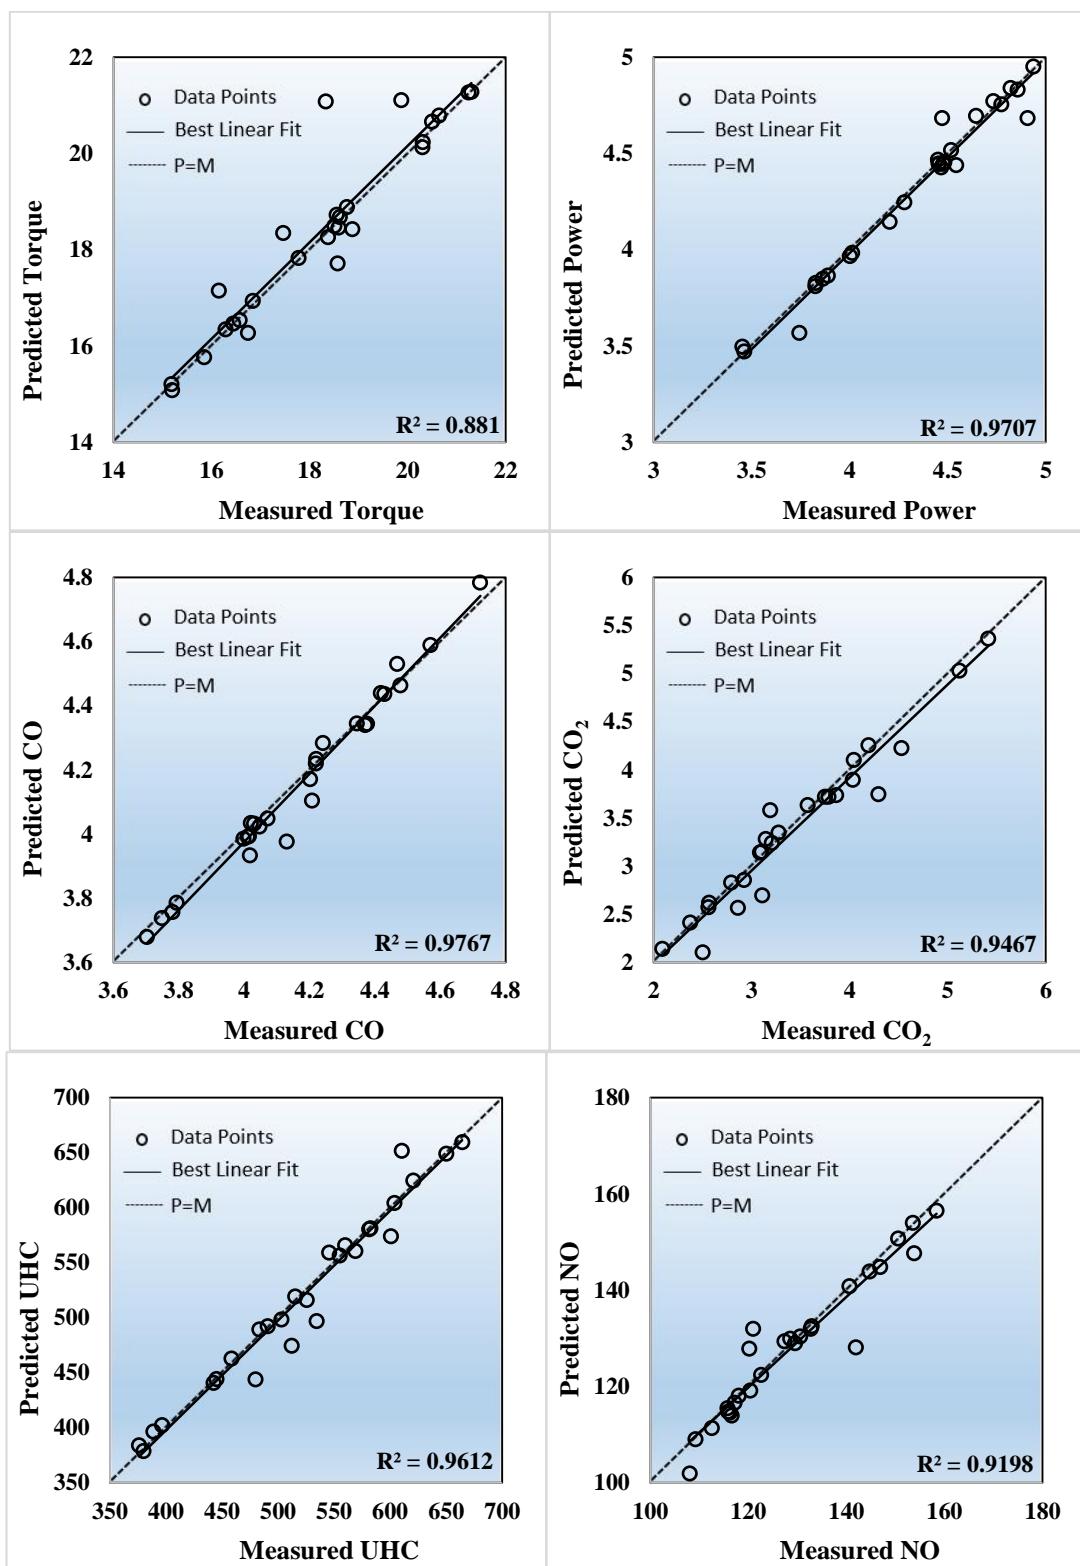


Figure 5: Prediction of ANN and experimental values for Performance and emissions

