



مدل‌سازی و پیش‌بینی مصرف سوخت و آلاینده‌گی در موتورهای دیزلی پاشش مستقیم با استفاده از شبکه عصبی مصنوعی با اعمال پارامترهای کنترلی دور موتور، جرم سوخت و دمای هوای ورودی

عباس زارع نژاد اشکذری^{۱*} و محمدرضا هادوی^۲

^۱ استادیار، دانشکده مهندسی مکانیک، دانشگاه علوم دریایی امام خمینی (ره)، نوشهر، ایران

^۲ دانشجوی دکتری، دانشکده مهندسی مکانیک، دانشگاه تربیت دبیر شهید رجایی و دانشگاه علوم دریایی امام خمینی (ره)، تهران، ایران

مقاله مستقل، تاریخ دریافت: ۱۳۹۴/۱۲/۲۶ تاریخ بازنگری: ۱۳۹۸/۱۲/۱۷؛ تاریخ پذیرش: ۱۳۹۹/۰۳/۲۹

چکیده

در پژوهش حاضر با استفاده از شبکه عصبی مصنوعی، مدل‌سازی و پیش‌بینی آلاینده‌های NO_x ، دوده و مصرف سوخت در یک موتور دیزلی پاشش مستقیم با اعمال متغیرهای کنترلی دور موتور، دمای هوای ورودی و جرم سوخت پاشیده شده، انجام شده است. شبکه عصبی با الگوریتم لونیبرگ-مارکوارت برای آموزش ارتباط موجود بین پارامترهای مذکور، طوری طراحی شده که در آن مدل‌سازی متغیرهای خروجی به صورت کاملاً مستقل انجام می‌گیرد. به عبارت دیگر، برای هر خروجی مانند NO_x ، تعداد نرون‌های لایه پنهان و پارامترهای کنترلی شبکه کاملاً متفاوت از همین پارامترها برای دوده یا مصرف سوخت خواهد بود. نتایج نشان می‌دهد که شبکه عصبی طراحی شده، به ازای ۳۶ نرون در لایه پنهان در دور ۳۷۳۳ به دقت ۰/۹۷ برای آزمایش داده‌ها در مدل‌سازی آلاینده NO_x می‌رسد. از طرفی دقت آزمایش برای مدل شبکه‌ای مصرف سوخت به ازای ۱۹ نرون در لایه پنهان در دور ۳۶۹۸ برابر ۰/۹۴ بوده که کاهش نسبی دقت مدل‌سازی آن، مربوط به پراکندگی ناموزون داده‌های تجربی در طیف وسیعی از دامنه مدل‌سازی است. مدل پیشنهادی شبکه عصبی، به دلیل همگرایی سریع و زمان پاسخگویی کوتاه، می‌تواند به‌عنوان یک روش مؤثر در سیستم‌های کنترل هوشمند موتورهای دیزلی برای کاهش آلاینده‌ها و مصرف سوخت، مورد استفاده قرار گیرد.

کلمات کلیدی: شبکه عصبی مصنوعی؛ مدل‌سازی؛ آلاینده‌گی؛ مصرف سوخت.

Modeling and Prediction of Fuel Consumption and Emissions of Direct Injection Diesel Engines using Artificial Neural Network by Applying Control Parameters of Engine Speed, Fuel Mass and Inlet Air Temperature

A. Zarenezhad Ashkezari^{1,*}, M.R. Hadavi²

¹ Assistant Professor, University of Imam Khomeini Marine Sciences, Department of Mechanical Engineering, Nowshahr, Iran

² Ph.D. Candidate, Shahid Rajaei Teacher Training University and University of Imam Khomeini Marine Sciences, Department of Mechanical Engineering, Tehran, Iran.

Abstract

In the present study, using artificial neural network, modeling and prediction of NO_x , soot and fuel consumption in a diesel engine is done by applying control variables of engine speed, inlet air temperature and injected fuel mass. The neural network with the Levenberg-Marquardt algorithm is designed to train the existing relationship between the above parameters, in which the output variables are modeled completely independently. In other words, for any output such as NO_x , the number of hidden layer neurons as well as the lattice control parameters would be quite different from the same parameters for soot or fuel consumption. The results show that the designed neural network reaches accuracy 0.97 for 36 neurons in the hidden layer at 3733th epoch to test the data in NO_x modeling. On the other hand, the test accuracy for modeling fuel consumption for 19 neurons in the hidden layer at 3698th epoch was 0.94, which is due to the uneven distribution of the experimental data over a wide range of modeling ranges. The neural network can also be used as an effective method in diesel engines intelligent control systems to reduce pollutants and fuel consumption due to its fast convergence and short response time.

Keywords: Artificial Neural Network; Modeling; Emissions; Fuel Consumption.

۱- مقدمه

شناسایی رفتار سیستم‌های پیچیده و مدل‌سازی و پیش‌بینی عملکرد آن‌ها از روش‌هایی است که در شاخه‌های مختلف علوم کاربرد دارد. به‌صورت تئوری برای اینکه بتوان به درک درستی از رفتار یک سیستم پیچیده رسید، نیاز به این است که مدل ریاضی آن سیستم در دست باشد. در حقیقت هدف مدل‌سازی یک سیستم، یافتن یک تابع پیوسته یا گسسته ریاضی با هدف ایجاد ارتباط بین ورودی‌ها و خروجی‌های سیستم است. برای سیستم‌های پیچیده، یافتن این رابطه ریاضی کاری دشوار می‌نماید؛ ولی امروزه روش‌هایی مانند، منطق فازی و شبکه عصبی این کار را ممکن ساخته است. در حقیقت روش‌های شبکه عصبی، توانایی خود را در حل سیستم‌های پیچیده غیر خطی نشان داده‌اند. ماهیت پیچیده و غیرخطی موتورهای دیزلی با توجه به وابستگی عملکرد آن‌ها به پارامترهای مختلف (از ده‌ها پارامتر موثر در فرایند احتراق گرفته تا پارامترهای هندسی موتور) عملاً استفاده از یک روش ریاضی مبتنی بر تخمین یک ضابطه را بسیار سخت و دشوار می‌نماید. در ضمن استفاده از روشی دقیق با سرعت پاسخگویی سریع در یک سیستم کنترل هوشمند جهت استفاده در یک موتور دیزلی بسیار حائز اهمیت است. لذا جهت شناسایی، تحلیل و بهینه‌سازی پارامترهای عملکردی موتورهای دیزلی، ابتدا می‌بایست یک مدل‌سازی قوی به‌منظور ارتباط مناسب بین متغیرهای ورودی و خروجی موتور ایجاد گردد. شبیه‌سازی دقیق موتورها می‌تواند استفاده از تکنولوژی‌های جدید و ارزیابی‌های دقیق روی طراحی‌های نو را فراهم آورد و استفاده صحیح از این روش‌ها به طرز قابل توجهی زمان طراحی محصول را کاهش داده و باعث پیشرفت کار طراحی گردد. مدل‌های شبکه عصبی فارغ از اینکه ماهیت عملکردی موتورهای دیزلی تا چه اندازه می‌تواند پیچیده باشد، با استفاده از داده‌های تجربی مکفی می‌تواند به‌خوبی و با دقت بالا، آن را مدل نماید. تحقیقات وسیعی برای گسترش این گونه روش‌ها در سال‌های اخیر انجام شده است.

