



Machine learning-driven modeling of the effect of variable valve timing on fuel consumption and emission reduction in a turbocharged port-injection engine

Faraz Javanshayani*, AmirHossein Hamad, AmirHossein Parivar, Mohammad Nejat

Irankhodro Powertrain Company (IPCo), Tehran, Iran

ARTICLE INFO

Keywords:

Machine Learning
Design of Experiments
Engine Calibration
Fuel Economy
Emissions

ABSTRACT

The persistent use of internal combustion engines in the transportation sector underscores a growing need for efficient methods to optimize their performance and emissions calibration. Conventional calibration methods, which rely heavily on experimentation, are often time-consuming, costly, and incapable of capturing the complex, non-linear interactions among critical parameters. This study presents a hybrid methodology integrating Design of Experiments (DOE) and Machine Learning (ML) to model brake specific fuel consumption (BSFC) alongside HC and NO_x emissions in a turbocharged gasoline engine. Two advanced ML algorithms were trained using an optimized DOE based on the Fedorov algorithm. Their predictive performance was systematically evaluated and compared across varying data volumes, ranging from 12.5% to 50% of the design space. Under limited data conditions (25% of the data), both models demonstrated stable performance for predicting HC and NO_x emissions, attributable to their inherent robustness against overfitting. Nevertheless, the prediction errors for these pollutants remained significant compared to those for BSFC, highlighting the necessity for further model refinement and experimental validation. When the data volume was increased to 50%, both models achieved high predictive accuracy, with mean R² values of 99% for BSFC, 96% for NO_x, and 90% for HC. This approach demonstrates that a desired calibration accuracy can be achieved using only 50% of the experimental data, thereby potentially reducing testing time and associated costs by half.



© 2026 Iranian Society of Engine, Tehran, Iran. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution Noncommercial 4.0 International (CC BY-NC 4.0 license). (<https://creativecommons.org/licenses/by-nc/4.0/>).

* Corresponding author

E-mail address: F_shayani@ip-co.com (F. Javanshayani)

Received 15 November 2025; Accepted 28 April 2026

E-ISSN: 2345-4121/ISSN: 1735-5214

Cite this article: Javanshayani F, Hamad AH, Parivar AH, Nejat M. Machine learning-driven modeling of the effect of variable valve timing on fuel consumption and emission reduction in a turbocharged port-injection engine. The Journal of Engine Research. 2026 May 22;73(1):50-65. doi: [10.22034/ER.2026.2076402.1112](https://doi.org/10.22034/ER.2026.2076402.1112)

شبیه‌سازی تأثیر زمان‌بندی متغیر دریچه‌ها بر مصرف سوخت و آلایندگی خام در موتورهای پرخوران احتراق جرقه‌ای تزریق درگاهی به کمک یادگیری رایانه‌ای

فراز جوان‌شایانی*، امیرحسین حمد، امیرحسین پریور، محمد نجات

شرکت تحقیق، طراحی و تولید موتور ایران خودرو (ایپکو)، تهران، ایران

اطلاعات مقاله	چکیده
کلیدواژه‌ها: یادگیری رایانه‌ای طرح آزمون نگاشت موتور مصرف سوخت آلایندگی	با تداوم نقش موتورهای احتراق داخلی در سامانه حمل‌ونقل، نیاز به روش‌های کارآمد برای نگاشت بهینه عملکرد و آلایندگی آن‌ها بیش از پیش احساس می‌شود. روش‌های نگاشت مبتنی بر آزمایش صرف، زمان‌بر و پرهزینه هستند و قادر به کشف تعاملات پیچیده و غیرخطی بین متغیرهای مؤثر نیستند. این پژوهش با به کارگیری یک راه‌حل ترکیبی طرح آزمون و یادگیری رایانه‌ای، به شبیه‌سازی مصرف سوخت ویژه ترمزی و آلاینده‌های HC و NOx در یک موتور بنزینی پرخوران پرداخته است. دو روش پیشرفته با استفاده از یک طرح آزمون بهینه شده مبتنی بر روش فدوروف آموزش داده شدند و عملکرد آن‌ها در شرایط مختلف حجم داده (از ۱۲.۵٪ تا ۵۰٪ از فضای طراحی) مقایسه گردید. در شرایط داده‌های محدود (۲۵٪ از داده‌ها)، هر دو روش به دلیل مقاومت ذاتی در برابر بیش‌برازش، عملکرد نسبتاً پایداری در پیش‌بینی آلاینده‌های HC و NOx نشان دادند. با این حال، خطای پیش‌بینی این متغیرها در مقایسه با مصرف سوخت همچنان قابل توجه بوده که لزوم توسعه بیشتر روش و اعتبارسنجی تجربی نتایج را نشان می‌دهد. با افزایش داده به ۵۰٪، هر دو روش به دقت قابل قبولی دست یافتند. مقادیر میانگین R2 برای NOx، BSFC و HC به ترتیب به ۹۹٪، ۹۶٪ و ۹۰٪ رسید. این رویکرد نشان داد که می‌توان با تنها ۵۰٪ از داده‌های آزمایشی، به دقت مطلوب در نگاشت دست یافت که به معنای کاهش ۵۰ درصدی زمان و هزینه‌های آزمایش است.



© 2026 Iranian Society of Engine, Tehran, Iran. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution Noncommercial 4.0 International (CC BY-NC 4.0 license). (<https://creativecommons.org/licenses/by-nc/4.0/>).

* نویسنده مسئول

پست الکترونیکی: F_shayani@ip-co.com (فراز جوان‌شایانی)

دریافت ۲۴ آبان ۱۴۰۴؛ پذیرش ۸ اردیبهشت ۱۴۰۵

شاپای الکترونیکی: ۴۱۲۱-۲۳۴۵ / شاپای چاپی: ۵۲۱۴-۱۷۳۵

Cite this article: Javanshayani F, Hamad AH, Parivar AH, Nejat M. Machine learning-driven modeling of the effect of variable valve timing on fuel consumption and emission reduction in a turbocharged port-injection engine. The Journal of Engine Research. 2026 May 22;73(1):50-65. doi: 10.22034/ER.2026.2076402.1112

۱- مقدمه

بر اساس گزارش‌های اخیر پیش‌بینی می‌شود که تقاضای جهانی برای انرژی حمل‌ونقل تا سال ۲۰۴۰ با نرخ سالانه ۱ تا ۱.۵ درصد افزایش یابد [۴-۱]. در حال حاضر، بیش از ۹۰ درصد حمل‌ونقل جهانی توسط موتورهای احتراق داخلی که با هیدروکربن‌های مایع سوخت‌رسانی می‌شوند، تأمین می‌گردد [۵]. علیرغم رشد چشمگیر انرژی‌های جایگزین و فناوری‌های رقابتی (مانند خودروهای برقی پیل‌محور، خودروهای دورگه و پیل‌های سوختی)، به طور گسترده پذیرفته شده است که موتورهای احتراق داخلی همچنان نقش قابل‌توجهی در بخش حمل‌ونقل ایفا خواهند کرد [۴-۱].

به دنبال حرکت جهانی برای کربن‌زدایی که عمدتاً تحت تأثیر الزامات قانونی و محدودیت‌های آلایندگی است، نوآوری‌ها در بخش حمل‌ونقل با سرعتی بی‌سابقه در حال رخ دادن هستند. در نتیجه، موتورهای احتراق داخلی کنونی تفاوت چشمگیری با نمونه‌های قرن نوزدهم دارند؛ به گونه‌ای که پیشرفت‌های اساسی در سامانه‌های تأمین هوا، تأمین سوخت و کنترل آلاینده‌ها، موتورهای جدید را به خودروهایی کارآمدتر از نظر توان خروجی و با اثرات زیست‌محیطی بمراتب کمتر تبدیل کرده است.