شکل ۵- پیش‌بینی شبکه عصبی و مقادیر تجربی برای عملکرد و آلایندگی

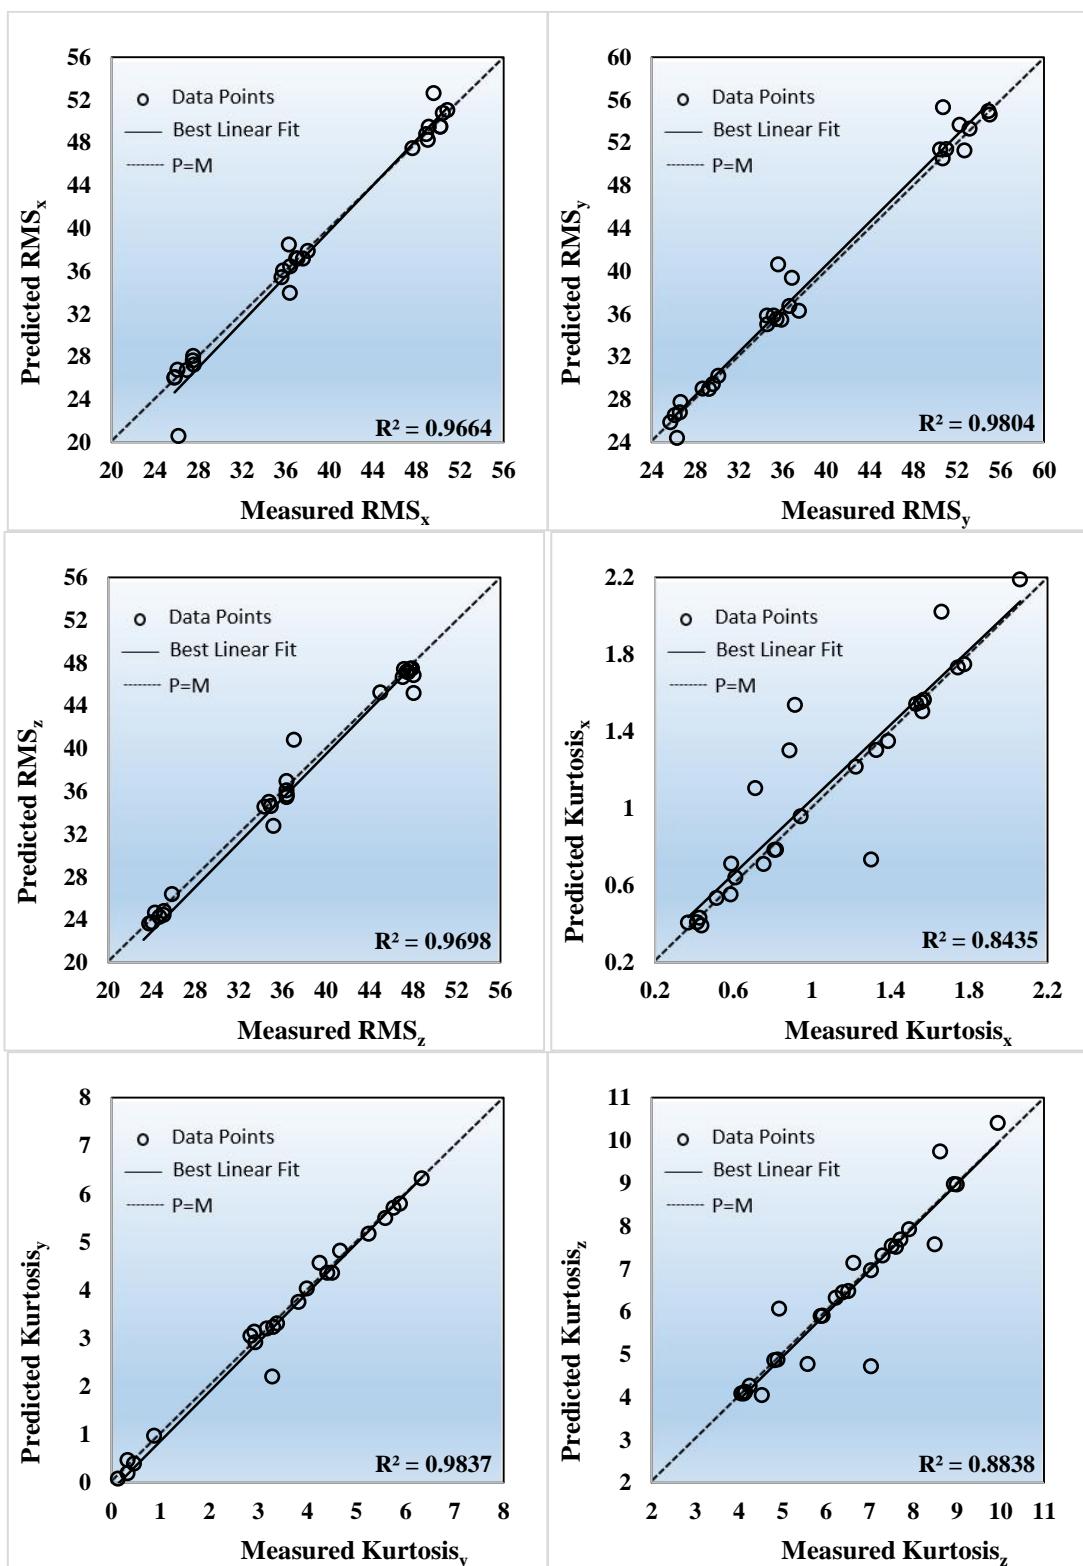


Figure 6: Prediction of ANN and experimental values of engine's vibration parameters