محسنیان و همکاران [۱]، با استفاده از شبکه عصبی مصنوعی پدیده‌های آفرز و انتشار شعله در یک موتور بنزینی را پیش‌بینی کردند. ورودی‌های شبکه عصبی، نسبت هم‌ارزی، انرژی، مدت زمان جرقه و فاصله الکترودها بوده و

رشد هسته شعله اولیه (زمان طی شده از لحظه جرقه تا شروع گسترش شعله) و سرعت شعله به عنوان خروجی‌های شبکه در نظر گرفته شد. سپس براساس شبکه عصبی ایجاد شده، خطای پیش‌بینی هر سیستم و انحراف مقادیر داده شده به‌وسیله آن، ارزیابی و بهترین سیستم برای پیش‌بینی آفرز و انتشار شعله پیشنهاد گردید. پارلاک و همکاران [۲]، با استفاده از شبکه عصبی مصنوعی، مصرف سوخت ویژه و دمای گازهای خروجی در یک موتور دیزلی را پیش‌بینی کردند. آن‌ها در این تحقیق آزمایشات متعددی را در دوره‌های مختلف موتور، زمان‌های مختلف پاشش سوخت و همچنین فشارهای متغیر هوای ورودی، جهت آموزش و آزمایش شبکه عصبی انجام دادند. سپس با استفاده از شبکه عصبی به‌دست آمده، مصرف سوخت ویژه و دمای گازهای خروجی را در شرایط مختلف کارکردی موتور (از دیدگاه سرعت، بار و زمان‌های پاشش سوخت) پیش‌بینی کردند که نتایج مطلوبی توسط شبکه عصبی حاصل شد. در تحقیق دیگری که توسط راماداس و همکاران [۳]، جهت بررسی توانایی شبکه عصبی در مدل‌سازی مقادیر عدد ستان سوخت در یک موتور دیزلی با سوخت بیودیزل انجام گرفت، به خوبی نشان داده شد که قابلیت شبکه عصبی در پیش‌بینی مقادیر پارامترهای خروجی، وابستگی شدیدی به نوع الگوریتم‌های به‌کار رفته در فرایند آموزش شبکه و تعداد داده‌های ورودی و خروجی استفاده شده در آن دارد. تحقیقات مشابه دیگری نیز به موضوع مدل‌سازی با استفاده از قابلیت‌های شبکه عصبی با رویکردهای متفاوت براساس تمرکز بر پارامترهای کنترلی موتورهای احتراق داخلی انجام گرفته است که از آن جمله می‌توان به کارهای انجام گرفته در مراجع [۴-۱۲]، اشاره کرد.

همچنین بهینه‌سازی شرایط عملکردی موتورهای احتراق داخلی با اعمال پارامترهای مختلف کنترلی موتور، با به‌کارگیری روش‌هایی همچون الگوریتم ژنتیک، مورچگان و نیز بررسی توانایی الگوریتم‌های مختلف در همگرایی سریع، در پژوهش‌های دیگری به وفور و به طور مفصل یافت می‌شوند [۱۲-۱۶]. ترکیب شبکه عصبی با الگوریتم مورچگان در مدل‌سازی یک موتور دیزلی و بهینه‌سازی آلایندگی‌های NO_x و دوده در تحقیقی که توسط محمدحسینی و همکاران انجام گرفته، مورد توجه و ارزیابی قرار گرفته است و

نمی‌شود، دینامومتر به صورت آزادانه روی بلبرینگ‌ها چرخش می‌کند، اما به محض اعمال بار، مقاومت ایجاد شده در اثر میدان مغناطیسی روی نیروسنج وارد شده و عدد نشان داده شده توسط نیروسنج به عنوان گشتاور وارد بر موتور شناخته می‌شود.

دستگاه مورد استفاده جهت اندازه‌گیری مصرف سوخت یک دی‌سنج جرمی SWPF-60 A بود که با دقت صدم کیلوگرم بر ساعت اندازه‌گیری می‌نمود. اساس عملکرد آن این‌گونه بود که سوخت از مخزن خارج شده و در یک بازه زمانی مشخص، میزان اختلاف وزن مخزن، اندازه‌گیری شده و در نهایت مقدار مصرف سوخت در بازه زمان مشخص می‌گردد. حسگرهای دما از نوع دماسنج مقاومتی (R) می‌باشند که قابلیت اندازه‌گیری دما تا ۱۹۰۰ درجه کلوین را داراست. پیچ آن‌ها از پلاتین خالص ساخته شده، میزان مقاومت پایه آن‌ها حدود ۱۰۰ اهم است. چون اتاق آزمون، مجهز به مدار الکتریکی مخصوصی بوده و مقاومت را در حسگر مربوطه سریعاً به ولتاژ تبدیل می‌کند، لذا پاسخ‌پذیری حسگرهای دما در حد مطلوب بوده و دقت آن‌ها ± 1 درجه کلوین است. برای اندازه‌گیری دور از یک دورسنج مغناطیسی استفاده شد که به شافت خروجی متصل است؛ همچنین برای اندازه‌گیری آلایندگی NO_x در کلیه مراحل آزمون موتور، از دستگاه AVL Dicom 4000 با دقت اندازه‌گیری $\pm 10 \text{ ppm}$ ساخت کشور اتریش استفاده شده است. این دستگاه دارای یک صفحه نمایش است که اطلاعات حاصل از سنجش آلایندگی را نشان می‌دهد. برای اندازه‌گیری آلایندگی دوده از دستگاه AVL Smoke meter V1.13 415S با دقت اندازه‌گیری $\pm 10 \text{ mg/m}^3$ استفاده شده است. لازم به یادآوری است که دستگاه‌های اندازه‌گیری آلایندگی، قبل از انجام آزمایش‌ها به طور دقیق کالیبره شده تا از دقت اندازه‌گیری‌ها اطمینان حاصل شود. کالیبراسیون دستگاه در جدول ۲ آمده است. اطلاعات مربوط به نتایج آزمایشات در یک سیستم کامپیوتری آنالیز و دریافت می‌گردد. محدوده تعریف شده برای دور موتور از ۵۹۱ تا ۲۳۰۸ دور در دقیقه بود. به ازای هر دور کاری موتور در این محدوده، نرخ جرمی سوخت پاشیده شده و دمای هوای ورودی نیز متغیر است. آزمون‌های موتور در قالب یک سری آزمایشات با هدف اندازه‌گیری مصرف سوخت و آلایندگی‌های NO_x و دوده با استفاده از

نتایج خوبی از همگرایی سریع الگوریتم به مقادیر بهینه نسبی با کاهش همزمان دو آلایندگی مذکور به دست آمده است [۱۷].

در مطالعات قبلی بطور پراکنده، پارامترهای قابل کنترل در موتورهای احتراق داخلی، با استفاده از شبکه عصبی و یا الگوریتم‌های فرا ابتکاری با تعداد زیادی از داده‌های تجربی برای آموزش شبکه، بررسی شده است. با وجود تحقیقات فراوان در عرصه‌های مختلف جهت مدل‌سازی مسائل متعدد، کاربرد شبکه‌های عصبی مصنوعی با ساختار پرسپترون چند لایه، هنوز در بسیاری از زمینه‌ها بالاخص در حوزه مدل‌سازی موتورهای دیزلی پاشش مستقیم چندان مورد تحقیق قرار نگرفته و سرعت همگرایی و همچنین دقت جواب‌های به‌دست آمده که در سیستم‌های کنترلی هوشمند وسایل نقلیه بسیار حائز اهمیت است، مورد ارزیابی قرار نگرفته است. در پژوهش حاضر، با استفاده از نتایج تجربی به‌دست آمده از آزمایش یک موتور دیزل پاشش مستقیم و با بهره‌گیری و توسعه شبکه عصبی پرسپترون چند لایه و با تعداد محدودی از داده‌های تجربی، به مدل‌سازی و پیش‌بینی آلایندگی‌های NO_x ، دوده و مصرف سوخت موتور با تمرکز بر پارامترهای کنترلی دور موتور، دمای هوای ورودی و میزان سوخت پاشیده شده، پرداخته شده است. همچنین سرعت همگرایی، صحت عملکرد و دقت شبکه عصبی پیشنهادی، در مدل‌سازی مسئله، مورد آزمون قرار گرفته است.