موتورهای احتراق داخلی سامانه‌هایی پیچیده هستند که در آن‌ها مجموعه‌ای از متغیرهای هم‌زمان و وابسته بر عملکرد و میزان آلایندگی اثر می‌گذارند. ویژگی‌های سوخت، شرایط ورودی، راهبرد پاشش [۶-۸]، بازخورانی گازهای خروجی [۹]، هندسه محفظه سمبه [۱۰-۱۲]، راهبرد و زمان‌بندی پاشش سوخت [۱۳-۲۰]، زاویه پاشش [۲۱، ۲۲]، نسبت گردابه [۲۳] و متغیرهای هندسی از مهم‌ترین عواملی هستند که این رفتار چندمتغیره را شکل می‌دهند. همین درهم‌تنیدگی، فرآیند نگاشت را به مسئله‌ای چالش‌برانگیز و غیرخطی تبدیل می‌کند [۲۴، ۲۵].

بهینه‌سازی عملکرد و آلایندگی موتورهای احتراق داخلی مستلزم بهینه‌سازی هم‌زمان تمام این متغیرهاست. این فرایند بسیار پیچیده است، زیرا برخی از این متغیرها وابسته به یکدیگرند و اثرات متفاوت (و گاه متضاد) بر عملکرد و آلایندگی دارند. به عنوان مثال، افزایش فشار پاشش یا جلو انداختن زمان‌بندی پاشش می‌تواند منجر به افزایش بازده حرارتی، بهبود مصرف سوخت و کاهش آلاینده‌هایی مانند منوکسیدکربن، هیدروکربن‌های نسوخته و دود شود. با این حال، این تغییرات همچنین موجب افزایش اکسیدهای ازت، نرخ افزایش فشار بیشینه و فشار بیشینه استوانه خواهند شد [۱۴-۱۹]. این پیچیدگی در مورد سایر متغیرهای طراحی نیز صدق می‌کند.

فرآیند نگاشت تجربی موتورهای احتراق داخلی عموماً کاری خسته‌کننده و زمان‌بر است. روش‌های سنتی مانند OFAT اگرچه می‌توانند اثر مستقل هر متغیر را نشان دهند، اما به دلیل ماهیت تک‌متغیره خود قادر به شناسایی تعاملات پیچیده میان عوامل نیستند. افزون بر این، انجام آزمون‌های پیاپی برای هر متغیر زمان و هزینه قابل‌توجهی را تحمیل می‌کند. روش‌های پیشرفته‌تر طرح آزمون ظرفیت آن را دارند که فرآیند نگاشت موتور را تسریع کنند. چندین روش استاندارد صنعتی مبتنی بر DoE برای نگاشت موتورهای احتراق داخلی مورد استفاده قرار می‌گیرند که از جمله آن‌ها می‌توان به جعبه ابزار نگاشت مبتنی بر روش (Model-Based Calibration Toolbox) از Mathworks [۲۶، ۲۷]، مجموعه ابزار EasyDoE از JAV، xCAL از ASCMO FEV [۲۸-۳۱] و ETAS [۳۲-۳۳] اشاره کرد. این ابزارهای تجاری مبتنی بر شبیه‌سازی، توسط صنعت خودروسازی برای انجام فرآیند نگاشت به کار می‌روند. اکثر ابزارهای تجاری از روش‌های DoE برای تولید آرایه‌های طرح آزمایش و از شبیه‌سازی آماری برای تولید سطوح پاسخ استفاده می‌کنند. عموماً این ابزارها از الگوهای آماری مانند تحلیل بازگشتی استاندارد، برآورد مربعات متعامد، الگوهای فرآیند گاوسی، توابع پایه شعاعی، چندجمله‌ای‌ها، خطوط منحنی‌ها، آزمون t یا رگرسیون قوی بهره می‌برند. از آنجا که نگاشت موتور مستلزم مدیریت متغیرها تنظیم مختلفی است، انتظار می‌رود همبستگی‌های بسیار غیرخطی با متغیرهای هدفی مانند مصرف سوخت و انتشار آلاینده‌ها وجود داشته باشد. الگوهای آماری سنتی برای ثبت این همبستگی‌ها ناکافی شده و دقت الگوها را تحت تأثیر قرار می‌دهند.

در دو دهه اخیر، پیشرفت‌های چشمگیری در حوزه هوش مصنوعی حاصل شده است. این پیشرفت‌ها، هوش مصنوعی را به ابزاری بالقوه مؤثر برای بهینه‌سازی سامانه‌های موتور/سوخت تبدیل کرده است [۱۰-۱۲، ۲۰، ۳۴، ۳۵]. به‌طور کلی، با افزایش پیچیدگی روابط میان متغیرها، الگوهای یادگیری رایانه‌ای توانایی بیشتری در ثبت رفتارهای غیرخطی نشان می‌دهند. به همین دلیل، این الگوها در مسائل نگاشت موتور که به‌طور طبیعی چندمتغیره هستند، عملکرد دقیق‌تری نسبت به الگوهای آماری سنتی دارند [۳۶]. علاوه بر این، از الگوهای یادگیری رایانه‌ای می‌توان به عنوان جایگزینی برای سامانه آزمون موتور استفاده کرد. به عنوان مثال، معیز و همکاران [۳۵] یک موتور سنگین‌دیزل احتراق تراکمی بنزینی (HD-GCI) را با استفاده از SuperLearner (SL) که یک الگوی یادگیری رایانه‌ای تلفیق‌شده^۱ با روش وراثت است، بهینه‌سازی کردند. سپس SL با روش صعود گرادیان شبکه‌ای ترکیب شد تا هندسه‌های سمبه دو موتور GCI بهبود یابد. موهان و همکاران [۱۲] کاربرد روش ML-GA را برای بهینه‌سازی همزمان افشانه و سمبه یک موتور HD-GCI در سه شرایط بار مختلف گسترش دادند. توقان و بایسک [۳۷] نیز از شبکه‌های عصبی مصنوعی و روش وراثت برای پیش‌بینی گشتاور و مصرف سوخت ویژه ترمزی بر اساس سرعت موتور، موقعیت دریچه گاز و زمان احتراق به منظور پشتیبانی از نگاشت تجربی موتور استفاده و مقایسه کردند.

رحیمی‌گرچی و همکاران [۳۸] از یک شبکه عصبی مصنوعی با یک لایه پنهان برای پیش‌بینی توان موتور و BSFC استفاده کرده و نتایج را با الگوهای رگرسیونی مقایسه نمودند و نشان دادند که شبکه‌های عصبی پیش‌بینی بهتری نسبت به روش تحلیل بازگشتی دارند. اخیراً نیز، ویوری و همکاران [۳۹] از شبکه‌های عصبی پیچشی عمیق در ترکیب با نمودارهای مبتنی بر دینامیک سیالات محاسباتی درون استوانه برای پیش‌بینی انتشار آلاینده‌های خروجی از موتور استفاده کردند. به طور مشابه، پان و همکاران [۳۸] روشی برای استفاده از داده‌های فشار درون استوانه و متغیرهای عملکرد موتور به منظور پیش‌بینی انتشار آلاینده‌های یک موتور احتراق تراکمی با مخلوط اولیه پیش‌مخلوط با استفاده از یادگیری بدون ناظر و روش‌های شناسایی غیرخطی توسعه دادند. روش آن‌ها از تحلیل مؤلفه‌های اصلی برای کاهش ابعاد داده‌های فشار استوانه استفاده می‌کند. متعاقباً، یک الگوی چندورودی-چندخروجی با استفاده از یک شبکه عصبی پرسپترون چندلایه برای پیش‌بینی انتشار NOx و دوده توسعه یافت [۴۰، ۴۱].