شکل ۶- پیش‌بینی شبکه عصبی و مقادیر تجربی برای پارامتر ارتعاش موتور

## نتیجه‌گیری

هدف اصلی تحقیق حاضر پیش‌بینی عملکرد (توان و گشتاور)، آلایندگی ( $\text{CO}_2$ ,  $\text{CO}$ ,  $\text{NO}$  و  $\text{UHC}$ ) و ارتعاش موتور ( $\text{RMS}_x$ ,  $\text{RMS}_y$ ,  $\text{RMS}_z$ ,  $\text{Kurtosis}_x$ ,  $\text{Kurtosis}_y$  و  $\text{Kurtosis}_z$ ) با افزودن نانولوله‌های کربن به مخلوط سوخت دیزل و بیودیزل توسط شبکه عصبی مصنوعی بود. در مدل سازی شبکه عصبی مصنوعی، ۷۰ درصد داده‌ها برای آموزش، ۲۰ درصد داده‌ها برای ارزیابی و ۱۰ درصد داده‌ها برای آزمون استفاده شد. نتایج نشان داد شبکه عصبی چندلایه (MLP) با قاعده یادگیری پسانشتر خطابه جلو (FFBP) و قاعده آموزش همراه با نظرارت لونبرگ-مارکوارت (trainlm) با ساختار  $12-20-20-12$  (۱۲ عدد نرون در لایه ورودی - ۲۰ عدد نرون در لایه مخفی - ۲۰ عدد نرون در لایه خروجی) برای پیش‌بینی عملکرد، آلایندگی و ارتعاش بدنه موتور دیزل بهینه بوده است. در مدل ارائه شده، از مجموعه ۳۲۴ داده موجود، ۲۲۷ داده به منظور آموزش شبکه، ۶۵ داده به منظور ارزیابی و ۳۲ داده به منظور آزمون شبکه عصبی در نظر گرفته شد. نتایج نشان داد که مصرف سوخت ویژه موتور و آلایندگی  $\text{CO}$  و  $\text{UHC}$  به ترتیب به میزان  $3/67$ ,  $27/49$  درصد افزایش داشته است. نتایج همبستگی خوبی را بین داده‌های پیش‌بینی شده (خروجی مدل) توسط مدل بهینه و داده‌های اندازه‌گیری شده (هدف) نشان داد. مقدار عددی ضریب همبستگی یا رگرسیونی (R) عملکرد و آلایندگی موتور برای پارامترهای گشتاور، توان،  $\text{CO}_2$ ,  $\text{CO}$ ,  $\text{NO}$  و  $\text{HC}$  به ترتیب  $0/93$ ,  $0/98$ ,  $0/98$ ,  $0/97$ ,  $0/98$  و  $0/95$  به دست آمد. در این مدل، مقادیر عددی ضریب همبستگی (R) ارتعاش برای ( $\text{RMS}_x$ ,  $\text{RMS}_y$ ,  $\text{RMS}_z$ ,  $\text{Kurtosis}_x$ ,  $\text{Kurtosis}_y$  و  $\text{Kurtosis}_z$ ) به ترتیب برابر  $0/98$ ,  $0/99$ ,  $0/91$ ,  $0/98$ ,  $0/94$  و  $0/90$  محاسبه شد. نتیجه گرفته شد که شبکه عصبی مصنوعی ایزار قدرتمندی بوده و دقت قابل قبولی را در موتورها برای پیش‌بینی عملکرد، آلایندگی و ارتعاش دارد.

## تشکر و قدردانی

بدین وسیله از دانشگاه علوم کشاورزی و منابع طبیعی گرگان و ستد فناوری نانو ایران، برای حمایت از این تحقیق، قدردانی به عمل می‌آید.