۲- انجام آزمایش

موتور استفاده شده در این تحقیق، موتور دیزلی پاشش مستقیم چهار زمانه شش سیلندر با قدرت ۲۴۰ اسب بخار در سرعت دورانی ۱۴۰۰ دور در دقیقه و با حجم جابجایی ۱۱/۵۸ سی‌سی است. مشخصات فنی موتور در جدول ۱ و همچنین طرحواره بستر آزمون در شکل ۱ آمده است. به منظور اندازه‌گیری گشتاور و توان، از یک دینامومتر هیدرولیکی ۴۰۰ کیلو وات، با دقت اندازه‌گیری ± 2 نیوتن متر و ثابت نگه داشتن دور با دقت ± 5 دور در دقیقه استفاده شده که با ایجاد میدان مغناطیسی نیروی ترمزی در برابر چرخش موتور ایجاد می‌نماید. دینامومترهای ادی کارنت مجهز به سامانه داده برداری عددی بوده که با جریان آب خنک می‌گردند. در حالی که هیچ باری روی موتور اعمال

جدول ۱- مشخصات موتور مورد بررسی [۱۸]

نوع موتور	دیزلی پاشش مستقیم تنفس طبیعی
کورس × قطر	۱۵۰ × ۱۲۸ (میلی‌متر)
نسبت تراکم	۱۶/۱:۱
حجم جابجایی	۱۱/۵۸ (لیتر)
باز شدن سوپاپ خروجی	۶۰° BBDC
بسته شدن سوپاپ ورودی	۶۰° ABDC
تعداد سیلندر	۶
دور موتور	۲۳۰۸-۵۹۱ (دور در دقیقه)
شروع پاشش سوخت	۱۶° BTDC
دمای سوخت پاشیده شده	۳۵۳ (درجه کلون)


جدول ۲- پارامترها، محدوده تغییرات و دقت دستگاه
AVL Dicom 4000

پارامتر	محدوده کالیبراسیون	دقت
NO _x	۰-۵۰۰۰۰ (ppm) حجمی	۱۰ ppm
λ	۰-۹۹۹۹	۰/۰۰۱
دمای روغن	۰ (°C) - ۱۵۰ (°C)	۱ (°C)

۳- تحلیل عدم قطعیت داده‌های آزمایشگاهی


در مطالعات تجربی محاسبه عدم قطعیت امری ضروری است. عدم قطعیت اطلاعاتی در مورد کیفیت پارامترهای اندازه‌گیری شده ارائه می‌دهد. به عبارت دیگر عدم قطعیت در مورد شک و احتمال درستی نتیجه پارامتر اندازه‌گیری شده اطلاعاتی را بیان می‌کند. صرف‌نظر از دقت آزمایش، به دلایل مختلف ممکن است، در جمع آوری داده‌های تجربی خطا وجود داشته باشد. بعضی از این خطاها از نوع تصادفی بوده و برخی به علت بروز اشتباه حین انجام آزمایش رخ می‌دهند. داده‌های نادرست حاصل از اشتباهات واضح بلافاصله قابل

سوخت گازوییل انجام گرفت. نحوه انجام آزمایش بدین صورت بود که ابتدا موتور در حدود ۱۰ دقیقه گرم شده تا از نظر دمای آب ورودی و خروجی و دمای روغن به حالت پایا برسد و آزمایشات در حالت تقریباً متعادل و پایدار انجام گیرد. جهت آماده کردن دستگاه ابتدا سطح روغن داخل کارتل چک گردیده تا کاملاً پر باشد. سپس جریان ورودی آب را به دینامومتر برقرار نموده و شیر سوزنی را باز کرده که با ماکزیمم جریان آب به دست آمده، این اطمینان بوجود آید که آب‌بندهای دینامومتر روغنکاری شده‌اند. حال جریان آب را تا حد چکه‌چکه کردن کاهش داده و موتور را روشن می‌نماییم. اجازه داده که موتور حدود ده دقیقه کار کند تا گرم شود. حال اهرم کنترل گاز تا موقعیت ماکزیمم آن جلو برده و سرعت ماکزیمم موتور یادداشت گردید. وقتی موتور خروجی یکنواختی پیدا کرد، سرعت، گشتاور، دمای هوای ورودی، جرم سوخت، مقدار آلاینده‌های NO_x، دوده و مصرف سوخت ترمزی یادداشت گردید و این روند برای شرایط کارکردی مختلف تکرار گردید. پس از انجام آزمایش، شیر سوزنی به آرامی بسته می‌شود. آنگاه گاز را بسته تا دور موتور آرام شود. اجازه داده تا موتور چند دقیقه‌ای در این حالت کار کند. آنگاه موتور خاموش شده و شیر اصلی آب بسته می‌شود. لازم به ذکر است که اندازه‌گیری برای هر نمونه سه مرتبه تکرار شد و میانگین آن‌ها به عنوان داده نهایی ثبت شد. تمامی تجهیزات، پیش از انجام آزمایش‌ها کالیبره شده تا از بروز خطای احتمالی در داده‌های آزمایشگاهی بدست آمده تا حد امکان جلوگیری شود.



شکل ۱- طرحواره بستر آزمون موتور: (a) مخزن سوخت، (b) مخزن هوا، (c) موتور مورد نظر جهت آزمایش، (d) صدا خفه‌کن، (e) دستگاه آنالایزر آلاینده‌ها، (f) دورسنج، (g) دینامومتر، (h) ظرف اندازه‌گیری دبی هوا، (i) ظرف اندازه‌گیری دبی سوخت، (j) ترنسیوسر، (k) دماسنج

داده‌های آزمایشگاهی جلوگیری شود. در هر مرحله ممکن است، اندکی اختلاف مشاهده شود که از خصوصیات کارهای تجربی است. این اختلاف ممکن است، به دلیل خطای دستگاه ثبت داده‌های آزمایشگاهی، از کالیبره خارج شدن حسگرها و یا خطای اپراتور باشد. برای حصول اطمینان از صحت نتایج به دست آمده اعداد نامربوط حذف می‌شوند. بطور مثال اگر از سه مقدار ثبت شده، عددی غیرمنطقی باشد، آن را کنار گذاشته و با استفاده از روابط به دست آمده درصد عدم قطعیت حاصل می‌شود. برای مثال، همانطور که نتایج نشان می‌دهد، داده‌های ثبت شده برای NO_x با $\pm 4\%$ قابل پذیرش است. به عبارت دیگر، اگر در نتایج $NO_x = 100 \text{ ppm}$ ، این مقدار در محدوده $[96 - 104 \text{ ppm}]$ یعنی $100 \pm 4 \text{ ppm}$ خواهد بود.



شکل ۲- مقادیر میانگین عدم قطعیت برای مصرف سوخت و آلاینده‌های NO_x و دوده

۴- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی^۱، یک ساختار ریاضی است که با الگوبرداری از مغز انسان، بین مجموعه‌ای از اعداد ورودی و خروجی، یک نگاشت برقرار می‌کند، بگونه‌ای که می‌توان از مجموعه m عضوی ورودی، به مجموعه n عضوی خروجی مورد نظر رسید. اساس کار بر این است که در ابتدا از تعدادی داده و مواد خام موجود استفاده کرده و شبکه با آن‌ها آموزش داده می‌شود. داده‌ها، یک دسته زوج شامل مجموعه ورودی و خروجی است که معمولاً از محاسبه یا از طریق تجربه و

تشخیص بوده و کنار گذاشته می‌شوند؛ ولی در مورد داده‌هایی که مشکوک هستند، به سادگی نمی‌توان تشخیص داد؛ بنابراین جهت تشخیص این خطاها، از تحلیل عدم قطعیت داده‌های آزمایشگاهی که به روش آماری صورت گرفته، استفاده شده است. عدم قطعیت یا مقدار احتمالی خطا، بسته به شرایط آزمایش ممکن است به میزان زیادی تغییر کند. خطاهای ثابت و تصادفی خطاهایی هستند که ممکن است، در یک اندازه گیری تجربی سبب عدم قطعیت گردند. معمولاً خطاهای ثابت با کالیبره نمودن وسایل اندازه‌گیری از بین می‌روند، ولی خطاهای تصادفی از طریق تحلیل آماری شناسایی می‌شوند. در کار حاضر با توجه به اینکه آزمون‌های موتور در قالب سه سری تکرار آزمایشات با هدف اندازه گیری مصرف سوخت و آلاینده‌های NO_x و دوده انجام گرفته است، لذا برای هر نقطه، سه داده آزمایشگاهی جمع آوری شده و سپس میانگین داده‌ها محاسبه و به‌عنوان داده نهایی آزمایشگاهی استفاده شده است.