همان‌طور که از مرور منابع ارائه‌شده مشهود است، استفاده از DoE و یادگیری رایانه‌ای برای تسریع فرآیندهای نگاشت و بهینه‌سازی موتور، با سرعت نسبتاً بالایی در حال گسترش است. در این مطالعه بر استفاده از روش‌شناسی‌های DoE و ML برای بهینه‌سازی عملکرد و کاهش زمان نگاشت در کل بازه حالت پایای موتور با مشخصات قابل مشاهده در جدول ۱ استفاده می‌شود. برخلاف فرآیند نگاشت سنتی مبتنی بر الگو، این مطالعه از دو الگوی ترکیبی به عنوان جایگزینی برای شبیه‌سازی آزمایش‌های موتور به منظور پیمایش کل فضای طراحی برای کمینه‌سازی مصرف ویژه سوخت ترمزی و عدد دوده استفاده می‌کند. نشان داده می‌شود که روش‌های پیشرفته نگاشت می‌توانند همزمان، عملکرد موتور را بهبود بخشیده و زمان نگاشت آن را در شرایط بار و سرعت مشخص کاهش دهند.

در این پژوهش، با به‌کارگیری یک طرح‌آزمون مبتنی بر روش فدوروف و دو الگوی یادگیری رایانه‌ای، امکان کاهش تعداد آزمون‌های تجربی در عین حفظ دقت نگاشت بررسی شده است. نتایج نشان داد که با استفاده از حداکثر ۵۰٪ از نقاط طراحی، می‌توان برای R^2 به دقتی در حد ۹۹٪ برای BSFC، ۹۶٪ برای NOx و ۹۰٪ برای HC دست یافت؛ در حالی که کاهش بیشتر تعداد نقاط (تا حدود ۲۵٪) هنوز هم دقت قابل‌قبولی را برای متغیرهای عملکردی فراهم می‌کند. این یافته‌ها نشان می‌دهد که استفاده از ترکیب DoE و یادگیری رایانه‌ای می‌تواند زمان و هزینه نگاشت را به‌طور معنی‌داری کاهش دهد، بدون آن‌که دقت پیش‌بینی در بازه‌های عملیاتی مورد نظر قربانی شود.

¹ Ensemble

۲- مواد و روش‌ها

۲-۱- مشخصات موتور

آزمایش‌های تجربی بر روی موتور ۴ استوانه بنزینی پرخوران EF7 با حجم ۱۶۴۹ سی‌سی با نسبت تراکم ۹/۳، قطر سمبه ۷۸/۶ و طول پیمایش سمبه ۸۶ سانتیمتر انجام گرفتند. به منظور جلوگیری از صرف هزینه و زمان مجدد، از داده‌های موجود برای این موتور استفاده شد. آزمون در دمای هوای ورودی ۲۵ درجه سانتیگراد در فشار هوای ورودی ۱۰۱ کیلوپاسکال انجام گرفته است. دمای سیال خنک‌کن ورودی ۹۰ درجه سانتیگراد و سایر شرایط مرزی مانند شرایط اشاره شده در استاندارد آزمون رعایت شدند. داده‌های آزمون در دوره‌های ۱۵۰۰ تا ۳۰۰۰ دور در دقیقه و فشار مؤثر متوسط ترمزی ۱ تا ۱۴ بار استفاده شد. در جدول ۱ مشخصات موتور و شرایط مرزی آزمون نشان داده شده‌اند.

جدول ۱ مشخصات موتور و شرایط مرزی آزمون

مشخصه	مقدار
نوع موتور	چهار استوانه پرخوران بنزینی EF7
حجم موتور	۱۶۴۹ سی‌سی
نسبت تراکم	۹/۳
قطر استوانه	۷۸/۶ میلی‌متر
پیمایش سمبه	۸۶ میلی‌متر
محدوده دور موتور آزمون	۱۵۰۰-۳۰۰۰ دور در دقیقه
محدوده BMEP	۱-۱۴ بار
دمای هوای ورودی	۲۵ درجه سانتیگراد
فشار هوای ورودی	۱۰۱ کیلوپاسکال
دمای سیال خنک‌کن	۹۰ درجه سانتیگراد
نوع سوخت	بنزین با اکتان ۹۵

۲-۲- نقاط اولیه آزمون

طرح‌آزمون شاخه‌ای از آمار کاربردی است که به برنامه‌ریزی، اجرا، تحلیل و تفسیر آزمون‌های مهارشده برای شناسایی عوامل تأثیرگذار بر یک یا چند متغیر می‌پردازد. DoE ابزاری جامع برای جمع‌آوری و تحلیل داده در زمینه‌های تجربی مختلف محسوب می‌شود. این روش با امکان دستکاری همزمان چندین عامل ورودی، تأثیر آن‌ها را بر متغیر خروجی هدف بررسی می‌کند و می‌تواند تعاملات پیچیده‌ای را که در روش سنتی بررسی یک عامل در هر زمان نادیده می‌ماند، شناسایی کند. در این روش می‌توان تمام ترکیبات ممکن عوامل یا تنها بخشی از آن‌ها را آزمایش کرد. برای اطمینان از اینکه داده‌های تجربی هم دارای محتوای اطلاعاتی بالا و هم از استحکام آماری کافی برای آموزش الگو برخوردار باشند، طرح آزمایشی داخلی با راهنمایی معیار بهینگی مبتنی بر الگو انجام شد. پیاده‌سازی این طرح با در نظر گرفتن تمام محدودیت‌های عملی و فیزیکی سامانه مورد مطالعه انجام پذیرفت. مجموعه نهایی نقاط آزمایشی به گونه‌ای انتخاب شدند که نه تنها معیار بهینه‌سازی آماری را ارضا کنند، بلکه از نظر عملی نیز قابل اجرا و تکرار باشند. روش فدوروف با ارزیابی دترمینان جدول اطلاعات، نقاطی را برمی‌گزیند که پراکندگی مناسب و محتوای اطلاعاتی بالاتری در فضای ورودی ایجاد کنند.

در این پژوهش، ابزاری داخلی برای تولید طرح‌آزمون توسعه یافته که از طرح Federov استفاده می‌کند، در فضای زبان برنامه‌نویسی پایتون ساخته شد. فرآیند با یک طرح‌ریزی اولیه پُرکننده فضا آغاز می‌شود تا محتوای اطلاعاتی حاصل

از تعداد محدودی آزمایش به حداکثر برسد. روش مبادله‌ای فدوروف اصلاح‌شده پیاده‌سازی شده است. این روش با انتخاب تصادفی نقاطی از مجموعه نامزد کامل آغاز می‌شود. سپس به صورت تکراری نقاط را بین مجموعه انتخاب‌شده و مجموعه نامزد مبادله می‌کند، در صورتی که این مبادله منجر به افزایش دترمینان آرایه اطلاعات شود. این عمل اطمینان حاصل می‌کند که نقاط انتخاب‌شده در سرتاسر فضای چندبعدی عوامل (شامل دور موتور، فشار مؤثر متوسط ترمزی، زمان‌بندی درچه ورودی و زمان‌بندی درچه تخلیه) پخش شده و پایه‌ای مستحکم برای ساخت الگو فراهم می‌کنند.