## 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*, 72, 2017, pp. 510-522.
2. A. Taghizadeh-Alisaraei, B. Ghobadian, T. Tavakoli-hashjin, and S. S. Mohtasebi, "Vibration analysis of a diesel engine using biodiesel and petrodiesel fuel blends," *Fuel*, 102, 2012, pp. 414-422.
3. P. Q. Tan, S. S. Ruan, Z. Y. Hu, D. M. Lou, and H. Li, "Particle number emissions from a light-duty diesel engine with biodiesel fuels under transient-state operating conditions," *Applied Energy*, 113, 2014, pp. 22-31.
4. L. Jianmin, S. Yupeng, Z. Xiaoming, X. Shiyong, and D. Lijun, "Procedia Engineering Fuel Injection System Fault Diagnosis Based on Cylinder Head Vibration Signal," *Procedia Engineering*, 16, 2011, pp. 218-223.
5. S. W. Lee, T. Herage, and B. Young, "Emission reduction potential from the combustion of soy methyl ester fuel blended with petroleum distillate fuel," *Fuel*, 83, 2004, pp. 1607-1613.
6. K. Heydari-Maleney, A. Taghizadeh-alisaraei, B. Ghobadian, and A. Abbaszadeh-mayvan, "Analyzing and evaluation of carbon nanotubes additives to diesohol-B2 fuels on performance and emission of diesel engines," *Fuel*, 196, 2017, pp. 110-123.
7. T. Shaafi, K. Sairam, A. Gopinath, G. Kumaresan, and R. Velraj, "Effect of dispersion of various nanoadditives on the performance and emission characteristics of a CI engine fuelled with diesel, biodiesel and blends-A review," *Renewable and Sustainable Energy Reviews*, 49, 2015, pp. 563-573.
8. I. Gravalos *et al.*, "Detection of fuel type on a spark ignition engine from engine vibration behaviour," *Applied Thermal Engineering*, 54, 2013, pp. 171-175.
9. R. Riazi *et al.*, "Employment of Statistical and Artificial Intelligence Techniques for Prediction of Combustion Dynamics in an Experimental Swirl-stabilized Combustor," *Fuel and Combustion*, 9, 2016, pp. 1-22. (in Persian).
10. M. Y. E. Selim, "Pressure-time characteristics in diesel engine fueled with natural gas," *Renewable Energy*, 22, 2001, pp. 473-489.
11. E. Uludamar, E. Tosun, and K. Aydin, "Experimental and regression analysis of noise and vibration of a compression ignition engine fuelled with various biodiesels," *Fuel*, 177, 2016, pp. 326-333.

