



Improvement in Control-oriented Modeling of SI Engines Using Grey-box Structure

ARTICLE INFO

Article Type

Original Research

Authors

Shamekhi A.M.¹ MSc,
Shamekhi A.H.*¹ PhD

How to cite this article

Shamekhi A.M, Shamekhi A.H. Improvement in Control-oriented Modeling of SI Engines Using Grey-box Structure. Modares Mechanical Engineering, 2019;19(5):1283-1295.

ABSTRACT

In this paper, an improved, real-time, highly accurate control-oriented style, named Neuro Mean Value Modeling, is presented for IC engine modeling. This model is a combination of neural networks and mean value model, and is able to overcome the shortcomings of both styles. In other words, taking advantage of both methods, this grey-box extension will be of more reliability than a mere black-box neural network, and also of more accuracy than roughly white-box mathematical relations of mean value model. In this paper, the model is modified to become suitable for designing an engine controller. Thanks to the sophisticated methods applied (such as committee method, improved partitioning, and especially, simplifying neural networks' tasks), neural networks of high accuracy with line-like regressions will be achieved. As will be seen, the model is precisely validated based on experimental-software data and it is capable of accurately predicting the engine's outputs (such as pollutant emissions, manifold pressure, knock probability, and engine speed) all in real time. In the end, the effect of engine control inputs on pollutant emissions and fuel consumption will be examined. The engine employed to establish the model is a ported fuel injection SI engine.

Keywords Spark-ignition Engines; Control-oriented Modeling; Mean Value Models; Grey-box structure; Artificial Neural Networks

¹Automotive Engineering Department, Faculty of Mechanical Engineering, KN Toosi University of Technology, Tehran, Iran

*Correspondence

Address: Faculty of Mechanical Engineering, KN Toosi University of Technology, Molla Sadra Avenue, Vanak Square, Tehran, Iran
Phone: +98 (21) 84063246
Fax: +98 (21) 88677274
shamekhi@kntu.ac.ir

Article History

Received: October 25, 2018
Accepted: December 23, 2018
ePublished: May 01, 2019

CITATION LINKS

[1] Modeling and simulation of combustion in SI engines via neural networks and ... [2] A new approach in improvement of mean value models for spark ... [3] Introduction to modeling and control of internal ... [4] Modeling and validation of automotive engines for control ... [5] An improved model for SI engines. ASME 2004 Internal ... [6] Enhancement of control oriented engine models using ... [7] Neural adaptive ignition ... [8] On-line stateprediction of engines based on fast ... [9] Modeling of a turbocharged di diesel engine using ... [10] Neural cylinder model and its transient ... [11] Application of artificial neural network ... [12] Improvement of neural network accuracy for engine ... [13] A combustion model for ICE by means of neural ... [14] A method for pre-calibration of DI diesel engine ... [15] Artificial neural network based prediction of performance ... [16] Artificial neural networks modelling of engine-out responses ... [17] Prediction of engine performance for an alternative fuel using ... [18] Nonlinear identification of a gasoline HCCI engine using neural ... [19] Performance and exhaust emissions prediction of a CRDI ... [20] Investigating the relative contribution of operational ... [21] Research of performance on a spark ignition engine fueled ... [22] Comparison of linear regression and artificial neural network ... [23] An artificial neural network model for a diesel engine fuelled ... [24] Prediction of cyclic variability in a diesel engine fueled with ... [25] MATLAB R2018b ... [26] Neural network ... [27] An introduction to neural ... [28] Neural networks: A comprehensive ... [29] Nonlinear system identification: From classical approaches to ... [30] Internal combustion engine ...

بهبود مدل‌سازی کنترل‌محور موتورهای اشتعال جرقه‌ای با استفاده از ساختار جعبه خاکستری

امیرمحمد شامخی MSc

گروه مهندسی خودرو، دانشکده مهندسی مکانیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

امیرحسین شامخی PhD

گروه مهندسی خودرو، دانشکده مهندسی مکانیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

چکیده

در این مقاله روشی بهبودیافته بلادرنگ و با دقت بالا در مدل‌سازی کنترل‌محور موتورهای احتراق داخلی، به نام نورو ام‌وی‌ام ارائه می‌شود. این مدل، ترکیبی از مدل‌های مقدار میانگین و شبکه‌های عصبی بوده و قادر است بر نواقص هر دو روش فایز آید. به بیان دیگر، با بهره‌گیری از مزایای هر دو روش این توسعه جعبه خاکستری دارای قابلیت اعتمادی بالاتر از یک شبکه عصبی جعبه سیاه صرف و همچنین دقتی بالاتر از روابط ریاضی (تقریباً) جعبه سفید مدل‌های مقدار میانگین خواهد بود. با بهبود این روش در مقاله حاضر مدل حاصله برای طراحی کنترلر مناسب خواهد بود. به‌واسطه استفاده از روش‌های پیشرفته‌تر طراحی (مانند ساختارهای گروهی، تقسیم‌بندی بهبودیافته و به‌خصوص ساده‌سازی وظیفه شبکه‌ها) شبکه‌های عصبی با دقت بالا و رگرسیون‌های شبه‌خطی حاصل می‌شود. چنانچه ملاحظه خواهد شد، مدل نهایی به‌دقت براساس داده‌های آزمایشگاهی- نرم‌افزاری صحه‌گذاری شده و قادر است خروجی‌های حالت ماندگار و گذرای موتور (مانند آلایندگی‌های خروجی، فشار منیفولد، وقوع ضربه و دور موتور) را با دقت بالا و به صورت بلادرنگ پیش‌بینی کند. در پایان تأثیر ورودی‌های کنترلی موتور بر آلایندگی‌ها و مصرف سوخت مورد مطالعه قرار می‌گیرد. موتور مورد بررسی در این پژوهش، یک موتور بنزینی با پاشش راهگاهی است.

کلیدواژه‌ها: موتورهای اشتعال جرقه‌ای، مدل‌سازی کنترل‌محور، مدل‌های مقدار میانگین، ساختار جعبه خاکستری، شبکه‌های عصبی مصنوعی

تاریخ دریافت: ۱۳۹۷/۰۸/۰۳

تاریخ پذیرش: ۱۳۹۷/۱۰/۰۲

*نویسنده مسئول: shamekhi@kntu.ac.ir

۱- مقدمه

امروزه کاهش مصرف سوخت و همچنین آلایندگی‌های موتورهای احتراقی، از جمله اهداف اصلی صنعت خودرو به شمار می‌روند. این اهداف، بدون توسعه سامانه‌های کنترلی مناسب امکان‌پذیر نیست. به‌طور کلی مدل‌سازی، گامی حیاتی در طراحی کنترلی به‌خصوص در مرحله طراحی نرم‌افزار- در- حلقه (Software in the Loop) به شمار می‌رود. در مورد یک موتور احتراقی، لازم است مدل مزبور تأثیر ورودی‌ها بر خروجی‌های کنترلی را به‌صورت بلادرنگ و با دقت بالا نشان دهد. هر گونه نقصان در دو ویژگی مزبور می‌تواند موجب اشکال در طراحی کنترلر شود.

به این ترتیب، طراحی مدل‌های بلادرنگ و با دقت بالاتر موتور می‌تواند زمینه‌ساز مصرف بهینه سوخت و کاهش آلایندگی شود. به‌دنبال پژوهش‌های پیشین^[1, 2] تلاش می‌شود تا در این مقاله، مدلی با دقت بالا، بلادرنگ (Real-time) و مناسب برای طراحی SIL سامانه کنترلی موتور اشتعال جرقه‌ای (SI) ارائه شود. چنانچه ملاحظه خواهد شد، مدل مزبور، علاوه بر بلادرنگ‌بودن، دارای ورودی‌ها و خروجی‌های مورد نیاز یک مدل کنترلی و همچنین، دقتی مشابه مدل‌های بر پایه دینامیک سیالات محاسباتی (CFD) خواهد بود که دستاوردی قابل ملاحظه در مدل‌سازی کنترل‌محور به شمار می‌رود.

موتور اشتعال جرقه‌ای، سیستمی غیرخطی و بسیار پیچیده است.

مدل‌سازی ترموسیالاتی بر پایه حل معادلات فیزیکی حاکم بر موتور، علی‌رغم دقت بالا، زمان حل بسیار بالایی دارد و بنابراین برای یک هدف کنترلی مناسب نیست. در واقع، طراحی SIL یک سیستم کنترلی، نیازمند یک مدل کنترل‌محور است که بلادرنگ باشد. مدل کنترل‌محور، به‌طور خلاصه باید دقیق و بلادرنگ و همچنین دارای ورودی‌ها و خروجی‌های کنترلی باشد. چنانچه در بخش‌های آتی ذکر خواهد شد، لازم است مدل کنترلی دارای ورودی‌هایی متناظر با عملگرها و همچنین خروجی‌هایی (حداقل) متناظر با حسگرهای موجود در یک موتور واقعی باشد.