برای پیاده‌سازی روش فدوروف، ابتدا یک شبکه نامزد شامل تمام ترکیبات مجاز چهار متغیر ورودی (دور موتور، BMEP، زمان‌بندی درچه ورودی و زمان‌بندی درچه خروجی) در محدوده‌های تعریف‌شده تولید شد. این مجموعه در مجموع شامل ۱۱۰۰ ترکیب بود که روش، زیرمجموعه‌های ۱۲/۵٪، ۲۵٪، ۳۳٪ و ۵۰٪ را از میان آن‌ها به‌عنوان نقاط آزمون انتخاب کرده است (به ترتیب ۱۳۷، ۲۷۵، ۳۶۳ و ۵۵۰ نقطه).

۲-۳- یادگیری رایانه‌ای

برای شناسایی روابط پیچیده و غیرخطی در مجموعه داده خود، از دو روش متفاوت یادگیری رایانه‌ای استفاده کردیم که به دلیل رویکردهای مکمل آنها در تشخیص الگو انتخاب شدند. روش اول یک پرسپترون چندلایه بود که به دلیل قابلیت ذاتی آن به عنوان یک تقریب‌زن جهانی توابع انتخاب شد. شبکه عصبی پرسپترون چندلایه با ساختار سلسله‌مراتبی خود قادر است الگوهای پیچیده داده را از طریق ترکیب توابع غیرخطی در لایه‌های متوالی استخراج و شبیه‌سازی کند. این ویژگی باعث می‌شود MLP در بازنمایی روابط چندبعدی میان ورودی‌ها و خروجی‌ها عملکرد مناسبی داشته باشد.

روش دوم، یک روش بردار پشتیبان با هسته غیرخطی بود که بر پایه اصول متفاوتی عمل می‌کند و با نداشت داده‌های ورودی به یک فضای ویژگی با ابعاد بالاتر، یک ابرصفحه جداسازی بهینه را پیدا می‌کند. به کارگیری این دو روش - یکی مبتنی بر الهام زیستی و یادگیری لایه‌ای و دیگری مبتنی بر تئوری آماری و ترفندهای هسته‌ای - با این هدف طراحی شد که اطمینان حاصل شود بینش‌های پیش‌بینی‌شده، کامل بوده و صرفاً حاصل یک رویکرد واحد نیستند. در جدول ۲ مشخصات و تفاوت‌های دو روش نشان داده شده‌اند.

جدول ۲ ویژگی روش‌ها

ویژگی	روش ۱	روش ۲
نوع روش	پرسپترون چند لایه	روش بردار پشتیبان
رویکرد اصلی	یادگیری لایه‌ای و تقریب تابع	بهینه‌سازی حاشیه و هسته غیرخطی
توانایی شبیه‌سازی غیرخطی	بسیار بالا (وابسته به ساختار شبکه)	بالا (به خصوص در نواحی با داده کم)
حساسیت به بیش‌برازش	بیشتر (در صورت عدم تنظیم شاخص)	کمتر (به ویژه در تعداد داده‌های کم)
هزینه محاسباتی	کمتر	بیشتر (در صورت تنظیم نوع kernel)
مناسب برای	متغیرهای با رفتار شدیداً غیرخطی	نواحی با تعداد نقاط کمتر

فرآیند توسعه هر دو روش با دقت بالا و به منظور اطمینان از تعمیم‌پذیری فراتر از مجموعه آموزشی انجام پذیرفت. برای پرسپترون چندلایه، ملاحظات حیاتی شامل طراحی توپولوژی شبکه - همچون تعداد لایه‌ها و واحدها - و پیکربندی فرآیند یادگیری برای جلوگیری از بیش‌برازش بود که از طریق روش‌های کنترل نویز و پیچیدگی در طول آموزش مدیریت شد. برای روش بردار پشتیبان، عملکرد روش به شدت به انتخاب هسته و متغیر تنظیم بستگی دارد که با دقت تنظیم شدند تا حاشیه جداسازی به حداکثر رسیده و در عین حال پایداری روش حفظ شود.

متغیرهای بکارگرفته شده برای پیش‌بینی رفتار سامانه شامل زمان‌بندی متغیر دریچه و هوا و دود در دور و بار مختلف است. زمان‌بندی متغیر دریچه هوا از ۰ تا ۶۰ به صورت ۱۵ درجه تغییر داده شده و زمان‌بندی متغیر دریچه دود از ۰ تا ۶۰- درجه به صورت ۱۵ درجه‌ای انجام شده‌است. زمان جرعه‌زنی برای اکثر نقاط آزمون در شرایط پیشینه گشتاور ترمزی تنظیم شده‌است و برای نقاط آزمون تمام بار و نزدیک آن با توجه به محدودیت‌های طراحی رعایت شده‌است.

۲-۳-۱- تنظیم شاخص‌ها

برای حصول اطمینان از عملکرد مطلوب روش، یک فرآیند بهینه‌سازی بیزی با استفاده از چارچوب نرم‌افزاری اجرا شد. نمونه‌بردار TPE برای پیمایش کارای فضای شاخص‌ها در طول ۱۵۰ دور آزمایش به کار گرفته شد. متغیرهای بهینه‌شده عبارت بودند از: حداکثر عمق درخت، نرخ یادگیری، تعداد پایه‌ترین تخمین‌زنده‌ها، نسبت نمونه‌های آموزشی استفاده‌شده در هر درخت و نسبت ویژگی‌های استفاده‌شده در هر درخت. در جدول ۳ شاخص‌های بهینه شده برای هر الگو برای هر شبیه‌سازی نشان داده شدند.

جدول ۳ شاخص‌های الگوهای بکارگرفته

شاخص‌های روش اول	شاخص‌های روش دوم
تعداد لایه‌های مخفی	نوع هسته
تعداد نوروها در هر لایه	C
تابع فعال‌ساز	γ در صورت استفاده از هسته RBF
نرخ یادگیر	ϵ
اندازه دسته	
تعداد دوره‌های آموزش	
بهینه‌ساز	

ارزیابی روش: ارزیابی روش‌ها با استفاده از روش تقسیم ۸۰ درصد از داده‌ها برای آموزش و ۲۰ درصد برای آزمون انجام پذیرفت. معیارهای اصلی سنجش عملکرد، خطای مربعات میانگین، خطای ریشه میانگین مربعات، خطای مطلق میانگین و R^2 بود که معیاری از دقت پیش‌بینی الگو بر روی داده‌های مشاهده‌نشده به دست می‌دهند. خطای مربعات میانگین به عنوان میانگین مربعات خطاها یا میانگین تفاضل مربع بین مقادیر برآوردی و مقادیر واقعی تعریف می‌شود.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (1)$$

که در آن Y_i مقادیر واقعی و $\hat{Y}_i$ مقادیر پیش‌بینی شده می‌باشند. خطای ریشه مربعات میانگین، ریشه دوم خطای مربعات میانگین است که در معادله ۲ نشان داده شده است:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (2)$$

خطای مطلق میانگین، میانگین مقادیر مطلق خطاها است:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (3)$$

مقدار R^2 نشان می‌دهد که داده‌ها چقدر به خط بازگشتی برازش شده نزدیک هستند. این معیار به صورت ریاضی به این شکل بیان می‌شود:


$$R^2 = \frac{\text{Explained Variation}}{\text{Total Variation}} = 1 - \frac{RSS}{TSS} \quad (4)$$

برای برآورد عدم قطعیت الگوها از روش Bootstrap استفاده شد. در این روش، مجموعه داده به طور مکرر با جایگزینی نمونه‌برداری شده ($B = 100$) و در هر تکرار الگو از ابتدا آموزش داده می‌شود. مجموعه پیش‌بینی‌های حاصل، توزیع آماری خروجی را تشکیل داده و انحراف معیار آن به عنوان عدم قطعیت و صدک‌های ۲/۵ درصدی و ۹۷/۵ درصدی به عنوان بازه اطمینان ۹۵ درصد محاسبه می‌شوند.