خطای احتمالی یا عدم قطعیت داده‌ها از رابطه (۱) محاسبه می‌شود:

$$\sigma_m = \frac{\sigma}{n^{0.5}} \quad (1)$$

که در این رابطه، σ_m انحراف معیار مقدار میانگین و σ انحراف معیار مجموعه اندازه گیری‌ها و n تعداد اندازه گیری‌ها در هر نقطه است. برای کلیه نتایج آزمایشگاهی $n = 3$ است. درصد عدم قطعیت داده‌های آزمایشگاهی نیز از رابطه (۲) محاسبه شده است:

$$X = \frac{\sigma_m}{\bar{x}} \times 100 \quad (2)$$

در رابطه بالا، X ، عدم قطعیت داده آزمایشگاهی بر حسب درصد و \bar{x} مقدار میانگین حسابی داده‌های آزمایشگاهی است.

در شکل ۲، مقدار میانگین عدم قطعیت داده‌های آزمایشگاهی برای مصرف سوخت و آلاینده‌های NO_x و دوده نشان داده شده است.

در یک مرحله آزمایش، یعنی در یک دور مشخص و در یک مقدار جرمی سوخت پاشیده شده و در یک دمای هوای ورودی به موتور در شرایط پایدار، آلاینده‌های NO_x ، دوده و مصرف سوخت اندازه گیری می‌شود. هر آزمایش سه بار تکرار شده تا حتی المقدور از بروز خطا در نمونه گیری و ثبت

¹ Artificial Neural Network (ANN)

معادلات (۴) و (۵) مقادیر خروجی‌های u_i و نرون‌های y_i را به ترتیب نشان می‌دهند:

$$u_i = \sum_{j=1}^n w_{ij} x_j + b_i \quad (۴)$$

$$y_i = f(u_i) \quad (۵)$$

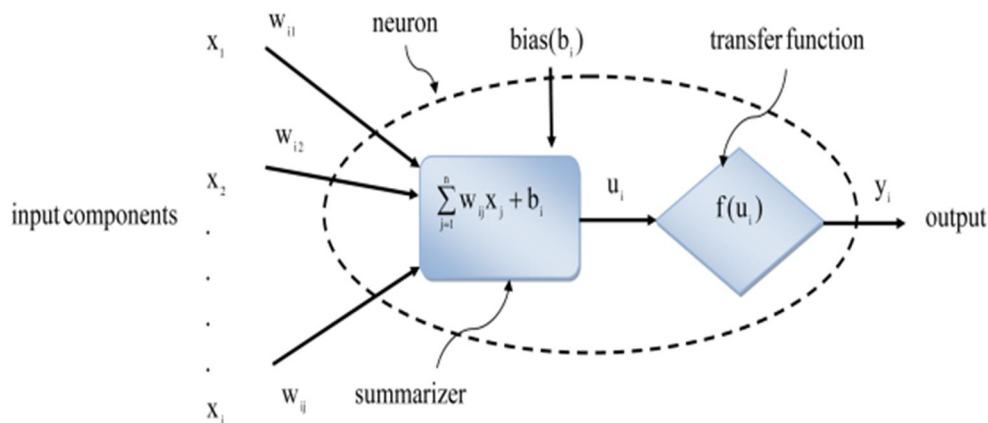
که در آن x_j مولفه j ام ورودی‌های نمایشی x ، و f تابع انتقال شبکه است.

مطابق با نظریه کلموگروف، یک شبکه پرسپترون چند لایه‌ای می‌تواند یک رابطه پیچیده و غیرخطی بین ورودی‌ها و خروجی‌های یک سیستم را تخمین بزند. همانگونه که در شکل ۴ مشاهده می‌گردد، یک پرسپترون سه لایه، یکی از ساده‌ترین و موثرترین شبکه‌هایی است که می‌تواند به دلیل تعداد پارامترهای کنترلی کم، در شبیه‌سازی سیستم‌های پیچیده مورد استفاده قرار گیرد. الگوریتم پس انتشار که به طور وسیعی در شبکه‌های پرسپترون کاربرد دارد، یک روش کاهش خطای خروجی شبکه بر پایه دستورالعمل کاهش گرادیانی با استفاده از تنظیم وزن‌ها و بایاس‌ها، نسبت به نرون‌های متناظر شبکه است. فرایند آموزش شبکه با تنظیم وزن‌ها و بایاس‌ها نسبت به هر نرون انجام می‌گیرد که این عمل توسط توابع انتقال مخصوصی انجام می‌گیرد. هدف از آموزش شبکه، پیدا کردن تعدادی از وزن‌ها و بایاس‌های بهینه است که شبکه بتواند توسط آن‌ها و به ازای هر مجموعه داده ورودی دلخواه، مقادیر خروجی قابل قبول و نزدیک به خروجی تجربی تولید کند. لازم به یادآوری است

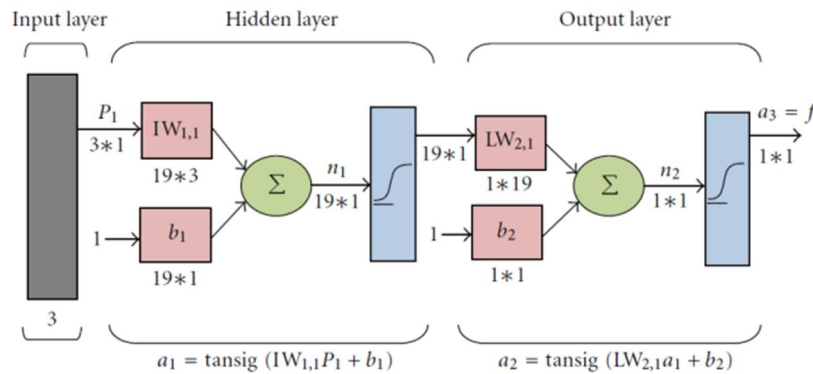
آزمایش به دست می‌آید. آموزش شبکه یعنی دستیابی به شبکه و مشخصات آن، به نحوی که بتواند نگاشت مزبور را بین هر یک از داده‌های ورودی و داده خروجی مربوطه آن برقرار کند. شبکه‌های عصبی، قادر به مدل‌سازی مسائل پیچیده در زمینه‌های مختلف از جمله موتور و مدل‌سازی آلایندگی‌ها و بطور کلی توانایی حل سیستم‌های پیچیده غیر خطی را دارا می‌باشند. از جمله مزایای شبکه عصبی، پیش‌بینی خروجی سیستم با دقت و سرعت بالا است.

المان‌های اساسی در یک شبکه عصبی نرون‌ها هستند که شامل وزن‌ها، بایاس‌ها، تجمیع‌کننده و توابع انتقال می‌باشند که در شکل ۳ نشان داده شده است. هر کدام از نرون‌ها، ورودی‌های x_1, x_2, \dots, x_n را دریافت می‌کنند که توسط w_i وزن‌دار شده‌اند. بایاس b_i که یک مقدار ثابت غیرصفر است، به ورودی‌های وزن‌دار در تجمیع‌کننده اضافه می‌گردد؛ مجموع به دست آمده وارد تابع انتقال می‌شود و خروجی مربوط به تابع انتقال به عنوان خروجی نرون حاصل می‌شود. توابع انتقال مختلف همچون tansig و logsig انواع متفاوتی از خروجی‌ها را به دست می‌دهند. بهتر است ورودی‌های مورد استفاده در شبکه بی‌بعد گردند تا نوع ورودی، تأثیری بر نتایج خروجی نداشته باشد. خروجی‌ها نیز با توجه به نوع تابع انتقال می‌توانند در بازه‌های مختلفی قرار گیرند. مثلاً تابع logsig که به صورت زیر تعریف می‌شود، مقادیر خروجی بین صفر و یک به دست می‌دهد:

$$y_j = \text{logsig}(u_j) = \frac{1}{1 + e^{-u_j}} \quad (۳)$$



شکل ۳- نمایشی ساده از عملکرد ریاضی یک نرون شبکه عصبی مصنوعی [۱۹]