روش مقدار میانگین (MVM)، متداول‌ترین روش مدل‌سازی کنترل‌محور بوده و پایه بسیاری از دیگر روش‌های مدل‌سازی است^[3]. این روش تلاش می‌کند تا با ساده‌سازی پدیده‌ها و معادلات فیزیکی بسیار پیچیده حاکم بر موتور، زمان محاسبات را کاهش دهد و مدلی بلادرنگ ارائه کند. در این روش، با صرف نظر از رفتار رفت و برگشتی موتور، آن را به‌صورت توریبی مدل می‌کند که به‌صورت پیوسته گشتاور تولید می‌کند^[3]. در اینجا سیستم به زیرسیستم‌های خود تا جایی می‌شکند که زیرسیستم‌هایی با ساده‌ترین وظایف مجزا به دست آیند. بسته به پاسخ زمانی، این زیرسیستم‌ها به‌صورت استاتیک، دینامیک یا ثابت در نظر گرفته می‌شوند. زیرسیستم‌های اصلی موتور در روش مقدار میانگین در جدول ۱ نمایش داده شده است.

جدول ۱ زیرسیستم‌های موتور اشتعال جرقه‌ای به‌همراه نوعشان برحسب پاسخ زمانی

نوع	زیرسیستم‌ها
استاتیک	دریچه‌گاز
دینامیک	منیفولد ورودی
استاتیک	تبادل گاز
دینامیک	رسوب سوخت
استاتیک	احتراق
دینامیک	اینرسی موتور

شکل ۱، طرحواره‌ای از زیرسیستم‌های یک موتور اشتعال جرقه‌ای و ارتباط آنها در یک مدل مقدار میانگین را نمایش می‌دهد. همان‌طور که ملاحظه می‌شود، ورودی‌های اصلی موتور عبارت از زاویه دریچه گاز، نسبت هوا به سوخت، آوانس جرقه و بار خارجی (اغتشاش) هستند.

از طرف دیگر، مدل‌های مقدار میانگین، از همان ابتدا^[4] تا به امروز^[3] از چندین مشکل اساسی رنج برده‌اند. چنانچه ذکر شد، این روش به‌منظور بهبود سرعت پاسخ مدل ارائه شد. اما این افزایش سرعت به بهای ازدست‌رفتن دقت مدل به دست آمد. این مشکل، به‌خصوص در پیش‌بینی آلایندگی‌ها به اوج می‌رسد. شامخی و غفاری در سال ۲۰۰۴، برای رفع این مشکل تلاش کردند تا مدل‌های مقدار میانگین و ترموسیالاتی را ترکیب کنند^[5]. هر چند این اقدام، دقت مدل را بسیار بالا برد، اما سرعت پاسخ را کاهش داد.

باید دقت داشت که ریشه این مشکل، نامعینی‌های حاصل از ساده‌سازی در مدل‌سازی مقدار میانگین است. به این ترتیب، ایده استفاده از مدل‌های جعبه‌سیاه مطرح شد. از آنجایی که این مدل‌ها تنها براساس ورودی/خروجی‌های تجربی به دست می‌آیند، درگیر پیچیدگی‌های حاصل از حل معادلات غیرخطی حاکم بر سیستم نمی‌شوند. روش‌های کلاسیک جعبه‌سیاه، نیازمند تعداد زیادی داده‌های متساوی‌فاصله برای مدل‌سازی سیستم بودند. این مشکل، پس از ورودی شبکه‌های عصبی در مدل‌سازی موتور برطرف شد^[6].

خروجی، از محفظه احتراق یک موتور دیزل استفاده کردند [16]. آنها می‌توانستند با استفاده از ۷ شبکه، هر کدام تنها با یک خروجی، به نتایج بهتری دست یابند. این مشکل در پژوهش کای و همکاران در سال ۲۰۱۲ برطرف شده است. آنها از یک شبکه عصبی استاتیک به‌منظور مدل‌سازی محفظه احتراق یک موتور با سوخت متانول بهره بردند [17]. جاناکیرامان و همکاران در سال ۲۰۱۳ از شبکه‌های سری- موازی پیشخور و NARX به‌منظور مدل‌سازی رفتار حالت گذرای یک موتور احتراق تراکمی مخلوط همگن (HCCI) بهره بردند. شبکه اول برای تخمین یک گام جلوتر و شبکه دوم برای پیش‌بینی چند گام جلوتر مورد استفاده قرار گرفت. آنها دو ساختار پرسپترون چندلایه (MLP) و پایه- شعاعی (RBF) را با یکدیگر مقایسه کرده و نشان دادند که مدل پرسپترون چندلایه عملکرد بهتری داشته است و به حافظه کمتری نیاز دارد [18].


روی و همکاران در سال ۲۰۱۴، از یک شبکه عصبی استاتیک به‌منظور پیش‌بینی توان و آلایندگی‌های یک موتور تک‌سیلندر با نسبت‌های متفاوت گازهای بازخورانی‌شده خروجی (EGR) بهره بردند [19]. نیکزادفر و شامخی در سال ۲۰۱۴، از شبکه‌های عصبی به‌منظور بهبود مدل‌های مقدار میانگین برای موتور دیزل استفاده کردند. آنها از دو شبکه عصبی برای مدل‌سازی زیرسیستم احتراق بهره بردند [20]. کاپوسوز و همکاران در سال ۲۰۱۵، از شبکه‌های عصبی به‌منظور مدل‌سازی تأثیرات نوع سوخت الکلی بر کارایی یک موتور احتراق جرقه‌ای استفاده کردند [21]. توسون و همکاران در سال ۲۰۱۶، از شبکه عصبی و رگرسیون خطی برای پیش‌بینی عملکرد موتور استفاده کردند و نشان دادند که شبکه عصبی دقت بالاتری در پیش‌بینی دارد [22]. آکاریا و همکاران در سال ۲۰۱۷، از یک مدل شبکه عصبی برای تخمین پارامترهای یک موتور دیزل با سوخت ترکیبی دیزل و بایو- دیزل در نسبت‌های مختلف بهره بردند [23]. گورجن و همکاران در سال ۲۰۱۸، از یک مدل شبکه عصبی برای پیش‌بینی تغییرات سیکلیک یک موتور دیزل با سوخت دیزل- بوتانول استفاده کردند [24].

چنانچه ملاحظه شد، تقریباً هیچ کدام از مطالعات مورد بررسی، مدلی کامل از موتور همراه با رفتار دینامیک آن ارائه نکردند و بر بعضی ویژگی‌های حالت ماندگار زیرسیستم احتراق تمرکز کردند. بی‌گمان، طراحی یک سیستم کنترلی برای موتور، نیازمند مدلی کامل شامل رفتار دینامیک و همچنین ورودی‌ها و خروجی‌های واقعی آن است. به‌علاوه، در محدود موارد مدل‌سازی دینامیک موتور، تنها از یک شبکه عصبی دینامیک برای مدل‌سازی کل موتور استفاده شد. چنانچه در ادامه بیان خواهد شد، با این روش دقت و قابلیت اعتماد مدل کاهش می‌یابد.

نگارندگان در مطالعه پیشین خود [2] با ترکیب شبکه‌های عصبی و مدل مقدار میانگین توانستند رفتار دینامیک موتور را همراه با دقتی بالا پیش‌بینی کنند. با این حال، مدل مذکور فاقد برخی زیرسیستم‌های مورد نیاز و همچنین ورودی/خروجی‌های یک مدل کنترل‌محور واقعی بود. در ادامه، پس از بیان روش طراحی، مدل‌سازی زیرسیستم‌های موتور بررسی خواهد شد. در پایان نیز نتایج حاصل از شبیه‌سازی صحت‌گذاری می‌شود.

۲- روش مدل‌سازی

چنانچه در قسمت قبل ذکر شد، شبکه‌های عصبی به‌دلیل دقت پایین مدل‌های مقدار میانگین مورد استفاده قرار گرفتند. اما باید توجه داشت که مدل‌های جعبه‌سیاه شبکه عصبی از دو مشکل ذاتی رنج می‌برند. اول اینکه با افزایش پیچیدگی سیستم (و در



شکل ۱) زیرسیستم‌های موتور احتراق جرقه‌ای در مدل‌سازی مقدار میانگین به‌همراه ورودی‌ها و خروجی‌ها [3]

اکثر مقالات بررسی‌شده در مورد مدل‌سازی موتور با استفاده از شبکه‌های عصبی، تنها بر مدل‌سازی برخی از ویژگی‌های زیرسیستم احتراق (مانند آزادسازی انرژی) تمرکز می‌کنند. حال آنکه برای طراحی یک سیستم کنترلی به مدلی کامل از موتور نیاز است. مولر و همبرگر در سال ۱۹۹۸، از یک شبکه عصبی استاتیک به‌منظور پیش‌بینی نقطه ۵۰٪ آزادسازی انرژی استفاده کردند [7]. ژنگ و همکاران در سال ۲۰۰۱، در یکی از معدود موارد مدل‌سازی کل موتور، تنها از یک شبکه عصبی دینامیک بازگشتی به‌منظور مدل‌سازی کل موتور بهره بردند [8]. هی و راتلند در سال‌های ۲۰۰۲، ۲۰۰۳ و ۲۰۰۴، برخی از ویژگی‌های حالت ماندگار احتراق را با استفاده از شبکه‌های عصبی مدل کردند. آنها به‌خصوص استفاده از شبکه‌های با تنها یک خروجی و میانگین‌گیری جمعی را پیشنهاد کردند [9, 10]. با این حال، روش آنها در تعمیم نتایج حالت ماندگار احتراق به رفتار دینامیک کل موتور، صحیح نبود [9-11]. برهما و همکاران در سال ۲۰۰۳، برای مدل‌سازی فشار سیلندر نشان دادند که با ترکیب مدل‌های فیزیکی و شبکه‌های عصبی می‌توان دقت و مقاومت مدل را افزایش داد [12].