برنامه‌نویسی این مجموعه در زبان Python با استفاده از کتابخانه‌های pandas، numpy، scikit-learn، صورت گرفت. داده‌های ورودی اولیه در ۴ حالت ۱۲/۵٪، ۲۵٪، ۳۳٪ و ۵۰٪ برای هر دو نوع یادگیری رایانه‌ای استفاده شدند و مقایسه شدند.


۳- نتایج و بحث

این بخش مقایسه برای هر دو الگو در ۴ حالت با نقاط اولیه متفاوت انجام گرفت. برای تمامی این حالات RMSE و R^2 محاسبه شده و به عنوان معیار دقت هر دو روش مقایسه شدند. شکل نشان دهنده RMSE برای هر پیش‌بینی دو روش را در حالت ۱۲/۵٪ نقاط کل را مقایسه می‌کنند. همانطور که در شکل دیده می‌شود، دقت کلی روش دوم در این تعداد نقطه اولیه بیشتر از روش اول بوده و آشفتگی کمتری دارد. رفتاری مشابه در شکل ۲ که RMSE را برای داده‌های NOx نشان می‌دهد نیز قابل مشاهده است. با وجود شباهت میانگین خطای دو روش، بررسی دقیق‌تر نشان می‌دهد که روش دوم در برخی نقاط دورافتاده عملکرد ضعیف‌تری داشته و همین موضوع باعث افزایش خطای کلی آن شده است. این رفتار بیانگر حساسیت روش دوم به داده‌های کم یا نواحی شدیداً غیرخطی است.




شکل ۱ مقایسه خطای مربعات برای مصرف سوخت ویژه ترمزی هر دو روش در ۱۲/۵٪ نقاط


در شکل ۳ و ۴ همین مقایسه برای حالت دوم (۲۵٪ نقاط) انجام گرفته است. همانطور که در شکل ۳ دیده می‌شود، برای مصرف سوخت ویژه ترمزی دقت روش اول نسبت به حالت قبل و همچنین نسبت به روش دوم با افزایش نقاط اولیه ورودی بهتر شده است. مشکل بالا بودن خطا در نقاط تکین برای روش دوم با افزایش تعداد نقاط هنوز ادامه دارد. رفتاری وارونه در شکل ۴ در مقایسه پیش‌بینی اکسیدهای ازت دیده می‌شود. که نشانگر قابلیت بالای روش دوم در شبیه‌سازی داده‌های غیرخطی با تعداد داده پایین است. رفتار غیرخطی اکسیدهای ازت نسبت به مصرف سوخت ویژه ترمزی بیشتر بوده و دلیل اصلی بالاتر بودن دقت روش دوم همین امر است. در شکل‌های ۵، ۶ و ۷ نیز رفتارهای متفاوت دیده می‌شود با این تفاوت که مقدار دقت روش اول با افزایش تعداد نقاط بهتر از روش دوم می‌شود (هم برای مصرف سوخت ویژه و هم برای NOx).




شکل ۲ مقایسه خطای مربعات برای آلاینده‌های ازت (NOx) هر دو روش در ۱۲٫۵٪ نقاط




شکل ۳ مقایسه خطای مربعات برای مصرف سوخت ویژه ترمزی هر دو روش در ۲۵٪ نقاط




شکل ۴ مقایسه خطای مربعات برای NOx ترمزی هر دو روش در ۲۵٪ نقاط



شکل ۵ مقایسه خطای مربعات برای مصرف سوخت ویژه ترمزی هر دو روش در ۳۳٪ نقاط



شکل ۶ مقایسه خطای مربعات برای مصرف سوخت ویژه ترمزی هر دو روش در ۵۰٪ نقاط



شکل ۷ مقایسه خطای مربعات برای NOx ترمزی هر دو روش در ۵۰٪ نقاط

برای درک بهتر رفتار روش‌ها، توزیع خطای پیش‌بینی در فضای متغیرهای ورودی انجام گرفت و نتایج نشان داد که بیشترین مقادیر خطا در نواحی حدى فضای طراحی، یعنی ترکیب‌های با زمان‌بندی‌های دریچه‌ها با همپوشی بالا (Overlap) و همچنین در مقادیر مرزى دور موتور و BMEP رخ می‌دهد. در مقابل، در نواحی مرکزی نقشه کاری موتور، که تراکم بیشتری از نقاط آموزشی وجود دارد، خطاها کوچک‌تر و یکنواخت‌تر هستند. برای BSFC، الگوی خطا نسبتاً هموار بوده و عمدتاً در لبه‌های نقشه افزایش می‌یابد؛ در حالی که برای NOx و HC، وجود برخی نقاط بسیار غیرخطی در نواحی با همپوشی بالا باعث ایجاد قله‌های موضعی در خطای پیش‌بینی شده است. مقایسه چهار حالت ۱۲/۵٪ تا ۵۰٪ نشان می‌دهد که با افزایش تعداد نقاط اولیه، هم مقدار خطا و هم پراکندگی آن در فضای ورودی کاهش یافته و رفتار روش‌ها پایدارتر می‌شود.

در جداول ۴-۶ مقدار میانگین RMSE و R^2 برای تمامی حالت‌ها برای BSFC، NOx و HC نشان داده شده است. مقایسه نتایج بدست آمده نشان می‌دهد که در تعداد نقاط پایین‌تر روش دوم عملکرد بهتر و دقت بیشتری نسبت به روش اول برای تمامی متغیرهای هدف دارد. با افزایش تعداد نقاط روش اول رویکردی بهتر به خود می‌گیرد و به دقتی بهتر از روش دوم می‌رسد.

برای هر دو روش افزایش تعداد نقاط باعث افزایش دقت پیش‌بینی می‌شود، به دلیل غیرخطی بودن قابل توجه رفتار HC نسبت به BSFC و NOx، افزایش تعداد نقاط همیشه به کاهش خطا منجر نشده است. ورود برخی نقاط دورافتاده به مجموعه آموزشی باعث شده مقدار RMSE در روش دوم برای حالت ۳۳٪ نسبت به ۲۵٪ افزایش پیدا کند.