12. 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*, 64-65, 2015, pp. 58-83.
13. 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*, 6, 2007, pp. 8-12.
14. C. Xin-yan, L. Hong-fei, J. Province, and J. Province, "Establishment and Analysis of Vibration System based on Time Series Models," *International Conference on Computer Application and System Modeling*, North University of China, Taiyuan, China, 2010, pp. 569-572.
15. 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 2011*, 2011, pp. 138-142.
16. 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*, 35, 2010, pp. 65-69.
17. 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*, 34, 2009, pp. 976-982.
18. M. Canakci, A. Erdil, and E. Arcaklioğlu, "Performance and exhaust emissions of a biodiesel engine," *Applied energy*, 83, 2006, pp. 594-605.
19. M. Dehghani *et al.*, "Performance and Exhaust Emissions of a SI Two-stroke Engine with Biolubricants Using Artificial Neural Network," *Energy Procedia*, 75, 2015, pp. 3-9.
20. M. Kapsuz, H. Ozcan, and J. A. Yamin, "Research of performance on a spark ignition engine fueled by alcohol-gasoline blends using artificial neural networks," *Applied Thermal Engineering*, 91, 2015, pp. 525-5534.
21. H. Mohamed Ismail *et al.*, "Artificial neural networks modelling of engine-out responses for a light-duty diesel engine fuelled with biodiesel blends," *Applied Energy*, 92, 2012, pp. 769-777.
22. S. Javed *et al.*, "Development of ANN model for prediction of performance and emission characteristics of hydrogen dual fueled diesel engine with Jatropha Methyl Ester biodiesel blends," *Journal of Natural Gas Science and Engineering*, 26, 2015, pp. 549-557.
23. M. K. D. Kiani, B. Ghobadian, T. Tavakoli, A. M. Nikbakht, and G. Najafi, "Application of artificial neural networks for the prediction of performance and exhaust emissions in SI engine using ethanol-gasoline blends," *Energy*, 35, 2010, pp. 65-69.
24. A. Uzun, "A parametric study for specific fuel consumption of an intercooled diesel engine using a neural network," *Fuel*, 93, 2012, pp. 189-199.
25. T. F. Yusaf, D. R. Buttsworth, K. H. Saleh, and B. F. Yousif, "CNG-diesel engine performance and exhaust emission analysis with the aid of artificial neural network," *Applied Energy*, 87, 2010, pp. 1661-1669.
26. A. Sharma, H. Sharma, P. K. Sahoo, R. K. Tripathi, and L. C. Meher, "ANN Based Modeling of Performance and Emission Characteristics of Diesel Engine Fuelled with Polanga Biodiesel at Different Injection Pressures," *International Energy Journal*, 15, 2015, pp. 57-72.