بروسکا و همکاران در سال ۲۰۰۵، از یک شبکه عصبی به‌منظور پیش‌بینی نسبت گرمای ویژه متغیر یک مدل تک‌ناحیه‌ای احتراق بهره بردند [13]. صمدانی و همکاران در سال ۲۰۰۹، از یک شبکه عصبی استاتیک برای مدل‌سازی احتراق، به‌منظور بهینه‌سازی چندهدفه ورودی‌های کنترلی یک موتور دیزل استفاده کردند [14]. کومار و همکاران در سال ۲۰۱۱ تلاش کردند تا ویژگی‌های حالت ماندگار یک موتور دیزل با نسبت تراکم متغیر را با استفاده از دو شبکه عصبی استاتیک پیش‌بینی کنند [15]. برای دستیابی به نتایج بهتر، باید از روش‌های پیشرفته‌تر با تعداد بیشتر داده‌ها بهره می‌بردند. اسماعیلی و همکاران در سال ۲۰۱۲ از جدولی شامل ۳۲۰ داده برای آموزش یک مدل شبکه عصبی استاتیک، با ۴ ورودی و ۷

محلی- سراسری، مانند: مدل‌های درختی محلی (Local Model Trees) برای مثال HOLIMOT، LOLIMOT و غیره یا آنفیس (ANFIS).

۲- استفاده از میانگین‌گیری جمعی (از روش‌های گروهی) به منظور غلبه بر تضاد بایاس/واریانس [28].

از طرف دیگر، تلاش می‌شود تا مدل حاصل علاوه بر بلادرنگ بودن و دقت بالا، دارای ورودی/خروجی‌های مناسب برای طراحی یک کنترلر باشد. چنانچه در شکل ۲ [3] ملاحظه می‌شود، خروجی حسگرهای موتور، ورودی‌های سامانه کنترلی است (مانند مقادیر حسگرهای ضربه، نسبت هوا به سوخت خروجی، دور موتور و فشار منیفولد). بنابراین لازم است که خروجی‌های مدل کنترلی شامل متغیرهایی نیز باشد که توسط حسگرها اندازه‌گیری می‌شود. به این ترتیب، خروجی‌های مدل عبارت از موارد زیر خواهند بود:


۱- دور موتور

۲- نسبت هوا به سوخت خروجی

۳- وجود ضربه

۴- فشار منیفولد ورودی

همچنین برخی دیگر از خروجی‌ها مانند آلاینده‌ها و میزان مصرف سوخت ویژه می‌توانند در مطالعه و بهینه‌سازی طراحی نقش‌های موثر ایفا کنند. در نقطه مقابل، ورودی‌های مدل شامل ورودی عملگرها و همچنین، اغتشاش (یا بار خارجی باشد) از قبیل میزان پاشش سوخت، میزان آوانس جرعه، ورودی دریچه گاز و بار خارجی (اغتشاش) است. در پایان باید توجه داشت که مدل‌سازی در این مقاله، ناظر به حالت کاملاً گرم موتور و سرعت‌های بیش از ۱۵۰۰ دور بر دقیقه است. در اینجا، زیرسیستم‌های هیدروکربن نسوخته، رسوب سوخت و تغییرات دمای موتور (که دو مورد آخر برای حالت کاملاً گرم موتور، محلی از اعراب ندارند)، به دلیل عدم دسترسی به داده‌های تجربی مورد نیاز، مدل نمی‌شوند. در ادامه، پس از مروری کوتاه بر اکتساب داده‌ها، مدل‌سازی زیرسیستم‌های موتور مورد بررسی قرار می‌گیرند.



شکل ۲) ارتباط بین موتور و واحد کنترل الکترونیکی [3]

۳- اکتساب داده‌ها

اساس مدل‌سازی بر پایه داده‌هایی تجربی است که از تست یک موتور واقعی به دست می‌آیند. به دلایل زیر لازم است ابتدا یک مدل نرم‌افزاری (مثلاً در نرم‌افزار جی.تی-پاور) از موتور مورد نظر، طراحی و براساس داده‌های تجربی، با دقت (بالاتر از ۹۰٪) صحه‌گذاری شود. داده‌های اکتسابی از این مدل به همراه داده‌های تجربی، مبنای مدل‌سازی کنترل‌محور خواهند بود و به این ترتیب،

عین حال، ثابت‌ماندن تعداد داده‌های آموزش)، قابلیت تخمین شبکه و در نتیجه، دقت مدل افت خواهد کرد. از سوی دیگر، قابلیت اعتماد یک مدل جعبه‌سیاه اصولاً نمی‌تواند به اندازه یک مدل جعبه‌سفید باشد. این مشکل، در خارج از ناحیه آموزش‌دیده تشدید می‌شود. به علاوه، در مورد شبکه‌های عصبی دینامیک، علاوه بر مشکلات بالا و همچنین افزایش زمان آموزش مورد نیاز، احتمال گرفتارشدن در مینیمم‌های محلی به شدت افزایش می‌یابد [2, 25, 26]. از طرف دیگر، تعداد نیوران‌های میانی مورد نیاز برای فراگیری یک سیستم، با پیچیده‌ترشدن سیستم افزایش می‌یابد. این افزایش منجر به پیچیده‌ترشدن سطح عملکرد شبکه و در نتیجه، افزایش احتمال گرفتارشدن در مینیمم‌های محلی می‌شود. همچنین، چنانکه ذکر شد، با ثابت‌ماندن تعداد داده‌های آموزش، افزایش نودهای میانی (برای جبران خطای بایاس)، منجر به افزایش خطای واریانس شبکه می‌شود و در نتیجه دقت شبکه کاهش می‌یابد. به این ترتیب، در این پژوهش از مدل‌سازی کل موتور، به عنوان یک سیستم بسیار پیچیده، توسط یک شبکه عصبی دینامیک منفرد پرهیز خواهد شد.

ایده محوری در این مقاله، ترکیب مدل‌های جعبه‌سیاه شبکه عصبی و روابط ریاضی (تقریباً) جعبه‌سفید مدل‌های مقدار میانگین است، به گونه‌ای که ساختار جعبه‌خاکستری حاصله، همزمان دقت بالاتر مدل‌های جعبه‌سیاه و قابلیت اعتماد مدل‌های جعبه‌سفید را دارا باشد. ترکیب این مدل‌ها به صورتی انجام می‌گیرد که وظیفه محوله بر هر شبکه، ساده‌تر شود و در نتیجه، دقت شبکه (و در نهایت مدل کلی) افزایش یابد. این ایده، یعنی ساده‌سازی وظیفه محوله بر هر شبکه که در تطابق با اصل ایجاز (Parsimony Principle) است، یکی از ایده‌های محوری در این مقاله است.

به این ترتیب، مدل نهایی دارای زیرسیستم‌هایی مانند مدل‌های کنترل‌محور مختص موتور خواهد بود (شکل ۱) [3]. با این تفاوت که در هر زیرسیستم، ترکیبی از شبکه‌های عصبی و مدل‌های ریاضی وجود خواهد داشت. یکی از مزایای جانمایی مدل‌های شبکه عصبی در زیرسیستم‌های مدل‌های کنترل‌محور متداول، امکان دسترسی به متغیرهای میانی است. باید توجه داشت که با این روش، تمامی شبکه‌ها استاتیک خواهند بود. این روش مدل‌سازی را Neuro-MVM می‌نامیم. لازم است در طراحی شبکه‌های عصبی، نکات زیر مد نظر قرار گیرد:

۱- تکرار فرآیند آموزش با وزن‌های اولیه متفاوت، برای اطمینان از همگرایی به مینیمم مطلق [26].

۲- استفاده از جداول الگوی کاملاً غنی شامل نقاط عملکردی متفاوت موتور، شامل مجموعه‌های آموزش، صحه‌گذاری و تست [27].

۳- توقف زودرس به منظور جلوگیری از بیش‌آموزش [28].

۴- توجه به تضاد بایاس/واریانس (Bias/Variance Dilemma) و جلوگیری از بیش‌معینی (Over-determination) [28, 29].