جدول ۴ مقدار میانگین ریشه مربعات برای BSFC برای تمامی حالات

نوع مشخصه	میانگین RMSE	میانگین R^2
روش اول با ۵۰٪ نقطه	26.43 ± 0.66	$99.3\% \pm 0.2\%$
روش اول با ۳۳٪ نقطه	33.44 ± 1.34	$99.0\% \pm 0.3\%$
روش اول با ۲۵٪ نقطه	35.61 ± 2.14	$98.8\% \pm 0.5\%$
روش اول با ۱۲/۵٪ نقطه	58.88 ± 5.89	$97.2\% \pm 0.8\%$
روش دوم با ۵۰٪ نقطه	26.74 ± 0.68	$99.3\% \pm 0.2$
روش دوم با ۳۳٪ نقطه	35.34 ± 1.42	$99.0\% \pm 0.3$
روش دوم با ۲۵٪ نقطه	37.74 ± 2.27	$98.7\% \pm 0.5$
روش دوم با ۱۲/۵٪ نقطه	49.14 ± 4.92	$97.9\% \pm 0.7$

جدول ۵ مقدار میانگین ریشه مربعات برای NOx برای تمامی حالات

نوع مشخصه	میانگین RMSE	میانگین R^2
روش اول با ۵۰٪ نقطه	510.33 ± 25.52	$96.2\% \pm 0.4\%$
روش اول با ۳۳٪ نقطه	610.92 ± 42.76	$94.0\% \pm 0.7\%$
روش اول با ۲۵٪ نقطه	754.33 ± 67.89	$90.0\% \pm 1.1\%$
روش اول با ۱۲/۵٪ نقطه	873.55 ± 104.83	$83.3\% \pm 1.6\%$
روش دوم با ۵۰٪ نقطه	557.04 ± 27.85	$95.9\% \pm 0.4\%$
روش دوم با ۳۳٪ نقطه	635.19 ± 44.46	$94.3\% \pm 0.7\%$
روش دوم با ۲۵٪ نقطه	642.80 ± 57.85	$91.6\% \pm 1\%$
روش دوم با ۱۲/۵٪ نقطه	828.21 ± 99.38	$84.7\% \pm 1.5\%$

جدول ۶ مقدار میانگین ریشه مربعات برای HC برای تمامی حالات

نوع مشخصه	میانگین RMSE	میانگین R^2
روش اول با ۵۰٪ نقطه	363.63 ± 14.55	$91.5\% \pm 0.6\%$
روش اول با ۳۳٪ نقطه	516.10 ± 30.96	$88.6\% \pm 0.8\%$
روش اول با ۲۵٪ نقطه	558.98 ± 44.72	$82.3\% \pm 1.2\%$
روش دوم با ۵۰٪ نقطه	457.03 ± 18.28	$89.9\% \pm 0.7\%$
روش دوم با ۳۳٪ نقطه	515.56 ± 36.08	$86.9\% \pm 0.9\%$
روش دوم با ۲۵٪ نقطه	514.56 ± 41.24	$87.5\% \pm 1.1\%$

برای پیش‌بینی BSFC هر دو روش با تعداد نقاط کمتری پیش‌بینی‌های قابل قبولی دارند ولی برای تخمین آلایندگی و پیش‌بینی رفتار غیرخطی بالای آن‌ها تعداد نقاط و همچنین دقت شبیه‌سازی و بهینه‌سازی شاخص‌های روش‌ها ملزوم است. علی‌رغم دقت بالای روش دوم، سرعت انجام شبیه‌سازی و یادگیری توسط این روش نسبت به روش اول نزدیک به ۵ برابر است که در تعداد متغیرهای بالاتر و تعداد داده‌های بالاتر می‌تواند هزینه انجام عملیات را به شدت بالا ببرد.

تحلیل عدم قطعیت روش‌ها نشان داد که میزان نوسان پیش‌بینی‌ها ارتباط مستقیم با حجم داده‌های آموزشی و ماهیت فیزیکی متغیر مورد پیش‌بینی دارد. برای BSFC، که رفتار نسبتاً هموار و وابستگی شبه‌خطی‌تری به متغیرهای کنترلی دارد، پراکندگی نتایج Bootstrap محدود بوده و عدم قطعیت در بازه ۰/۲ تا ۰/۸ درصد برای R^2 مشاهده شد. این روند نشان می‌دهد که با افزایش تعداد نقاط طرح‌آزمون، روش به‌طور پایدار روابط ورودی-خروجی را فرا می‌گیرد.

در مقابل، مقادیر NOx به دلیل ماهیت شدیداً غیرخطی، وابستگی به دما، مراحل احتراق و حساسیت بالا به تغییرات زمان‌بندی دریچه‌ها، نوسان بیشتری در بین تکرارهای Bootstrap نشان می‌دهد. عدم قطعیت R^2 برای NOx در بازه بزرگ‌تری (۰/۴ تا ۱/۶ درصد) قرار گیرد. افزایش محسوس عدم قطعیت در مقادیر ۲۵٪ و ۱۲/۵٪ داده بیانگر آن است که روش در نواحی حدی نقشه و شرایط کم‌داده، پایداری کمتری دارد. از آن‌جا که تولید HC تحت تأثیر پدیده‌های موضعی مانند سوخت‌نسوخته، نواحی سرد و wall-wetting است، شبیه‌سازی آن دشوارتر است. این موضوع در نتایج Bootstrap نیز منعکس شده و عدم قطعیت R^2 در محدوده ۰/۶ تا ۱/۲ درصد قرار گرفته است. بنابراین، روند افزایش عدم قطعیت در HC نیز کاملاً با افزایش پیچیدگی فیزیکی و کاهش حجم داده سازگار است.

به‌طور کلی، مقایسه سه کمیت BSFC، NOx و HC نشان می‌دهد که هرچه رفتار متغیر خروجی غیرخطی‌تر و پراکندگی ذاتی آن بیشتر باشد، توزیع Bootstrap پهن‌تر و عدم قطعیت نهایی بزرگ‌تر خواهد بود.

نهایتاً جدول ۷ میزان میانگین خطای پیش‌بینی BSFC را برای داده‌های غیر آموزشی با مقادیر واقعی BSFC نشان می‌دهد. این نتایج نشان می‌دهد که با تعداد ۳۳ درصد نقاط مورد استفاده خطای پیش‌بینی به حتی کمتر از ۱ درصد در کل بازه آزمون نیز می‌رسد. همچنین روش دوم برای این تعداد داده‌ها روش مناسب‌تری است.

جدول ۷ مقدار میانگین خطای پیش‌بینی برای مصرف سوخت ویژه ترمزی برای هر دو روش

درصد نقاط انتخابی	میانگین خطای BSFC (%)
روش اول با ۵۰٪ نقطه	0.53%
روش اول با ۳۳٪ نقطه	0.94%
روش اول با ۲۵٪ نقطه	1.10%
روش دوم با ۵۰٪ نقطه	0.58%
روش دوم با ۳۳٪ نقطه	0.98%
روش دوم با ۲۵٪ نقطه	1.22%

۴- نتیجه‌گیری

این پژوهش به صورت تجربی و کمی اثر بخشی یک تغییر پارادایم در فرآیند نگاشت موتورهای احتراق داخلی از روش‌های صرفاً آزمایشگاهی وقت‌گیر و پرهزینه به سمت رویکردهای داده‌محور و هوشمند گام بر می‌دارد. یافته‌های کلیدی زیر، که همگی از پشتیبانی آماری قوی برخوردارند، گواه این ادعا هستند:

- قابلیت یادگیری رایانه‌ای در شبیه‌سازی پدیده‌های پیچیده: نتایج به وضوح نشان داد که روش‌های اول و دوم توانایی یادگیری روابط غیرخطی و تعاملات پیچیده بین متغیرهای کنترلی موتور و خروجی‌های عملکردی BSFC و NOx را با دقت قابل توجه (به ترتیب $R^2 > 99\%$ و 95%) دارند. این سطح از دقت در صورت تلفیق با داده‌های آزمایشگاه معتبر می‌تواند زمینه‌ساز توسعه روش‌ها و فرآیندهای نوین در بهینه‌سازی موتور باشد. این روش‌ها به تدریج می‌توانند به ابزاری قابل اعتماد و قدرتمند برای روش‌های ساده‌تر پاسخ سطح و تلفیق با فرآیندهای تجربی تبدیل شوند.
- تأثیر حیاتی حجم داده و انتخاب روش: در مراحل اولیه توسعه و با حجم داده محدود (کمتر از 25%)، روش دوم به دلیل مقاومت در برابر بیش‌برازش، گزینه مناسب‌تری به ویژه برای متغیرهای با رفتار غیرخطی مانند NOx و HC محسوب می‌شود. با افزایش داده‌ها به $33-50\%$ ، هر دو روش به دقت بالاتری دست می‌یابند روش اول نیز عملکرد قابل قبولی نشان می‌دهد. با این حال، با توجه به خطای نسبی روش‌ها در پیش‌بینی آلاینده‌ها، لازم است نتایج نهایی پیش از به کارگیری، از طریق آزمون‌های تجربی مستقلی اعتبارسنجی شوند و نمی‌توان صرفاً به خروجی روش برای انتخاب نقاط نهایی اکتفا کرد.