27. Y. Cay, A. Cicek, F. Kara, and S. Sağıroğlu, "Prediction of engine performance for an alternative fuel using artificial neural network," *Applied Thermal Engineering*, 37, 2012, pp. 217-225.
28. H. Oğuz, I. Saritas, and H. E. Baydan, "Prediction of diesel engine performance using biofuels with artificial neural network," *Expert Systems with Applications*, 37, 2010, pp. 6579-6586.
29. S. H. Hosseini *et al.*, "Effect of added alumina as nano-catalyst to diesel-biodiesel blends on performance and emission characteristics of CI engine," *Energy*, 124, 2017, pp. 543-552.
30. S. H. Hosseini, A. Taghizadeh-Alisaraei, B. Ghobadian, and A. Abbaszadeh-Mayvan, "Performance and emission characteristics of a CI engine fuelled with carbon nanotubes and diesel-biodiesel blends," *Renewable Energy*, 111, 2017, pp. 201-213.
31. A. Taghizadeh-Alisaraei and A. Rezaei-Asl, "The effect of added ethanol to diesel fuel on performance, vibration, combustion and knocking of a CI engine," *Fuel*, 185, 2016, pp. 718-733.
32. C. Pachaud, R. Salvetat, and C. Fray, "Crest factor and kurtosis contributions to identify defects inducing periodical impulsive forces," *Mechanical systems and signal processing*, 11, 1997, pp. 903-916.
33. Y. Wang, J. Xiang, R. Markert, and M. Liang, "Spectral kurtosis for fault detection, diagnosis and prognostics of rotating machines : A review with applications," *Mechanical Systems and Signal Processing*, 66, 2015, pp. 679-698.
34. F. De Lorenzo and M. Calabro, "Kurtosis: A Statistical Approach to Identify Defect in Roller Bearings," *2nd International Conference on Marine Research and Transportation*, Ischia, Naples, Italy, 2007, pp. 17-24.
35. B. Najafi, "Effect of Fatty Acid Ethyl Esters in Biodiesel Fuel on Diesel Engine Performance," *Fuel and Combustion*, 5, No. 2, 2012, pp. 25-34. (in Persian)
36. G. R. Kannan, R. Karvembu, and R. Anand, "Effect of metal based additive on performance emission and combustion characteristics of diesel engine fuelled with biodiesel," *Applied Energy*, 88, 2011, pp. 3694-3703.
37. M. Zhu, Y. Ma, and D. Zhang, "Effect of a homogeneous combustion catalyst on the combustion characteristics and fuel efficiency in a diesel engine," *Applied Energy*, 91, 2012, pp. 166-172.
38. M. Mirzajanzadeh *et al.*, "A novel soluble nano-catalysts in diesel-biodiesel fuel blends to improve diesel engines performance and reduce exhaust emissions," *Fuel*, 139, 2015, pp. 374-382.
39. V. Arul Mozhi Selvan, R. B. B. Anand, M. Udayakumar, V. A. M. Selvan, R. B. B. Anand, and M. Udayakumar, "Effect of Cerium Oxide Nanoparticles and Carbon Nanotubes as fuel-borne additives in Diesterol blends on the performance,