۵- استفاده از الگوریتم‌هایی مانند تنظیم بیزین (Bayesian Regulation)، (به منظور جلوگیری از توقف‌های بی‌مورد حین آموزش) یا لیونبرگ-مارکوود.

۶- پرهیز از ورودی‌های کم‌اثر یا بی‌اثر [12].


۷- استفاده از شبکه‌های تنها با یک خروجی [11].

به علاوه، به منظور دستیابی به دقت‌های بالاتر (هنگام مدل‌سازی زیرسیستم‌های پیچیده‌تر) از روش‌های پیشرفته‌تر مدل‌سازی استفاده خواهد شد:

۱- استفاده از تقسیم‌بندی بهبودیافته یا استفاده از مدل‌های



نمودار (۱) عملکرد شبکه حین آموزش



نمودار (۲) رگرسیون شبکه جانمایی شده در زیرسیستم دریچه گاز

۵- زیرسیستم تبادل گاز

چنانچه قبلاً نیز ذکر شد، موتور را می توان مانند پمپی حجمی در نظر گرفت. در این پمپ، دبی سیال ورودی به سیلندر به صورت زیر تقریب زده می شود [3]:

$$\dot{m}(t) = \rho_{in}(t) \cdot \lambda_l(P_m, \omega_e) \cdot \frac{V_d \cdot \omega_e(t)}{4\pi} \quad (4)$$

در واقع، این زیرسیستم به صورت استاتیک مدل می شود. در رابطه بالا، ρ_{in} چگالی سیال ورودی به سیلندر، $\omega_e(t)$ دور موتور (برحسب رادیان بر ثانیه)، P_m فشار منیفولد و V_d حجم جابه جایی موتور است. میزان انحراف مدل فوق از یک پمپ حجمی ایده آل توسط بازده حجمی $\lambda_l(P_m, \omega_e)$ در نظر گرفته می شود. این ترم به دلیل کثرت پارامترهای تاثیرگذار در آن (مانند اثرات ژم، رزونانس و غیره)، اصولاً توسط اندازه گیری های تجربی تعیین می شود و در این پژوهش، با استفاده از شبکه عصبی مدل می شود.

موتور مورد بررسی در این پژوهش، از نوع پاشش راهگاهی است. برای این نوع موتور، ترکیبی از هوا و سوخت وارد سیلندر می شود. بنابراین، چگالی سیال ورودی به سیلندر باید محاسبه شود. روابط مربوطه، با فرض تبخیر کامل سوخت و اختلاط آدیاباتیک هوا و سوخت و همچنین با فرض مخلوط حاصل به عنوان یک گاز کامل، در یک منبع [3] بیان شده است.

آنها را داده های "آزمایشگاهی- نرم افزاری" می نامیم.

تعداد داده های تجربی بسیار کم است و فراگیری این سیستم پیچیده توسط شبکه های عصبی کافی نخواهند بود. این داده ها اصولاً از تست یک موتور متصل به واحد کنترلی موتور به دست می آیند و به این ترتیب، داده های خروجی تنها براساس ورودی های کنترلی مطلوب به دست آمده اند. باید توجه داشت که مدل کنترل محور نهایی (که براساس این داده ها ساخته خواهد شد)، باید قادر به نمایش دقیق نقاط عملکردی نامطلوب موتور نیز باشد. برای طراحی مدل کنترل محور به برخی پارامترهای میانی نیاز است که معمولاً در جدول های داده های تجربی وجود ندارند.

به این ترتیب، ۶۷ داده تجربی حاصل از تست موتور وانت مزدا (B2000 PICKUP 2.0L 4-cyl Engine Code FE) به بیش از ۴۰۰ داده افزایش می یابد. اطلاعات بیشتر در این زمینه در پژوهش پیشین نگارندگان [1] قابل ملاحظه است.

۴- مدل سازی دریچه گاز

جریان هوا با استفاده از دریچه گاز وارد موتور می شود. این زیرسیستم به صورت استاتیک مدل می شود. با فرض انبساط آیزنتروپیک، رابطه جریان ورودی به صورت زیر بیان می شود [3, 30]:

$$\dot{m}(t) = C_d \cdot A(t) \cdot \frac{P_{in}(t)}{\sqrt{R \cdot \vartheta_{in}(t)}} \cdot \Psi\left(\frac{P_{in}(t)}{P_{out}(t)}\right) \quad (1)$$

که در آن، $\Psi(\cdot)$ به صورت زیر تعریف می شود:

$$\Psi\left(\frac{P_{in}(t)}{P_{out}(t)}\right) = \begin{cases} \sqrt{k} \left[\frac{2}{k+1} \right]^{\frac{k+1}{k-1}}, & P_{out} < P_{cr} \\ \left[\frac{P_{out}}{P_{in}} \right]^{1/k} \cdot \sqrt{\frac{2k}{k-1} \cdot \left[1 - \left(\frac{P_{out}}{P_{in}} \right)^{\frac{k-1}{k}} \right]}, & P_{out} > P_{cr} \end{cases} \quad (2)$$

در روابط فوق P_{in} فشار محیط، P_{out} فشار چندراجه، ϑ_{in} دمای ورودی، C_d ضریب تخلیه و k نسبت گرمای ویژه هوا است. همچنین، فشار بحرانی P_{cr} برابر است با:

$$P_{cr} = \left[\frac{2}{k+1} \right]^{\frac{k}{k-1}} \cdot P_{in} \quad (3)$$

A سطح موثر ورودی دریچه گاز برحسب زاویه دریچه است [30] که در اینجا به دلیل طولانی بودن رابطه از توضیح آن پرهیز می شود و ضریب تخلیه (C_d) یک پارامتر تجربی است. اعمال روابط پیشنهاد شده در منابع نتوانستند با پاسخ های مورد انتظار به خوبی مطابقت کنند. در راستای پیاده سازی هدف پروژه، مبنی بر جانمایی مدل های جعبه سیاه در جعبه سفید، ضریب C_d باید با استفاده از یک شبکه عصبی، برای شرایط مختلف عملکردی موتور مدل شود. این شبکه، براساس دو ورودی موثر فشار چندراجه و زاویه دریچه گاز ساخته می شود و به نوعی، انحراف مدل مقدار میانگین از داده های آزمایشگاهی- نرم افزاری را اصلاح می کند. عملکرد و رگرسیون شبکه مذکور در نمودارهای ۱ و ۲ نمایش داده شده است.

به طوری که ملاحظه می شود، ساده سازی وظیفه شبکه، کمیته سازی ورودی های شبکه به ورودی های موثر و همچنین، استفاده از تنظیم بیزین باعث می شود تا شبکه به کیفیت بسیار بالایی دست یابد. در واقع، تنظیم بیزین به شبکه فرصت می دهد تا ضمن پرهیز از بیش معینی، تا حد امکان آموزش ببیند و در عین حال، ساختار مناسب خود را نیز پیدا کند.

گشتاور تولیدی و T_l گشتاور خارجی (یا ورودی مزاحم) است. ω_e نیز به مانند گذشته، دور موتور است. در مدل سازی مقدار میانگین، رفتار رفت و برگشتی با وارد کردن تاخیر زمانی بین اثرات ورود و خروج از سیلندر لحاظ می شود. به عنوان مثال، گشتاور تولیدی موتور، فوراً به افزایش فشار چندراهِه واکنش نشان نمی دهد، بلکه تاخیری به اندازه زمان مکش تا تولید گشتاور (τ_{IPS}) وجود خواهد داشت:

$$\tau_{IPS} \approx \frac{2\pi}{\omega_e} \quad (۷)$$

لازم به ذکر است که اصطکاک موتور در مقادیر گشتاور تولیدی (در زیرسیستم تولید گشتاور) لحاظ می شود.

۸- زیرسیستم احتراق


این زیرسیستم شامل پنج خروجی شامل میزان گشتاور تولیدی، وجود ضربه، نسبت هوا به سوخت خروجی و مقادیر آلاینده های اکسید نیتروژن (NO_x) و مونوکسید کربن (CO) حاصل از احتراق (همان طور که پیشتر ذکر شد، امکان اکتساب داده ها برای آلاینده UHC وجود نداشت) است. به علاوه ورودی ها عبارت از میزان پاشش سوخت (یا نسبت هوا به سوخت ورودی)، مقدار هوای ورودی، سرعت موتور و میزان آوانس جرّقه (در صورت وجود زمان بندی متغیر سوپاپ، یک ورودی به زیرسیستم اضافه می شود) هستند. این زیرسیستم، پیچیده ترین و پرچالش ترین قسمت مدل سازی موتور محسوب می شود. عدم دقت کافی در مدل سازی این قسمت به معنای اشکال اساسی در مدل نهایی خواهد بود. با توجه به خطای بالای مدل های مقدار میانگین مرسوم، در این پژوهش، تمامی این خروجی ها توسط شبکه های عصبی، پیش بینی خواهند شد. همچنین، با توجه به آنچه ذکر شد، به منظور افزایش دقت مدل، برای هر خروجی، یک ساختار شبکه ای مجزا طراحی می شود؛ یعنی پنج زیرسیستم متفاوت. باید توجه داشت که با بسته شدن سوپاپ ها در هر سیکل موتور، شرایط مرزی حین فرایند احتراق، بدون تغییر خواهد بود. بنابراین، می توان زیرسیستم احتراق را استاتیکی فرض کرد^[۳]، هر چند ورودی های آن حالت دینامیک دارند. با توجه به پیچیدگی و بیشترین تعداد ورودی های این زیرسیستم ها، تعداد داده های لازم برای آموزش شبکه ها بیشتر خواهد بود. همچنان که قبلاً ذکر شد، به دلیل پیچیدگی بیشتر و نیاز به حصول به دقت های بالاتر، از روش های پیشرفته تر شبکه عصبی به صورت زیر برای مدل سازی این زیرسیستم ها استفاده می شود:

۱- استفاده از تقسیم بندی بهبود یافته یا استفاده از مدل های محلی- سراسری (مانند مدل های درختی محلی یا آنفیس). باید دقت داشت که روش آنفیس برای سیستم های با تعداد بالای ورودی شاید چندان کارآمد نباشد.