جمع‌بندی نهایی و چشم‌انداز آینده: این مطالعه نشان می‌دهد که حرکت به سمت ابزارهای یادگیری رایانه‌ای، اگرچه هنوز در مراحل اولیه قرار دارد، اما ظرفیت قابل توجهی برای پیشبرد مهندسی نگاشت هوشمند در آینده دارد. با توجه به پیچیدگی روزافزون موتورهای مدرن (مانند سامانه‌های تزریق مستقیم و جداول کنترلی گسترده) که نگاشت صرفاً مبتنی بر آزمون را به چالشی بزرگ تبدیل کرده است، به کارگیری این روش‌ها به ضرورتی اجتناب ناپذیر تبدیل خواهد شد. یکی از محدودیت‌های مهم این پژوهش آن است که تمام تحلیل‌ها بر اساس داده‌های یک موتور مشخص و در بازه محدودی از سرعت و بار انجام شده است. بنابراین، اگرچه نتایج به‌خوبی نشان‌دهنده ظرفیت روش ترکیبی DoE-ML در کاهش تعداد آزمون‌ها و حفظ دقت پیش‌بینی هستند، اما برای تعمیم‌پذیری کامل این رویکرد لازم است در مطالعات آتی، از داده‌های متنوع‌تر شامل شرایط عملیاتی گسترده‌تر، انواع سوخت مختلف و حتی موتورهای با معماری دیگر نیز استفاده شود. اعتبارسنجی بین‌موتوری و بین‌نقشه‌ای می‌تواند تصویر دقیق‌تری از میزان پایداری و اعتمادپذیری روش‌ها ارائه دهد. اگرچه دقت روش‌های یادگیری رایانه‌ای در پیش‌بینی آلاینده‌ها هنوز به سطح مورد نیاز برای جایگزینی کامل آزمون‌های تجربی نرسیده است، اما نتایج این مطالعه نشان می‌دهد که این روش‌ها می‌توانند به‌عنوان یک ابزار کمکی قدرتمند در فرآیند نگاشت به کار گرفته شوند. کاهش تعداد آزمایش‌های لازم و توانایی روش‌ها در شناسایی الگوهای غیرخطی، مهم‌ترین مزیت‌های این رویکرد هستند. تلفیق هوشمندانه طرح آزمون بهینه، روش‌های یادگیری رایانه‌ای و داده‌های تجربی، می‌تواند در آینده به یک راهبرد نوین تبدیل شود که فرآیند بهینه‌سازی موتور را به شکل قابل توجهی بهبود دهند. برای پژوهش‌های آتی، گسترش این چارچوب به سایر آلاینده‌های کلیدی مانند دوده و ادغام آن با روش‌های بهینه‌سازی چند هدفه برای یافتن بهترین توازن عملی بین معیارهای متضاد، پیشنهاد می‌شود.

فهرست علائم

BSFC

CFD

مصرف سوخت ویژه ترمزی

دینامیک سیالات محاسباتی

<i>CNN</i>	عصبی پیچشی عمیق
<i>CO</i>	مونواکسید کربن
<i>EGR</i>	بازخورانی گاز خروجی
<i>GA</i>	روش وراثت
<i>GCI</i>	احتراق تراکمی بنزینی
<i>ICE</i>	موتور احتراق داخلی
<i>MAE</i>	خطای مطلق میانگین
<i>MSE</i>	خطای مربعات میانگین
<i>NO_x</i>	اکسیدهای ازت
<i>OFAT</i>	یک متغیر نگاشت در هر مرحله
<i>PCA</i>	تحلیل مؤلفه‌های اصلی
<i>PCCI</i>	مخلوط اولیه پیش‌مخلوط
<i>PPRR</i>	نرخ افزایش فشار بیشینه
<i>RMSE</i>	خطای ریشه مربعات میانگین
<i>RSM</i>	روش‌های سطح پاسخ
<i>SVM</i>	روش بردار پشتیبان
<i>UHC</i>	هیدروکربن‌های نسوخته

References

- [1] Mobil E. Outlook for Energy: A View to 2040. 2018.
- [2] Birol F. International Energy Outlook 2018. 2018.
- [3] Kalghatgi GT. The outlook for fuels for internal combustion engines. *International Journal of Engine Research*. 2014 Jun;15(4):383-98.
- [4] Gadonneix P, Sambo A, Tie'nan L, Choudhury AR, Teyssen J, Lleras JA, Naqi AA, Meyers K, Shin HC, Nadeau MJ, Morris M. Global transport scenarios 2050. *World Energy Council*. 2011;456.
- [5] Paoli L, Gül T. Electric cars fend off supply challenges to more than double global sales. *International Energy Agency [Internet]*. 2022.
- [6] Badra J, Viollet Y, Elwardany A, Im HG, Chang J. Physical and chemical effects of low octane gasoline fuels on compression ignition combustion. *Applied Energy*. 2016 Dec 1;183:1197-208. doi: 10.1016/j.apenergy.2016.09.060
- [7] Vallinayagam R, An Y, Vedharaj S, Sim J, Chang J, Johansson B. Naphtha vs. diesel line—The effect of fuel properties on combustion homogeneity in transition from CI combustion towards HCCI. *Fuel*. 2018 Jul 15;224:451-60. doi: 10.1016/j.fuel.2018.03.123
- [8] Badra J, Zubail A, Sim J. Numerical investigation into effects of fuel physical properties on GCI engine performance and emissions. *Energy & fuels*. 2019 Sep 17;33(10):10267-81. doi: 10.1021/acs.energyfuels.9b02340
- [9] Jiang C, Huang G, Liu G, Qian Y, Lu X. Optimizing gasoline compression ignition engine performance and emissions: Combined effects of exhaust gas recirculation and fuel octane number. *Applied Thermal Engineering*. 2019 May 5;153:669-77. doi: 10.1016/j.applthermaleng.2019.03.054
- [10] Badra J, Khaled F, Sim J, Pei Y, Viollet Y, Pal P, Futterer C, Brenner M, Som S, Farooq A, Chang J. Combustion system optimization of a light-duty GCI engine using CFD and machine learning. In *WCX SAE World Congress Experience 237384* 2020 Apr 14. doi: 10.4271/2020-01-1313
- [11] Badra J, Khaled F, Tang M, Pei Y, Kodavasal J, Pal P, Owoyele O, Fuetterer C, Brenner M, Farooq A. Engine combustion system optimization using CFD and machine learning: a methodological approach. In *Internal combustion engine division fall technical conference 2019 Oct 20 (Vol. 59346, p. V001T06A007)*. American Society of Mechanical Engineers. doi: 10.1115/ICEF2019-7238