- combustion and emission characteristics of a variable compression ratio engine," *Fuel*, 130, 2014, pp. 160-167.
40. C. S. Aalam and C. G. G. Saravanan, "Effects of nano metal oxide blended Mahua biodiesel on CRDI diesel engine," *Ain Shams Engineering Journal*, 8, 2015, pp. 1-8.
41. S. Gumus, H. Ozcan, M. Ozbey, and B. Topaloglu, "Aluminum oxide and copper oxide nanodiesel fuel properties and usage in a compression ignition engine," *Fuel*, 163, 2016, pp. 80-87.
42. W. M. Yang *et al.*, "Emulsion fuel with novel nano-organic additives for diesel engine application," *Fuel*, 104, 2012, pp. 726-731.
43. K. Çelebi, E. Uludamar, E. Tosun, S. Yıldızhan, K. Aydin, and M. Özcanlı, "Experimental and artificial neural network approach of noise and vibration characteristic of an unmodified diesel engine fuelled with conventional diesel, and biodiesel blends with natural gas addition," *Fuel*, 197, 2017, pp. 159-173.
44. J. Syed, R. U. Baig, S. Algarni, Y. V. V. S. Murthy, M. Masood, and M. Inamurrahman, "Artificial Neural Network modeling of a hydrogen dual fueled diesel engine characteristics: An experiment approach," *International Journal of Hydrogen Energy*, 42, 2017, pp. 14750-14774.
45. H. Soukht Saraee, H. Taghavifar, and S. Jafarmadar, "Experimental and numerical consideration of the effect of CeO<sub>2</sub> nanoparticles on diesel engine performance and exhaust emission with the aid of artificial neural network," *Applied Thermal Engineering*, 113, 2017, pp. 663-672.
46. J. Rezaei, M. Shahbakhti, B. Bahri, and A. A. Aziz, "Performance prediction of HCCI engines with oxygenated fuels using artificial neural networks," *Applied Energy*, 138, 2015, pp. 460-473.

## English Abstract

### Modeling the effects of Carbon nanotubes added to diesel-biodiesel fuel blends on performance and emissions of a diesel engine using artificial neural network

Seyyed Hassan Hosseini<sup>1</sup>, Ahmad Taghizadeh-Alisaraei<sup>2\*</sup>, Barat Ghobadian<sup>3</sup> and Ahmad Abbaszadeh-Mayvan<sup>4</sup>

1- Department of Mechanical Biosystems, Gorgan University of Agricultural Science and Natural Resources, Gorgan, Iran, ho3eini1991@gmail.com

2- Department of Mechanical Biosystems, Gorgan University of Agricultural Science and Natural Resources, Gorgan, Iran, Ahmadtza@yahoo.com

3-Department of Mechanical Biosystems, Faculty of Agriculture, Tarbiat Modares University, P. O. Box Tehran, Iran, Ghobadib@modares.ac.ir

4- Department of Mechanical Biosystems, Gorgan University of Agricultural Science and Natural Resources, Gorgan, Iran, abbaszadeh62@gmail.com

\*Correspondent author

(Received: 2017.06.29, Received in revised form: 2017.07.08, Accepted: 2017.08.23)

Biodiesel and some nano-catalysts are an important additive to diesel fuel and can improve the engine performance and reduce emissions. In this study, biodiesel was added to pure diesel with ratios of 5 and 10 percent. Then, the carbon nanotubes were mixed as additive with these blends with concentrations of 30, 60, and 90 ppm to evaluate the performance, emissions, and vibration levels in a diesel engine. An ANN model, based on standard back-propagation learning algorithm for the engine, was developed. Multi-layer perception network (MLP) was used. The input or independent parameters were fuel blend, engine speed, fuel density, fuel viscosity, LHV, intake manifold pressure, fuel consumption, exhaust gas temperature, oxygen contained in exhaust gases, oil temperature, relative humidity and ambient air pressure. The target parameters were performance, emissions and RMS and Kurtosis of engine vibrations. The results showed that the specific fuel consumption and CO and UHC emissions decreased, while NOx emission increased. Also, the ANN model showed the training algorithm of back-propagation with 20-20 neurons in hidden layers (logsig-logsig) is able to predict different parameters with good performance and accuracy. The corresponding R-values for training, validation and testing were 0.9999, 0.9985 and 0.9994, respectively.

**Keywords:** Biodiesel with Carbon nanotubes, Emissions, Vibration, neural network