۲- استفاده از میانگین گیری جمعی (از روش های گروهی)، به منظور غلبه بر تضاد بایاس/واریانس. برای این منظور باید شبکه های مورد استفاده تا حدی بیش معین باشند.

شکل ۳ ترکیب دو روش فوق را برای زیرسیستم های پیچیده تر نمایش می دهد. به طور خلاصه، هر خروجی به صورت یک زیرسیستم مجزا مدل می شود. هر زیرسیستم، در صورت نیاز با استفاده از مدل های محلی- سراسری (مانند آنفیس یا لولیمات) یا میانگین گیری جمعی از شبکه های گروهی مدل می شود. برای زیرسیستم های پیچیده تر (در صورت نیاز)، از ترکیب دو روش تقسیم بندی بهبود یافته و میانگین گیری جمعی استفاده می شود. به این ترتیب که ابتدا ناحیه عملکردی مربوطه، براساس رژیم های

مانند قبل، شبکه عصبی ساخته شده، میزان انحراف پاسخ روابط فوق از سیستم واقعی را در نظر می گیرد. به این ترتیب، نامعینی های مدل نشده در نظر گرفته خواهد شد. ورودی های شبکه برای تخمین بازدهی جمعی $\lambda_l(P_m, \omega_e)$ ، دو متغیر $\omega_e(t)$ و P_m هستند (نمودار ۳).



نمودار ۳) رگرسیون شبکه جانیایی شده در زیرسیستم تبادل گاز

۶- زیرسیستم دریافت کننده (یا دینامیک منیفولد ورودی)

رفتار دینامیک چندراهِه، توسط این زیرسیستم تعیین می شود. این زیرسیستم به صورت یک انباره با پارامترهای متمرکز مدل می شود که براساس (انتگرال گیری از) تفاوت مقدار جرم ورودی و خروجی از چندراهِه، میزان فشار لحظه ای چندراهِه ورودی را تعیین می کند. یعنی^[۳]:

$$\frac{d}{dt} P(t) = \frac{R \cdot \theta}{V} [\dot{m}_{in}(t) - \dot{m}_{out}(t)] \quad (۵)$$

در رابطه بالا، V حجم چندراهِه، P فشار، $\dot{m}_{in}$ و $\dot{m}_{out}$ دبی های جرمی هوای ورودی به چندراهِه و خروجی از آن و θ دمای هوا در چندراهِه است.

لازم به ذکر است که متناسب با حسگرهای موتور، باید یکی از خروجی های مدل، فشار منیفولد ورودی باشد. به دلیل استفاده از شبکه های عصبی ممکن است فشار محاسبه شده (علی رغم محاسبه از طریق انتگرال گیر) دارای نوسانات بالا باشد. در این پژوهش، یک فیلتر پایین گذر برای این منظور طراحی می شود. به منظور افزایش دقت و ایجاد ترکیب جعبه خاکستری می توان به جای θ ، یک شبکه عصبی برای حالات مختلف عملکردی موتور در نظر گرفت.


۷- زیرسیستم دینامیک دورانی

گشتاور تولیدی توسط موتور، به میل لنگ تحویل داده می شود. چرخ طیار که به میل لنگ متصل است، وظیفه یکنواخت کردن دور خروجی موتور را بر عهده دارد. دور موتور با انتگرال گیری از تفاضل گشتاور تولیدی توسط موتور و بار خروجی، از یک دور اولیه مشخص، محاسبه می شود. در واقع این زیرسیستم، یک انباره انرژی است که به صورت زیر مدل می شود^[۳]:

$$\theta_e \frac{d}{dt} \omega_e(t) = T_e(t - \tau_{IPS}) - T_l(t) \quad (۶)$$

در رابطه بالا، θ_e اینرسی مقاوم میل لنگ و قسمت های دوار، T_e

بایاس/واریانس است. همان طور که می دانیم، برای یک شبکه منفرد، یک تعداد بهینه نیوران میانی وجود دارد که با تجاوز از آن، علی رغم کاهش خطای بایاس، خطای واریانس شبکه افزایش می یابد. اساس این روش، بر پایه افزایش نیوران های میانی به منظور بیش معینی گروهی از شبکه هاست تا خطای بایاس آنها کاهش یابد. به لحاظ ریاضی می توان ثابت کرد چنانچه گروهی از این شبکه های بیش معین در کنار هم قرار گیرند و میانگین آنها محاسبه شود، خطای واریانس مجموعه کاهش خواهد یافت [28]. به این ترتیب، می توان با غلبه بر تضاد بایاس/واریانس به دقت های بالاتری دست یافت.



شکل ۴) میانگین گیری گروهی [28]

به طور خلاصه، روش های گروهی (از جمله میانگین گیری جمعی) بیان می کنند که خرد جمعی می تواند از نظر یک متخصص منفرد دقیق تر باشد. یکی از مزایای ترکیب دو روش فوق، امکان طراحی تعداد متفاوت شبکه های گروهی برای هر زیر- ناحیه است. در ادامه، مدل سازی هر زیرسیستم از مجموعه احتراق بیان می شود.

۱-۸- مدل سازی گشتاور تولیدی

این زیرسیستم با تعداد ۴۳۳ داده آموزش می بیند. هنگام آموزش ملاحظه می شود که شبکه ها نمی توانند هم مقادیر بزرگ و هم مقادیر کوچک را به خوبی یاد بگیرند. به دلیل اهمیت و پیچیدگی بالای این زیرسیستم از ترکیب دو روش تقسیم بندی بهبود یافته و میانگین گیری گروهی استفاده می شود. به منظور تقسیم بندی به دو زیر- ناحیه، روابط زیر به صورت تجربی پیشنهاد می شود: مجموعه آموزش اول:

$$\left(\frac{\dot{m}_{air}}{rpm} \times 1000 < 0.012\right) OR (Spark Advance \geq -6) \rightarrow Set\#1$$

مجموعه آموزش دوم:

$$\left(\frac{\dot{m}_{air}}{rpm} \times 1000 < 0.0085\right) AND (Spark Advance < 0) \rightarrow Set\#2$$

ملاحظه می شود که دو مجموعه در مرز خود با یکدیگر همپوشانی دارند. حال شرط تقسیم بندی شبکه ها در مدل نهایی به صورت زیر تعریف می شود:


$$if \left(\frac{\dot{m}_{air}}{rpm} \times 1000 < 0.01\right) OR (Spark Advance \geq -2) \rightarrow NN\#1$$

$$if \left(\frac{\dot{m}_{air}}{rpm} \times 1000 \geq 0.01\right) AND (Spark Advance < -2) \rightarrow NN\#2$$

با این تعاریف، از ۴۳۳ داده موجود، مجموعه اول شامل ۲۸۲ داده و مجموعه دوم شامل ۳۰۵ داده خواهد بود. با این دسته بندی و آموزش دو شبکه، میزان خطای میانگین مربعات مدل (MSE)، از ۰/۲۳۲۳ (مربوط به بهترین شبکه منفرد آموزش دیده)، به ۰/۱۱۷۲ (یعنی تقریباً نصف) کاهش می یابد.

با توجه به اهمیت این زیرسیستم (که خروجی آن دور موتور را تعیین خواهد کرد)، تلاش می شود تا دقت آن با استفاده از روش گروهی افزایش یابد. به این ترتیب، به جای هر شبکه در ساختار فوق، یک گروه از شبکه ها قرار می گیرند. باید توجه داشت که

مختلف عملکردی، به چندین قسمت (یا زیر- ناحیه) تقسیم می شود. به عبارت دیگر، برای هر رژیم عملکردی در هر زیرسیستم، یک زیر- ناحیه در نظر گرفته می شود. این تقسیم بندی می تواند براساس بهینه سازی یا دید فیزیکی طراح انجام گیرد. هر زیر- ناحیه با زیر- ناحیه های مجاور، کمی همپوشانی خواهد داشت. ما این روش را "تقسیم بندی بهبود یافته" می نامیم. برای هر زیر- ناحیه، یک گروه از شبکه ها آموزش خواهد دید (شکل ۳). ترکیب دو روش مذکور، چنانچه در ادامه ملاحظه خواهد شد، دقت نهایی را تا حد بسیار زیادی افزایش خواهد داد.