شکل ۴- ساختار نمونه از شبکه عصبی پرسپترونی [۱۹]

بررسی بوده و به ترتیب ۳ و ۱ می‌باشند. الگوریتم مورد استفاده جهت آموزش مسئله، لونیبرگ-مارکوارت بوده و توابع انتقال لایه ورودی و خروجی هر دو از نوع $tansig$ است که به صورت رابطه (۶) تعریف می‌شود:

$$\text{tansig}(n) = \frac{2}{1 + e^{-2n}} - 1 \quad (6)$$

روند مدل‌سازی در شبکه‌های در نظر گرفته شده به این صورت است که ابتدا تعداد ۱۴۴ داده تجربی، وارد شبکه شده‌اند. این داده‌ها براساس آزمایشات انجام گرفته، استخراج شده و برای پارامترهای کنترلی مذکور اعمال گردیده است. لازم به ذکر است که محدوده پارامترهای ورودی دور موتور، دمای هوا و جرم سوخت پاشیده شده برای شبکه مذکور، مطابق جدول (۳) به ترتیب در بازه‌های [۲۳۰۸، ۵۹۱]، [۲۸/۳، ۱۵/۴] و [۱۰/۳۱، ۰/۳۹] قرار دارند.

فلوچارت شبکه عصبی مورد نظر جهت مدل‌سازی در شکل ۶ آمده است.

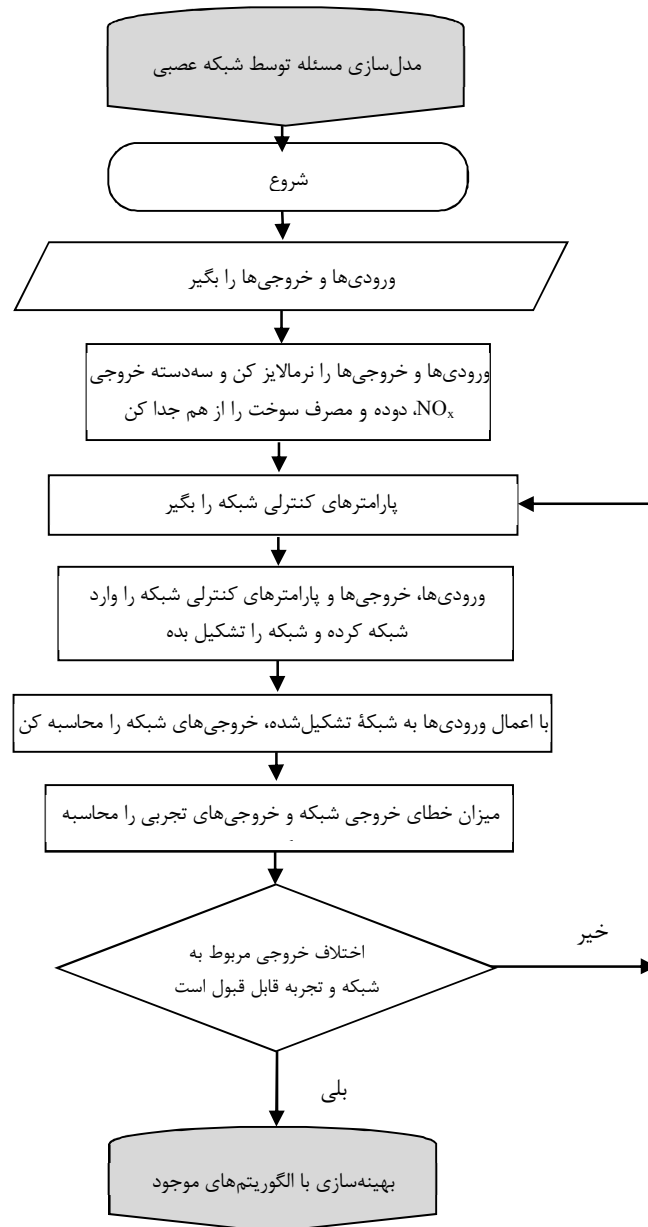


شکل ۵- ساختار شبکه عصبی برای سه ورودی سرعت موتور، دمای هوای ورودی و جرم سوخت پاشیده شده

که نوع توابع انتقال و الگوریتم‌های آموزشی نقش اساسی در مدل‌سازی شبکه ایفا می‌کنند؛ بنابراین باید متناسب با نوع مسئله به دقت انتخاب گردند. به عنوان مثال برای یک مسئله خاص از شکل ۴ چنین برداشت می‌شود که تعداد پارامترهای ورودی ۳ و تعداد پارامترهای خروجی ۱ است. تعداد نرون‌های لایه پنهان و خروجی هر دو ۱۹ است و نوع تابع انتقال در هر دو لایه تابع $tansig$ در نظر گرفته شده است.

۵- مدل پیشنهادی شبکه عصبی

با توجه به اینکه داده‌های تجربی برای ورودی‌های مختلف هم از جهت تعداد و هم از جهت تطابق (منظم نبودن داده‌های ورودی به ازای هر داده خروجی) دارای ناهمگونی می‌باشند، لذا برای کاهش میزان تأثیرگذاری خطاهای حاصل، یک شبکه عصبی با سه پارامتر ورودی در نظر گرفته شده است. در شکل ۵، ساختار شبکه عصبی طراحی شده برای مدل‌سازی NO_x ، دوده و همچنین مصرف سوخت، با توجه به سه پارامتر ورودی سرعت موتور، دمای هوای ورودی و جرم سوخت پاشیده شده، نشان داده شده است. شبکه مذکور طوری طراحی شده است که در آن مدل‌سازی پارامترهای خروجی به صورت کاملاً مستقل انجام می‌گیرد؛ یعنی برای هر خروجی مانند NO_x ، تعداد نرون‌های لایه پنهان و همچنین پارامترهای کنترلی شبکه کاملاً متفاوت از همین پارامترها برای آلاینده دوده یا مصرف سوخت خواهد بود. تعداد نرون‌های لایه پنهان با استفاده از روش آزمون و خطا به دست آمده است. تعداد نرون‌های لایه‌های ورودی و خروجی متناظر با تعداد ورودی‌ها و خروجی‌های مسئله مورد



شکل ۶- فلوجارت شبکه عصبی موردنظر جهت مدل‌سازی

همچنین انواع مکانیزم‌های بروز رسانی وزن‌ها و بایاس‌ها (LM, Gd, Gdm, Cgb, Cgp) در شبکه مذکور ارزیابی گردیده تا عملکرد تک تک آن‌ها برای مسئله حاضر سنجیده شود. مطابق این ارزیابی که نتایج آن‌ها در جداول ۴ تا ۶ آورده شده است، مکانیزم بروز رسانی Cgb نتایج بهتری برای

مدل‌سازی آلاینده NO_x و مصرف سوخت و مکانیزم Cgp نتیجه بهتری برای آلاینده دوده در پی دارد. همانطور که مشاهده می‌شود، شبکه عصبی طراحی شده، به ازای ۳۶ نرون در لایه پنهان در دور ۳۷۳۳ به خطایی کمتر از ۳ درصد برای آزمایش داده‌ها در مدل‌سازی آلاینده NO_x می‌رسد.

این آلاینده نمی‌باشد. در نهایت شبکه مورد نظر، برای مدل‌سازی مصرف سوخت با توجه به مقادیر جدول ۶ ساده‌ترین شبکه از لحاظ تعداد نرون‌های فرایند مدل‌سازی خواهد بود. خطای آزمایش برای مدل شبکه‌ای مصرف سوخت، کمی بیشتر از دو مدل ایجاد شده برای NO_x و دوده است. به عبارت دیگر، شبکه مورد نظر به ازای ۱۹ نرون در لایه پنهان در دور ۳۶۹۸ به خطای ۶ درصدی برای آزمایش داده‌ها در مدل‌سازی مصرف سوخت می‌رسد. دلایل متعددی می‌توان برای کاهش نسبی دقت مدل‌سازی آن ذکر کرد که از آن جمله می‌توان به پراکندگی ناموزون داده‌های تجربی برای این پارامتر در طیف وسیعی از دامنه مدل‌سازی اشاره کرد. در جداول زیر، \bar{b} ، تعداد بهینه نرون‌ها در لایه پنهان است.