شکل ۳) ترکیب روش های تقسیم بندی بهبود یافته و میانگین گیری گروهی، رژیم دوم می تواند به دو قسمت تقسیم شود.

ایده کلیدی در روش تقسیم بندی این بوده که یادگیری یک رژیم رفتاری به خصوص برای یک شبکه، بسیار ساده تر از یادگیری همزمان چندین رژیم رفتاری متفاوت است. با این روش، در واقع، وظیفه محوله بر هر شبکه ساده تر می شود و در نتیجه می توان از شبکه هایی ساده تر با کیفیت بالاتر بهره برد (اصل ایجاز). چنانکه در شکل ۳ ملاحظه می شود، هر قسمت (یا زیر- ناحیه) در مرز خود با قسمت مجاور، همپوشانی دارد. اضافه شدن نواحی مشترک مرزی به هر زیر- ناحیه سبب می شود تا کاهش تعداد داده های آموزش ناشی از تقسیم بندی تا حدی جبران شود. باید به خاطر داشت که کاهش داده های آموزشی در دسترس برای هر شبکه، موجب افزایش خطای واریانس و در نتیجه کاهش دقت شبکه می شود. به علاوه با این روش، تخمین نواحی مرزی با دقت بالاتری انجام می گیرد. به این دلیل، ما این روش را تقسیم بندی بهبود یافته نامیدیم. از سوی دیگر، روش میانگین گیری جمعی (شکل ۴) [28]، یکی از موثرترین و قدرتمندترین روش ها برای غلبه بر تضاد


می‌دهد. چنانکه ملاحظه می‌شود، ساختار گروهی می‌تواند تمامی داده‌ها را به‌درستی پیش‌بینی کند. حال، حدود ۶۰ داده اضافی که در آموزش، تست یا صحت‌گذاری هیچ کدام از شبکه‌ها استفاده نشده است، برای تست نهایی مورد استفاده قرار می‌گیرد. به‌طوری که در شکل ۷ مشاهده می‌شود، بهترین شبکه منفرد می‌تواند ۸۹/۵٪ داده‌ها را به‌درستی پیش‌بینی کند، در حالی که ساختار گروهی قادر است در ۹۶/۵٪ موارد به‌درستی پاسخ دهد.



شکل ۵) نمودار آشفته‌گی بهترین شبکه منفرد آموزش‌دیده




شکل ۶) نمودار آشفته‌گی کلی ساختار گروهی



شکل ۷) مقایسه آشفته‌گی پیش‌بینی الگوها توسط بهترین شبکه منفرد و ساختار گروهی برای داده‌های ناآشنا برای تمامی شبکه‌ها: الف) مقایسه آشفته‌گی پیش‌بینی الگوها توسط بهترین شبکه منفرد، ب) ساختار گروهی

داده‌های با خروجی پایین، معمولاً متعلق به کارکرد نامطلوب موتور و داده‌های با خروجی بالاتر، معمولاً متعلق به کارکرد مطلوب موتور هستند. بنابراین، برای گروه شبکه‌های با خروجی بزرگ‌تر، تعداد بیشتری شبکه طراحی می‌شود. در نهایت، به‌جای شبکه اول، ۵ شبکه و به‌جای شبکه دوم، ۱۰ شبکه قرار می‌گیرند. لازم به ذکر است که تلاش می‌شود تا تمامی شبکه‌های گروهی، بیش‌معین باشند تا روش گروهی اثربخشی خود را نشان دهد.

به این ترتیب، خطای میانگین مربعات مدل به ۰/۰۶۵۷٪ یعنی تقریباً نصف حالت دوشبکه‌ای و یک‌چهارم بهترین شبکه منفرد (که خود از میان ده‌ها شبکه انتخاب شده است) کاهش می‌یابد. نمودار رگرسیون کلی (شامل مجموع داده‌های آموزش، صحت‌گذاری و تست) این زیرسیستم، به‌صورت نمودار ۴ خواهد بود. چنانچه پیداست مدل حاصله، چه برای مقادیر کم و چه برای مقادیر بالای گشتاور، دقت قابل توجهی دارد. البته باید توجه داشت که نقطه ضعف متد گروهی، افزایش زمان پاسخ مدل است. بنابراین، نباید تعداد شبکه‌های یک گروه، بیش از حد زیاد شود.



نمودار ۴) نمودار رگرسیون کلی (شامل مجموعه‌های آموزش، صحت‌گذاری و تست) زیرسیستم تولید گشتاور


۸-۲- مدل‌سازی وجود ضربه

وظیفه حسگر ضربه این است که بروز ضربه در سیلندرها را به واحد کنترل الکترونیکی اطلاع دهد تا مازول کنترل ضربه، آوانس جرقه را کاهش دهد. با توجه به اینکه سیگنال ضربه، تنها مقادیر صفر یا یک (به‌معنی وجود یا عدم وجود ضربه) را به خود می‌گیرد، بنابراین بهتر است از شبکه‌های مربوط به تشخیص الگو برای این زیرسیستم استفاده شود.


با توجه به دقت نسبتاً مناسب شبکه‌های آموزش‌دیده، تنها از روش گروهی با ۵ شبکه، به‌منظور افزایش دقت استفاده می‌شود. شکل ۵، ماتریس آشفته‌گی مربوط به بهترین شبکه منفرد آموزش‌دیده (منتخب از بین ده‌ها شبکه آموزش‌دیده) را نشان می‌دهد. اعداد یک و صفر، در محورهای افقی و عمودی، به‌ترتیب نشانگر وجود یا عدم وجود ضربه است. برای مثال، آشفته‌گی داده‌های تست (زیر-ماتریس پایین، سمت چپ) نشان می‌دهد که ۳ خروجی با مقدار صفر (به‌معنی عدم وجود ضربه) به اشتباه، یک پیش‌بینی شده است.

شکل ۶، ماتریس آشفته‌گی نهایی ساختار ۵ شبکه‌ای را نمایش

دلیل این مساله، بیش از همه، تغییرات بازده احتراق برای نسبت‌های متفاوت هوا به سوخت است. برای مثال، با غنی‌تر شدن سوخت، دمای شعله و تمایل به احتراق کامل کاهش می‌یابد. این شرایط، در ترکیب شیمیایی محصولات احتراق، تاثیرگذار است و برای مثال باعث می‌شود تا به‌جای دی‌اکسیدکربن، مونوکسیدکربن تولید شود. این مساله نیز به نوبه خود موجب تغییر نسبت هوا به سوخت خروجی نسبت به مقدار آن در ورودی به سیلندر می‌شود. نمودار ۸، رگرسیون شبکه عصبی طراحی شده را نشان می‌دهد.



نمودار (۶) رگرسیون یک شبکه آموزش دیده برای زیرسیستم مونوکسید کربن



نمودار (۷) رگرسیون ساختار گروهی مونوکسید کربن برای تمامی داده‌ها و همچنین حدود ۶۰ داده اضافی تست؛ الف) رگرسیون ساختار گروهی مونوکسید کربن برای تمامی داده‌ها، ب) حدود ۶۰ داده اضافی تست


۳-۸ مدل سازی آلایند اکسیدهای نیتروژن

این زیرسیستم، پیچیده‌ترین زیرسیستم موتور احتراقی است و باید از ترکیب دو روش تقسیم‌بندی بهبودیافته و ساختار گروهی برای مدل سازی آن استفاده کرد. بررسی‌ها نشان دادند که برای حصول به پاسخ مناسب باید از تقسیم‌بندی سه‌گانه استفاده شود. به این ترتیب، تقسیم‌بندی بهبودیافته جدول داده‌ها، به صورت تجربی زیر انجام می‌گیرد:

- $(Air/Fuel\ Ratio \geq 12) \rightarrow Set\#1$
 $(11 \leq Air/Fuel\ Ratio \leq 14) \rightarrow Set\#2$
 $(Air/Fuel\ Ratio < 12) \text{ OR } (NOx < 4000) \rightarrow Set\#3$
 تقسیم‌بندی شبکه‌ها در مدل نهایی نیز به صورت زیر انجام می‌گیرد:
 $(Air/Fuel\ Ratio > 13) \rightarrow NN\#1$
 $(11 \leq Air/Fuel\ Ratio \leq 13) \rightarrow NN\#2$
 $(Air/Fuel\ Ratio < 11) \rightarrow NN\#3$

با بهره‌گیری از دو روش گروهی و تقسیم‌بندی بهبودیافته، خطای میانگین مربعات به $2/96 + E^4$ تقلیل می‌یابد. یعنی حدود ۹۰٪ کاهش نسبت به بهترین شبکه منفرد آموزش دیده (که خود از بین حدود ۵۰ شبکه انتخاب شده است)، نشان از کارایی چشمگیر روش‌های مورد استفاده دارد. به علاوه، میانگین قدر مطلق خطا، حدوداً یک چهارم ساختار آنفیس خواهد بود.

در نهایت، رگرسیون کلی شبکه به صورت نمودار ۵ است. باید توجه داشت که تعداد اندک داده‌هایی که از خط اصلی رگرسیون خارج هستند، مربوط به نقاط عملکردی کاملاً نامتعارف موتور بوده که امکان کارکرد موتور در آن شرایط، تقریباً غیرممکن است. بنابراین، می‌توان گفت که مدل ناکس قادر است خروجی اکسیدهای نیتروژن را با دقت بالایی پیش‌بینی کند.



نمودار (۵) رگرسیون کلی زیرسیستم ناکس

۴-۸ زیرسیستم آلایند مونوکسید کربن

با توجه به پیچیدگی کمتر این زیرسیستم، می‌توان تنها از یک شبکه برای مدل سازی استفاده کرد (نمودار ۶). به منظور دستیابی به دقت‌های بالاتر می‌توان از ساختار گروهی بهره برد (نمودار ۷). نمودار ۷، رگرسیون ساختار گروهی برای تمامی داده‌ها (اعم از داده‌های آموزش، صحت‌گذاری و تست) و همچنین حدود ۶۰ داده اضافی تست نهایی را نمایش می‌دهد. چنانچه در نمودارهای ۶ و ۷ ملاحظه می‌شود، ساختار منفرد دقت نسبتاً خوبی دارد و استفاده از ساختار گروهی می‌تواند دقت مدل را کمی بهبود دهد.


۵-۸ زیرسیستم نسبت هوا به سوخت خروجی

همان‌طور که قبلاً ذکر شد، مقدار نسبت هوا به سوخت خروجی از سیلندر، با نسبت هوا به سوخت ورودی به سیلندر متفاوت است.

خود می‌رسد. همچنین، مصرف سوخت ویژه ترمزی، چنانچه در نمودار ۹- الف مشخص است، برای نسبت هوا به سوخت استوکیومتریکی به مقدار پهنه خود می‌رسد.


نمودار ۹- ب تاثیرات آوانس جرقه بر پارامترهای عملکردی را نمایش می‌دهد. نتایج این نمودار نیز برای حالات تمام بار ۳۰۰۰ دور بر دقیقه به دست آمده‌اند. مطابق انتظار، مقدار ناکس تقریباً به صورت خطی با افزایش زاویه جرقه کاهش می‌یابد [3]. از این نمودار به راحتی می‌توان دریافت که میزان آوانس جرقه، تاثیر زیادی بر مقدار آلایندة ناکس دارد.

اصولاً آوانس جرقه، تاثیر بسیار کمی بر میزان مونوکسید کربن دارد و این مساله به وضوح در نمودار ۹- ب مشخص است. در مورد مصرف سوخت ویژه، چنانچه ملاحظه می‌شود، با افزایش آوانس جرقه، موتور اقتصادی‌تر کار خواهد کرد. این مساله بیانگر این حقیقت است که با افزایش آوانس جرقه، ماکزیمم فشار احتراق و متعاقباً توان تولیدی افزایش می‌یابد. با این حال، در این حالت، آلایندة ها و همچنین احتمال وقوع ضربه افزایش خواهد یافت.



نمودار ۹) مقایسه نتایج مدل نهایی و تست موتور و همچنین، تاثیر ورودی‌های کنترلی بر عملکرد موتور؛ الف) تاثیرات نسبت هوا به سوخت، ب) تاثیرات آوانس جرقه بر پارامترهای عملکردی

همان‌طور که قبلاً ذکر شد، یکی از چالش‌برانگیزترین انتظارات از یک مدل موتور، پیش‌بینی دقیق حالت گذراست. به منظور صحت‌گذاری حالت گذرای مدل با داده‌های تست، ورودی‌های دینامیک مطابق با نمودار ۱۰ در نظر گرفته می‌شود. چنانچه ملاحظه می‌شود، ورودی‌ها شامل گستره عملکردی بسیار بالا با تغییرات بسیار سریع هستند. اگرچه این ورودی‌ها بسیار نامتعارف به نظر



نمودار ۸) رگرسیون شبکه آموزش‌دیده برای زیرسیستم نسبت هوا به سوخت خروجی

بررسی‌های انجام‌شده نشان داد که تمامی ورودی‌ها در نسبت هوا به سوخت خروجی تاثیرگذارند و برای حصول به بیشترین دقت باید شبکه عصبی طراحی‌شده، شامل هر چهار ورودی باشد. در انتها تاخیر زمانی مکش تا تخلیه به صورت زیر در نظر گرفته می‌شود:

$$\tau_{IEG} \approx \frac{3\pi}{\omega_e} \quad (۸)$$


۹- صحت‌گذاری و مطالعه پارامتری

در این قسمت، نتایج حاصل از شبیه‌سازی مدل نهایی (Neuro-MVM) با نتایج آزمایشگاهی- نرم‌افزاری تست موتور [1] مقایسه می‌شود و ضمن صحت‌گذاری، تاثیر ورودی‌های کنترلی بر خروجی‌های موتور مورد بررسی قرار می‌گیرد.


نمودار ۹- الف و ب، به ترتیب تاثیر نسبت هوا به سوخت و آوانس جرقه بر عملکرد موتور را نمایش می‌دهد. متغیرهای عملکردی خروجی مزبور شامل اکسیدهای نیتروژن، مونوکسید کربن و مقدار مصرف سوخت ویژه ترمزی (BSFC) هستند. چنانچه ملاحظه می‌شود، مدل نهایی تطابق بالایی با نتایج تست (آزمایشگاهی- نرم‌افزاری) موتور دارد. شرایط تست مدل، مانند شرایط تست داده‌های تجربی واقعی موتور در نظر گرفته می‌شود؛ یعنی دمای ورودی ۲۹۵ کلوین و فشار محیط ۸۸/۰ کیلوپاسکال.

در نمودار ۹- الف، نسبت هوا به سوخت به صورت پیوسته از مقدار ۱۰ تا ۱۶ برای حالات تمام بار ۳۰۰۰ دور بر دقیقه تغییر می‌کند. همان‌طور که انتظار می‌رفت، میزان ناکس با نسبت هوا به سوخت به صورت سهموی تغییر می‌کند. مقدار ماکزیمم در نزدیکی مقدار استوکیومتریکی که دمای شعله به حداکثر می‌رسد، رخ می‌دهد [3]. به بیان دیگر، تولید ناکس، به شدت متاثر از دمای شعله است و در نسبت هوا به سوخت استوکیومتریکی (که احتراق به صورت کامل انجام می‌گیرد)، دمای شعله و به تبع آن، مقدار ناکس به حداکثر می‌رسد.

از طرف دیگر، تغییرات آلایندة مونوکسید کربن بر حسب نسبت هوا به سوخت، مطابق انتظار، یک منحنی نزولی است. این آلایندة برای مخلوط رقیق که اکسیژن کافی برای سوختن دارد، به کمترین مقدار




نمودار ۱۳) صحنه‌گذاری تغییرات فشار منیفولد در حالت گذرا



نمودار ۱۴) صحنه‌گذاری احتمال وقوع ضربه در حالت گذرا

می‌رسند، اما به منظور چالش مدل و نشان دادن قابلیت‌های آن مناسب‌اند. سرعت اولیه موتور ۴۰۰۰ دور بر دقیقه در نظر گرفته می‌شود.

نمودارهای ۱۱-۱۴، به ترتیب خروجی‌های دور موتور، مقدار آلاینده ناکس، تغییرات فشار منیفولد (حاصل از فیلتر پایین‌گذر) و وقوع ضربه را در حالت گذرای موتور نمایش می‌دهند. همان‌طور که مشخص است، مدل در تمامی حالات قادر است رفتار دینامیک موتور را با دقت بالا پیش‌بینی کند که این مساله، یکی از نقاط تمایز این پژوهش با مقالات پیشین است.



نمودار ۱۵) ورودی‌های دینامیک اعمالی به منظور صحنه‌گذاری رفتار گذرای مدل

۱۰- نتیجه‌گیری

در این پژوهش، یک مدل کنترل‌محور جدید برای موتور اشتعال جرقه‌ای به نام Neuro-MVM ارائه شد. چنانچه ذکر شد، مدل‌های مقدار میانگین متداول (MVM)، به خصوص در پیش‌بینی آلاینده‌ها، دقت پایینی دارند. همان‌طور که نشان داده شد، Neuro-MVM قادر است عملکرد موتور را به صورت بلادرنگ و با دقت بالا، حتی در حالت دینامیک (حتی برای آلاینده‌ها) پیش‌بینی کند. به علاوه، مدل مذکور توانست خروجی‌ها و ورودی‌های مورد نیاز برای طراحی نرم‌افزار-در-حلقه سیستم کنترلی موتور را در بر گیرد. مدل نهایی توانست اهداف مذکور را حتی در یک گستره بسیار وسیع عملکرد دینامیک موتور محقق کند که این مساله نشان از قابلیت اعتماد بالای مدل دارد.