جدول ۳- دامنه تغییرات ورودی‌های شبکه عصبی

پارامتر کارکردی	واحد	دامنه تغییر
دور موتور	rpm	[۵۹۱، ۲۳۰۸]
دمای هوای ورودی	°C	[۱۵/۴، ۲۸/۳]
جرم سوخت پاشیده شده	g/sec	[۰/۳۹، ۱۰/۳۱]

نکته‌ای که حائز اهمیت است، این است که افزایش تعداد نرون‌ها تأثیر قابل توجهی روی کاهش خطا در شبکه نخواهد داشت، هر چند این امر باعث بزرگتر شدن شبکه و پیچیدگی بیشتر آن خواهد شد. مطابق با جدول ۵، فرایند مدل‌سازی دوده با تعداد نرون‌های بیشتر در دور پایین‌تری انجام می‌شود ولی این امر به معنی کاهش یافتن خطای مدل‌سازی در مورد

جدول ۴- نتایج آموزش و آزمایش شبکه برای مدل‌سازی NO_x با استفاده از الگوریتم‌های آموزشی مختلف و بهترین \bar{b}

training algorithm	training MSE	testing MSE	training R	testing R	optimizing epoch	optimized \bar{b}
LM	۰/۰۰۳۱	۰/۰۰۲۸	۰/۹۰۲	۰/۹۱۱	۴۹۸۰	۱۱
Gd	۰/۰۰۳۴	۰/۰۰۲۸	۰/۸۸۱	۰/۹۱۸	۲۴۹۲	۲۵
Gdm	۰/۰۰۳۱	۰/۰۰۲۷	۰/۹۰۳	۰/۹۲۷	۹۹۳۰	۴۲
Cgb	۰/۰۰۱۹	۰/۰۰۱۴	۰/۹۷۶	۰/۹۷۱	۳۷۳۳	۲۶
Cgp	۰/۰۰۲۱	۰/۰۰۲۵	۰/۹۵۸	۰/۹۶۱	۲۵۰۱	۲۵

جدول ۵- نتایج آموزش و آزمایش شبکه برای مدل‌سازی دوده با استفاده از الگوریتم‌های آموزشی مختلف و بهترین \bar{b}

training algorithm	training MSE	testing MSE	training R	testing R	optimizing epoch	optimized \bar{b}
LM	۰/۰۳۹۱	۰/۰۰۵۰	۰/۹۵۵	۰/۹۵۳	۳۱۱	۱۷
Gd	۰/۰۵۳۲	۰/۰۰۳۴	۰/۹۴۱	۰/۹۴۸	۲۰۵۰	۵۵
Gdm	۰/۰۴۹۱	۰/۰۴۲۲	۰/۸۶۷	۰/۹۰۱	۱۹۸۹	۴۵
Cgb	۰/۰۰۶۷	۰/۰۰۸۱	۰/۹۶۴	۰/۹۴۰	۲۰۷۰	۴۲
Cgp	۰/۰۰۱۰	۰/۰۰۲۵	۰/۹۷۲	۰/۹۶۰	۲۰۸۱	۳۸


جدول ۶- نتایج آموزش و آزمایش شبکه برای مدل‌سازی مصرف سوخت با استفاده از الگوریتم‌های آموزشی مختلف و بهترین \mathcal{B}

training algorithm	training MSE	testing MSE	training R	testing R	optimizing epoch	optimized \mathcal{B}
LM	۰/۰۰۵۲	۰/۰۰۳۳	۰/۸۸۸	۰/۹۰۰	۳۸۹۸	۱۴
Gd	۰/۰۰۲۵	۰/۰۰۳۵	۰/۸۹۰	۰/۹۱۸	۲۶۵۳	۲۸
Gdm	۰/۰۰۳۸	۰/۰۰۲۹	۰/۹۲۵	۰/۹۴۵	۸۵۴۱	۴۸
Cgb	۰/۰۰۲۱	۰/۰۰۳۸	۰/۹۵۸	۰/۹۴۹	۳۶۹۸	۱۹
Cgp	۰/۰۰۲۸	۰/۰۰۴۲	۰/۹۵۶	۰/۹۴۸	۴۲۰۵	۳۰


عصبی است. با توجه به نمودارهای رسم شده می‌توان نتیجه گرفت که هرچه قدر داده‌های خروجی مربوط به شبکه در هر ناحیه به خط چین (که بیانگر رابطه $\text{output} = \text{target}$ است)، نزدیکتر باشد، مدل‌سازی در آن ناحیه بهتر انجام گرفته است. این شکل‌ها، دقت و کارایی شبکه را در مدل‌سازی پارامترهای مختلف نشان می‌دهند. R در نمودارهای شبکه عصبی ضریب تصحیح نامیده می‌شود که بیانگر میزان انحراف خروجی‌های شبکه با خروجی‌های تجربی است و هر چه این مقدار به عدد ۱ نزدیکتر باشد، مجموع مربعات خطا کمتر است و شبکه از قابلیت مدل‌سازی بهتری برخوردار است.

۶- نتایج مدل‌سازی شبکه عصبی

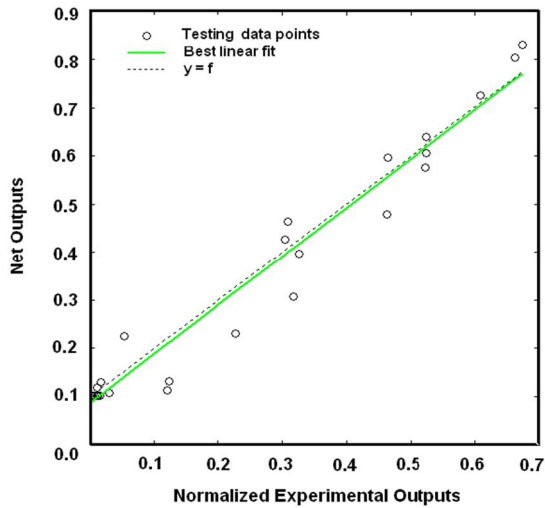
در اشکال ۷ تا ۱۲، نمودارهای مربوط به دقت مدل‌سازی شبکه به همراه نمودار همگرایی خطای درجه دو متوسط، برای دو حالت آموزش و آزمایش شبکه در خصوص آلاینده‌های NO_x ، دوده و همچنین مصرف سوخت نمایش داده شده‌است. ذکر این نکته ضروری است که خطای به‌دست آمده برای آزمایش شبکه توسط داده‌های مستقل از داده‌های مورد نیاز برای آموزش شبکه به‌دست می‌آید؛ در واقع این خطا عملکرد شبکه و خطای کلی آن را نشان می‌دهد. محور افقی، نتایج بی‌بعد شده خروجی واقعی (تجربی) و محور عمودی، خروجی‌های بی‌بعد پیش‌بینی شده توسط شبکه



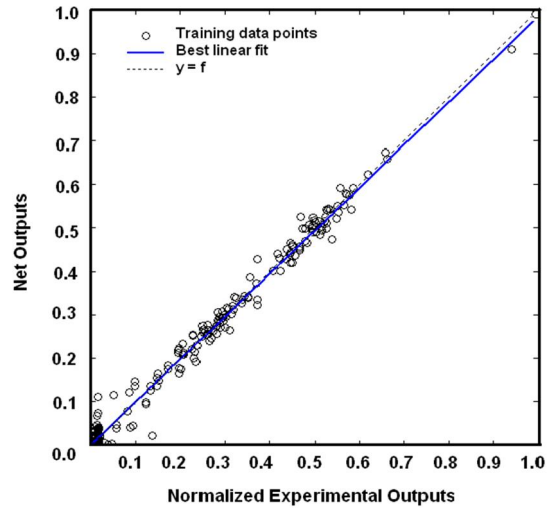
شکل ۸- خروجی‌های مربوط به آزمایش شبکه در برابر خروجی‌های آزمایشگاهی برای NO_x با ضریب تصحیح $R=0.971$