ترکیب معادلات (تقریباً جعبه سفید) مدل‌های مقدار میانگین و شبکه‌های عصبی (جعبه سیاه) موجب شد تا مدل حاصل، از مزایای هر دو نوع مدل‌سازی بهره‌مند شود. این مساله، نه تنها باعث قابلیت اعتماد بالای مدل شد (از دقت بالای مدل در گستره بالای عملکردی آن نیز مشخص است)، بلکه همچنین با ساده‌سازی وظایف محوله بر شبکه‌ها موجب افزایش دقت شبکه‌ها و در نتیجه مدل نهایی شد. علاوه بر این، استفاده از روش‌های پیشرفته‌تر در طراحی شبکه‌های عصبی باعث شدند که رگرسیون‌های حاصل، حتی برای داده‌های کاملاً ناآشنا شبیه به خط شوند.

تشکر و قدردانی: موردی از سوی نویسندگان بیان نشده است.


تاییدیه اخلاقی: موردی از سوی نویسندگان بیان نشده است.

تعارض منافع: موردی از سوی نویسندگان بیان نشده است.

سهم نویسندگان: امیرمحمد شامخی (نویسنده اول)، پژوهشگر



نمودار ۱۱) صحنه‌گذاری تغییرات دور موتور در حالت گذرا



نمودار ۱۲) صحنه‌گذاری تغییرات ناکس در حالت گذرا

Control and Systems, June 9-11, Alghero, 1998, Piscataway: IEEE; 1998.

7- Müller R, Hemberger HH. Neural adaptive ignition control. SAE Transactions. 1998;107:1636-1641.

8- Gang X, Jianwu Z, Li Ch. On-line stateprediction of engines based on fast neural network. SAE 2001 World Congress, 5-8 March, 2001, Detroit, Michigan, USA. Warrendale: SAE International; 2001.

9- He Y, Rutland CJ. Modeling of a turbocharged di diesel engine using artificial neural networks. SAE Transactions. 2002;111:1532-1543.

10- He Y, Rutland CJ. Neural cylinder model and its transient results. SAE Technical Paper 2003-01-3232; 2003.

11- He Y, Rutland CJ. Application of artificial neural networks in engine modelling. International Journal of Engine Research. 2004;5(4):281-296.

12- Brahma I, He Y, Rutland CJ. Improvement of neural network accuracy for engine simulations. SAE Technical Paper 2003-01-3227; 2003.

13- Brusca S, Lanzafame R, Messina M. A combustion model for ICE by means of neural network. SAE Technical Paper 2005-01-2110; 2005.

14- Samadani E, Shamekhi AH, Behrooz MH, Chini R. A method for pre-calibration of DI diesel engine emissions and performance using neural network and multi-objective genetic algorithm. Iranian Journal of Chemistry and Chemical Engineering. 2009;28(4):61-70.

15- Kumar Sh, Srinivasa Pai P, Shrinivasa Rao BR. Artificial neural network based prediction of performance and emission characteristics of a variable compression ratio CI engine using WCO as a biodiesel at different injection timings. Applied Energy. 2011;88(7):2344-2354.

16- Ismail HM, Ng HK, Queck CW, Gan S. Artificial neural networks modelling of engine-out responses for a light-duty diesel engine fuelled with biodiesel blends. Applied Energy. 2012;92:769-777.

17- Cay Y, Çiçek A, Kara F, Sağiroğlu S. Prediction of engine performance for an alternative fuel using artificial neural network. Applied Thermal Engineering. 2012;37:217-225.

18- Janakiraman VM, Nguyen X, Assanis D. Nonlinear identification of a gasoline HCCI engine using neural networks coupled with principal component analysis. Applied Soft Computing. 2013;13(5):2375-2389.

19- Roy S, Banerjee R, Bose PK. Performance and exhaust emissions prediction of a CRDI assisted single cylinder diesel engine coupled with EGR using artificial neural network. Applied Energy. 2014;119:330-340.

20- Nikzadfar K, Shamekhi AH. Investigating the relative contribution of operational parameters on performance and emissions of a common-rail diesel engine using neural network. Fuel. 2014;125:116-128.

21- Kapusuz M, Ozcan H, Yamin JA. Research of performance on a spark ignition engine fueled by alcohol-gasoline blends using artificial neural networks. Applied Thermal Engineering. 2015;91:525-534.

22- Tosun E, Aydin K, Bilgili M. Comparison of linear regression and artificial neural network model of a diesel engine fueled with biodiesel-alcohol mixtures. Alexandria Engineering Journal. 2016;55(4):3081-3089.

23- Acharya N, Acharya S, Panda S, Nanda P. An artificial neural network model for a diesel engine fuelled with mahua biodiesel. In: Behera HS, Mohapatra DP, editors. Computational intelligence in data mining: Proceedings of the international conference on CIDM, 10-

اصلی/نگارنده بحث (۵۰٪)؛ امیرحسین شامخی (نویسنده دوم)،

روش‌شناس/پژوهشگر کمکی (۵۰٪)

منابع مالی: موردی از سوی نویسندگان بیان نشده است.

۱۱- پی‌نوشت

علام

A	سطح موثر ورودی دریچه گاز
C_d	ضریب تخلیه
CO	مونوکسید کربن
k	نسبت گرمای ویژه هوا
$\dot{m}_{in}$	دبی جرمی هوای ورودی به چندراهه
$\dot{m}_{out}$	دبی جرمی هوای خروجی از چندراهه
MSE	خطای میانگین مربعات
MVM	مدل مقدار میانگین
$\dot{m}_\beta$	دبی جرمی هوای ورودی به سیلندر
$\dot{m}_\phi$	دبی جرمی سوخت
NOx	اکسیدهای نیتروژن
P_{cr}	فشار بحرانی
P_{in}	فشار محیط، ورودی به دریچه گاز
P_m	فشار منیفولد
P_{out}	فشار چندراهه، خروجی از دریچه گاز
SI	موتور اشتعال جرقه‌ای
SIL	نرم‌افزار در حلقه
UHC	هیدروکربن‌های نسوخته
V	حجم چندراهه
V_d	حجم جابه‌جایی موتور
T_e	گشتاور تولیدی
T_l	گشتاور خارجی
ϑ	دمای هوا در چندراهه
θ_e	اینرسی مقاوم میل‌لنگ و قسمت‌های دوار
ϑ_{in}	دمای ورودی به دریچه گاز
λ_l	بازده حجمی
τ_{IEG}	تاخیر زمانی مکش تا تخلیه
τ_{IPS}	تاخیر زمان مکش تا تولید گشتاور
ρ_{in}	چگالی سیال ورودی به سیلندر
ω_e	دور موتور

منابع

- 1- Shamekhi AH, Shamekhi AM. Modeling and simulation of combustion in SI engines via neural networks and investigation of calibration and data acquisition in the GT-Power software. Modares Mechanical Engineering. 2015;14(13):233-244. [Persian]
- 2- Shamekhi AM, Shamekhi AH. A new approach in improvement of mean value models for spark ignition engines using neural networks. Expert Systems with Applications. 2015;42(12):5192-5218.
- 3- Guzzella L, Onder Ch. Introduction to modeling and control of internal combustion engine systems. 2nd Edition. Berlin: Springer; 2010.
- 4- Moskwa JJ, Hedrick JK. Modeling and validation of automotive engines for control algorithm development. Journal of Dynamic Systems Measurement and Control. 1992;114(2):278-285.
- 5- Shamekhi AH, Ghaffari A. An improved model for SI engines. ASME 2004 Internal Combustion Engine Division Fall Technical Conference, 24-27 October, 2004, Long Beach, California, USA. New York: American Society of Mechanical Engineers; 2004.
- 6- Arsie I, Pianese C, Rizzo G. Enhancement of control oriented engine models using neural network. Proceeding of the 6th IEEE Mediterranean Conference on

1996.

27- Krose B. An introduction to neural network. 8th Edition. Amsterdam: University of Amsterdam; 1996.

28- Heykin S. Neural networks: A comprehensive foundation. 2nd Edition. Upper Saddle River: Prentice Hall PTR; 1998.

29- Nelles O. Nonlinear system identification: From classical approaches to neural networks and fuzzy models. 1st Edition. Berlin: Springer; 2001.

30- Heywood J. Internal combustion engine fundamentals. 1st Edition. New York: McGraw-Hill; 1988.

11 December 2016. Singapore: Springer; 2017. pp. 193-201.

24- Gürgen S, Ünver B, Altın İ. Prediction of cyclic variability in a diesel engine fueled with n-butanol and diesel fuel blends using artificial neural network. Renewable Energy. 2018;117:538-544.

25- MathWorks. MATLAB R2018b Help [Internet]. Natick: MathWorks; 2018 [cited 2018 Oct 01]. Available from: Not Found

26- Hagan MT, Demuth HB, Beale M. Neural network design. 1st Edition. Boston: PWS Publishing Company;