شکل ۷- خروجی‌های مربوط به آموزش شبکه در برابر خروجی‌های آزمایشگاهی برای NO_x با ضریب تصحیح $R=0.976$



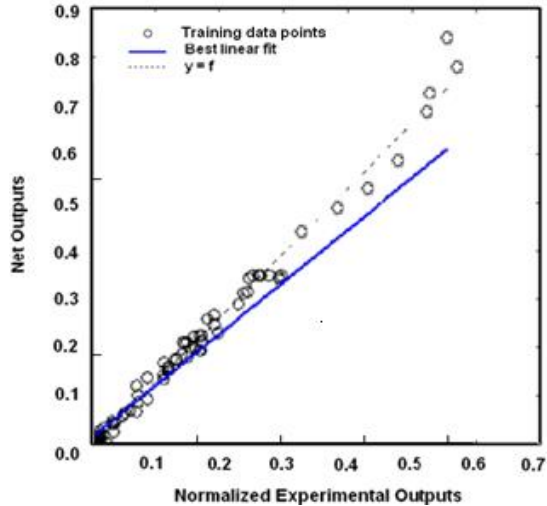
شکل ۱۰- خروجی‌های مربوط به آزمایش شبکه در برابر خروجی‌های آزمایشگاهی برای دوده با ضریب تصحیح $R=0.960$



شکل ۹- خروجی‌های مربوط به آموزش شبکه در برابر خروجی‌های آزمایشگاهی برای دوده با ضریب تصحیح $R=0.972$



شکل ۱۲- خروجی‌های مربوط به آزمایش شبکه در برابر خروجی‌های آزمایشگاهی برای مصرف سوخت با ضریب تصحیح $R=0.949$




شکل ۱۱- خروجی‌های مربوط به شبکه آموزش یافته در برابر خروجی‌های آزمایشگاهی برای مصرف سوخت با ضریب تصحیح $R=0.958$

خواهد بود و چنانچه در محدوده‌ای تعداد داده‌ها جهت مدل‌سازی (با توجه به فاصله نقاط به دست آمده از خط $(y=x)$) کم باشد، می‌توان از روش‌های دیگر همچون استفاده از نرم افزار و مدل‌ها بر پایه CFD داده‌های بیشتری در این نقاط برای افزایش دقت مدل‌سازی تولید کرد؛ بنابراین نمودارهای بالا علاوه بر بیان دقت مدل‌سازی به شکلی


هدف از بیان نتایج خروجی‌های شبکه و خروجی‌های آزمایشگاهی که در اشکال ۷ تا ۱۲ ارائه گردیده است، علاوه بر درک بهتر میزان دقت شبکه در مقایسه با خروجی‌های واقعی (تجربی) نشانگر این واقعیت نیز می‌تواند باشد که هر جا تراکم داده‌های تجربی برای آموزش شبکه بیشتر باشد، در محدوده آن نقاط، شبکه از دقت و عملکرد بهتری برخوردار

روند بهینه‌سازی وزن‌ها و بایاس‌ها متوقف شود. کمترین خطا برای خروجی‌های مختلف در دوره‌های متفاوتی اتفاق می‌افتد که در شکل‌های ۱۳ الی ۱۵ نشان داده شده است. به‌منظور صحت عملکرد و دقت مدل پیشنهادی، می‌توان نمودار داده‌های آزمایشگاهی و شبیه‌سازی را برای آلاینده‌های NO_x و دوده، مطابق اشکال ۱۶ و ۱۷ مقایسه


ساده‌تر، نشان‌دهنده میزان دقت شبکه در محدوده‌های محلی خاص نیز است. میزان کاهش مجموع مربعات خطا (MSE) پس از تکرارهای مختلف با توجه به بروزرسانی وزن‌ها و بایاس‌ها بایستی روند همگرایی خود را ادامه دهد تا در نهایت خطا به مقدار دلخواه (کمتر از ۰/۱) رسیده و دستور بروزرسانی و نیز



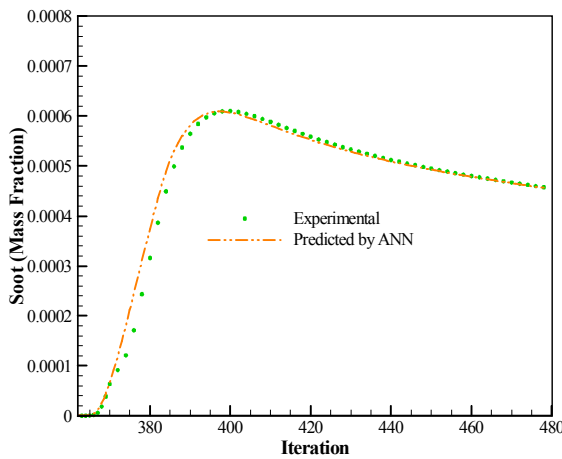
شکل ۱۳- همگرایی مقدار مجموع مربعات خطا به ازای تکرارهای مختلف برای آلاینده NO_x در شبکه




شکل ۱۴- همگرایی مقدار مجموع مربعات خطا به ازای تکرارهای مختلف برای آلاینده دوده در شبکه



شکل ۱۵- همگرایی مقدار مجموع مربعات خطا به ازای تکرارهای مختلف برای مصرف سوخت در شبکه



شکل ۱۷- خروجی‌های به‌دست آمده از شبکه عصبی در برابر داده‌های آزمایشگاهی برای آلاینده دوده



شکل ۱۶- خروجی‌های به‌دست آمده از شبکه عصبی در برابر داده‌های آزمایشگاهی برای آلاینده NO_x

۷- نتیجه‌گیری

همانگونه که اشاره شد، از مهمترین عواملی که در ارتقاء توان، بهبود عملکرد و کیفیت و کمیت آلاینده‌های خروجی از موتورهای دیزلی تأثیرگذار است، پارامترهای مرتبط با سامانه سوخت‌رسانی و هوارسانی است. جرم سوخت پاشیده شده به محفظه احتراق، دمای سوخت و دمای هوای ورودی به موتور

نمود. همانطور که مشاهده می‌گردد، نتایج بدست آمده از شبکه عصبی تطابق بسیار خوبی را در مقایسه با داده‌های تجربی نشان می‌دهد. کاهش ناچیز دقت مدل پیشنهادی در شبیه‌سازی آلاینده دوده نسبت به NO_x را می‌توان به پراکندگی ناموزون داده‌های تجربی برای این پارامتر در طیف وسیعی از دامنه مدل‌سازی مرتبط دانست که آموزش شبکه عصبی بر اساس این داده‌ها صورت گرفته است.

زمان پاسخ‌گویی کوتاه می‌تواند برای کاهش زمان محاسبه ECU و هزینه کالیبراسیون استفاده شود.

۸- مراجع

[۱] محسنیان راد اف، خشنودی م (۱۳۸۰) شبیه‌سازی گسترش شعله در موتورهای جرقه‌افروزی با استفاده از شبکه عصبی. پایان‌نامه کارشناسی ارشد: دانشگاه سیستان و بلوچستان، ایران.

[2] Parlak A, Islamoglu Y, Yasar H, Egrisogut A (2006) Application of artificial neural network to predict specific fuel consumption and exhaust temperature for a diesel engine. *App Therm Eng* 26: 824-828.

[3] Ramadhas AS, Jayaraj S, Muraleedharan C, Padmakumari K (2006) Artificial neural networks used for the prediction of the cetane number of biodiesel. *Ren Energy* 31(15): 2524-2533.

[4] Atashkari K, Nariman-Zadeh N, Golcu M, Khalkhali A, Jamali A (2007) Modelling and multi-objective optimization of a variable valve-timing spark-ignition engine using polynomial neural networks and evolutionary algorithms. *En Conv Manag* 48: 1029-1041.

[5] Ghobadian B, Rahimi H, Nikbakht AM, Najafi G, Yusaf TF (2009) Diesel engine performance and exhaust emission analysis using waste cooking biodiesel fuel with an artificial neural network. *Ren Energy* 34: 976-982.

[6] Abassi A, Khalilarya S, Jafarmadar S (2010) The influence of injection system characteristics on the first- and second-law terms in high-speed DI diesel engines with swirl combustion chamber. *Int J Exergy* 7(4).

[7] Togun NK, Baysec S (2010) Prediction of torque and specific fuel consumption of a gasoline engine by using artificial neural networks. *App Energy* 87: 349-355.

[۸] نجفی ب (۱۳۹۰) پیش‌بینی تأثیر استفاده از سوخت بیودیزل حاصل از روغن پسماند بر عملکرد و آلایندگی موتور دیزل به کمک شبکه عصبی مصنوعی. مجله علمی پژوهشی مهندسی مکانیک مدرس ۲۰-۱۱: ۱۱(۴).

[9] Cay Y, Cicek A, Kara F, Sagioglu S (2012) Prediction of engine performance for an alternative fuel using artificial neural network. *App Ther Eng* 37: 217-225.

[10] Arumugam S, Sriram G, Shankara Subramanian PR (2012) Application of artificial intelligence to predict the performance and exhaust emissions of

از مهمترین فاکتورهای موثر در عملکرد و آلایندگی موتورهای دیزلی است [۲۰-۲۲]. لذا در پژوهش حاضر از روش شبکه عصبی مصنوعی با الگوریتم آموزشی لوبز-مارکوارت برای مدل‌سازی و ایجاد ارتباط بین متغیرهای ورودی دور موتور، جرم سوخت پاشیده شده و دمای هوای ورودی و همچنین پارامترهای خروجی NO_x ، دوده و مصرف سوخت جهت بکارگیری در سیستم کنترلی موتورهای دیزل پاشش مستقیم، استفاده گردید. نتایج نشان می‌دهد که مدل پیشنهادی شبکه عصبی همانطور که نشان داده شد، از توانایی بالایی برای مدل‌سازی و پیش‌بینی مسائل پیچیده غیرخطی برخوردار است. استفاده از این نوع شبکه به دلیل همگرایی سریع که مربوط به ویژگی خود شتابدهندگی آن است، در موتورهای دیزل پاشش مستقیم می‌تواند بسیار حائز اهمیت باشد؛ همچنین نتایج حاصله بیانگر آنست که شبکه عصبی طراحی شده، به ازای ۳۶ نرون در لایه پنهان در دور ۳۷۳۳ به خطایی کمتر از ۳ درصد برای آزمایش داده‌ها در مدل‌سازی آلایندگی NO_x می‌رسد. از طرفی فرایند مدل‌سازی دوده با تعداد نرون‌های بیشتر در دور پایین‌تری انجام می‌شود. نکته‌ای که حائز اهمیت است، این است که افزایش تعداد نرون‌ها تأثیر قابل توجهی بر روی کاهش خطا در شبکه نخواهد داشت، هر چند این امر باعث بزرگتر شدن شبکه و پیچیدگی بیشتر آن خواهد شد؛ همچنین شبکه پیشنهادی به ازای ۱۹ نرون در لایه پنهان در دور ۳۶۹۸ به خطای ۶ درصدی برای آزمایش داده‌ها در مدل‌سازی مصرف سوخت می‌رسد. دلایل متعددی می‌توان برای کاهش نسبی دقت مدل‌سازی آن ذکر کرد که از آن جمله می‌توان به پراکندگی ناموزون داده‌های تجربی برای این پارامتر در طیف وسیعی از دامنه مدل‌سازی اشاره کرد. علاوه بر این، مدل پیشنهادی شبکه عصبی مصنوعی تنها به مقدار محدودی از داده‌ها برای آموزش در مقایسه با روش‌های متداول مورد استفاده در جدول محاسبات واحد کنترل الکترونیکی^۱ و یا سیستم‌های کنترلی هوشمند موتورهای احتراق داخلی نیاز دارد که در آن مقدار زیادی از داده‌های تجربی برای پیش‌بینی و یا کالیبره کردن عملکرد موتور و کنترل آلایندگی موردنیاز است. مدل پیشنهادی شبکه عصبی مصنوعی، به علت همگرایی سریع و

^۱ ECU

- diesel engine emissions using a combined ANN-ACO method. *Applied Soft Comput* 34: 139-150.
- [18] Zarenezhad Ashkezari A, Hossein Nezhad A, Farahat S (2016) Reduction of pollutant emissions by developing a variable valve timing system in a direct injection diesel engine using computational fluid dynamics modeling. *Environ Prog Sustain* 35: 1430-1440.
- [19] Thompson GJ, Atkinson CM, Clark NN, Long TW, Hanzevack E (2000) Neural network modelling of the emissions and performance of a heavy-duty diesel engine. *Proc Instn Mech Eng Part D Eng* 214: 111-126.
- [۲۰] چامه سرا س، میرسلیم س م (۱۳۹۵) بررسی تاثیر فشار هوای ورودی و عوامل پاشش سوخت بر روی ارتقاء توان و کاهش آلایندگی موتور دیزل سنگین. *مجله علمی پژوهشی مکانیک سازه‌ها و شاره‌ها* ۲۳۹-۲۴۷: ۶(۴).
- [۲۱] مبشری ر، اکبری ر (۱۳۹۶) بررسی تاثیرات همزمان فشار پاشش سوخت و بازخورانی گازهای خروجی بر عملکرد و میزان آلاینده‌های تولیدی یک موتور اشتعال تراکمی پاشش مستقیم سرعت بالا. *مجله علمی پژوهشی مکانیک سازه‌ها و شاره‌ها* ۲۱۳-۲۲۶: ۷(۳).
- [22] Zarenezhad Ashkezari A, Divsalar K, Malmir R, Abbaspour I (2020) Emission and performance analysis of DI diesel engines fueled by biodiesel blends via CFD simulation of spray combustion and different spray breakup models: a numerical study. *J Therm Anal Calorim* 139(4): 2527-2539.
- diesel engine using rapeseed oil methyl ester. *Pro Eng* 38: 853-860.
- [۱۱] شیرنشان ع، حسین‌زاده سامانی ب، ندای علی ا (۱۳۹۵) پیش‌بینی مشخصه‌های عملکردی یک مولد قدرت دیزل بوسیله شبکه عصبی با کاربرد سوخت بیودیزل. *فصلنامه علمی پژوهشی تحقیقات موتور* ۴۳-۵۰: ۴۲.
- [۱۲] حسینی س ح، تقی‌زاده علی سرایی ا، قبادیان ب، عباس‌زاده مایوان ا (۱۳۹۶) مدل‌سازی اثر نانولوله‌های کربن اضافه‌شده به مخلوط سوخت دیزل - بیودیزل بر عملکرد و آلایندگی یک موتور دیزل با استفاده از شبکه عصبی. *نشریه علمی پژوهشی سوخت و احتراق* ۱-۱۶: ۱۰(۲).
- [13] Kesgin U (2004) Genetic algorithm and artificial neural network for engine optimization of efficiency and NO_x emission. *Fuel* 83: 885-895.
- [14] Prucka RG, Wu B, Filipi ZS, Kramer DM, Ohl GL (2005) Cam-Phasing optimization using artificial neural network surrogate models-maximizing torque output. *SAE Paper* 2005-01-3757.
- [15] Park S (2012) Optimization of combustion chamber geometry and engine operating conditions for compression ignition engines fueled with dimethyl ether. *Fuel* 97: 61-71.
- [16] Bhaskor JBora, Ujjwal KSaha (2016) Optimisation of injection timing and compression ratio of a raw biogas powered dual fuel diesel engine. *App Therm Eng* 92: 111-121.
- [17] Mohammadhassani J, Dadvand A, Khalilarya S, Solimanpur M (2016) Prediction and reduction of