- [12] Mohan B, Tang M, Badra J, Pei Y, Traver M. Machine learning and response surface-based numerical optimization of the combustion system for a heavy-duty gasoline compression ignition engine. SAE Technical Paper; 2021 Apr 6.
- [13] Mohan B, Yang W, Kiang Chou S. Fuel injection strategies for performance improvement and emissions reduction in compression ignition engines—A review. Renewable and Sustainable Energy Reviews. 2013 Dec 1;28:664-76. doi: 10.1016/j.rser.2013.08.051
- [14] Badra JA, Sim J, Elwardany A, Jaasim M, Viollet Y, Chang J, Amer A, Im HG. Numerical simulations of hollow-cone injection and gasoline compression ignition combustion with naphtha fuels. Journal of Energy Resources Technology. 2016 Sep 1;138(5):052202. doi: 10.1115/1.4032622
- [15] Sim J, Badra J, Elwardany A, Im H. Spray modeling for outwardly-opening hollow-cone injector. InSAE 2016 World Congress and Exhibition 2016 Apr 5. SAE Technical Paper. doi: 10.4271/2016-01-0844
- [16] Badra J, Elwardany A, Sim J, Viollet Y, Im H, Chang J. Effects of in-cylinder mixing on low octane gasoline compression ignition combustion. InSAE 2016 World Congress and Exhibition 2016 Apr 5. SAE Technical Paper.
- [17] Badra JA, Sim J, Viollet Y, Zhang Y, Engineer N, Chang J. CFD guided gasoline compression ignition engine calibration. InInternal combustion engine division fall technical conference 2017 Oct 15 (Vol. 58325, p. V002T06A012). American Society of Mechanical Engineers. doi: 10.1115/ICEF2017-3583
- [18] Atef N, Badra J, Jaasim M, Im HG, Sarathy SM. Numerical investigation of injector geometry effects on fuel stratification in a GCI engine. Fuel. 2018 Feb 15;214:580-9. doi: 10.1016/j.fuel.2017.11.036
- [19] Badra J, Alhussaini A, Sim J, Viollet Y, Amer A. Parametric Study to Optimize Gasoline Compression Ignition Operation under Low Load Condition Using CFD. SAE Technical Paper; 2021 Apr 6.
- [20] Sim J, Chang J, Badra J. CFD-guided optimization of the injector and injection parameters for light-duty GCI engine. Fuel. 2022 May 15;316:123389. doi: 10.1016/j.fuel.2022.123389
- [21] Tang Q, An Y, Raman V, Shi H, Sim J, Chang J, Magnotti G, Johansson B. Experimental study on the effects of spray-wall interaction on partially premixed combustion and engine emissions. Energy & Fuels. 2019 May 1;33(6):5673-81. doi: 10.1021/acs.energyfuels.9b00602
- [22] Mohan B, Mubarak Ali MJ, Ahmed A, Hernandez Perez F, Sim J, Roberts W, Sarathy M, Im H. Numerical simulations of high reactivity gasoline fuel sprays under vaporizing and reactive conditions. InWCX World Congress Experience 237382 2018 Apr 3. doi: 10.4271/2018-01-0292
- [23] Zhang Y, Pei Y, Engineer N, Cho K, Cleary D. CFD-guided combustion strategy development for a higher reactivity gasoline in a light-duty gasoline compression ignition engine. InWCX™ 17: SAE World Congress Experience 2017 Mar 28. SAE Technical Paper.
- [24] Mohammadi A, Montazer Y, Rahimi Asiabarak H. Reduction of fuel consumption and emissions of Iranian naturally aspirated engine on Samand vehicle with thermal management. The Journal of Engine Research. 2025 Feb 19;71(4):58-76. doi: 10.22034/er.2025.2053701.1077 [In Persian]
- [25] Asef A, Ajami Kashani N, Parivar A, Zakeri E, Mohsenirad M. Conceptual and experimental study of an Atkinson cycle engine of a Series-Parallel hybrid electric vehicle. The Journal of Engine Research. 2024 Feb 20;70(4):69-80. doi: 10.22034/er.2024.2025131.1041 [In Persian]
- [26] Pei Y, Pal P, Zhang Y, Traver M, Cleary D, Futterer C, Brenner M, Probst D, Som S. CFD-guided combustion system optimization of a gasoline range fuel in a heavy-duty compression ignition engine using automatic piston geometry generation and a supercomputer. SAE International Journal of Advances and Current Practices in Mobility 270091. 2019 Jan 15;1(1):166-79.
- [27] Styron JP. Using model-based calibration toolbox multimodels for cycle-optimized diesel calibration. InMathWorks Automotive Conference 2008 Dec 27.
- [28] Jiang S, Nutter D, Gullitti A. Implementation of model-based calibration for a gasoline engine. SAE Technical Paper; 2012 Apr 16.
- [29] Franzke B, Schloßhauer A, Lückmann D, Thewes M. Variable Turbine Geometry Additional Degree of Freedom for CO2 Reduction. MTZ worldwide. 2017 Oct;78(10):36-41. doi: 10.1007/s38313-017-0101-2
- [30] Huber T, Kruse T, Lauff U. Modellbasierte Applikation. Hanser automotive. 2013(10):33-5.
- [31] Cho Y, Huber T, Lauff U, Reddy R. Optimisation of gasoline engines automation and machine

- learning techniques in calibration. *ATZelektronik worldwide*. 2017 Jun;12(3):48-53. doi: [10.1007/s38314-017-0031-4](https://doi.org/10.1007/s38314-017-0031-4)
- [32] Kuder J, Kruse T, Wülfers S, Stuber A, Gschweidl K, Lick P, Fürhapter A. Calibrating bosch motronic systems. *MTZ worldwide*. 2003 Dec;64(12):15-8. doi: [10.1007/BF03227636](https://doi.org/10.1007/BF03227636)
- [33] Schoeggl P, Koegeler HM, Gschweidl K, Kokal H, Williams P, Hulak K. Automated EMS calibration using objective driveability assessment and computer aided optimization methods. In *SAE 2002 World Congress & Exhibition 2002 Mar 4*. SAE International. doi: [10.4271/2002-01-0849](https://doi.org/10.4271/2002-01-0849)
- [34] Badra J, Pal P, Pei Y, Som S, editors. *Artificial intelligence and data driven optimization of internal combustion engines*. Elsevier; 2022 Jan 5.
- [35] Moiz AA, Pal P, Probst D, Pei Y, Zhang Y, Som S, Kodavasal J. A machine learning-genetic algorithm (ML-GA) approach for rapid optimization using high-performance computing. *SAE International journal of commercial vehicles*. 2018 Apr 3;11(2018-01-0190):291-306.
- [36] Maran JP, Priya B. Comparison of response surface methodology and artificial neural network approach towards efficient ultrasound-assisted biodiesel production from muskmelon oil. *Ultrasonics Sonochemistry*. 2015 Mar 1;23:192-200. doi: [10.1016/j.ultsonch.2014.10.019](https://doi.org/10.1016/j.ultsonch.2014.10.019)
- [37] Togun N, Baysec S. Genetic programming approach to predict torque and brake specific fuel consumption of a gasoline engine. *Applied Energy*. 2010 Nov 1;87(11):3401-8. doi: [10.1016/j.apenergy.2010.04.027](https://doi.org/10.1016/j.apenergy.2010.04.027)
- [38] Rahimi-Gorji M, Ghajar M, Kakaee AH, Domiri Ganji D. Modeling of the air conditions effects on the power and fuel consumption of the SI engine using neural networks and regression. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*. 2017 Feb;39(2):375-84. doi: [10.1007/s40430-016-0539-1](https://doi.org/10.1007/s40430-016-0539-1)
- [39] Waley A, Gao J, Grover R. Prediction of engine-out emissions using deep convolutional neural networks. *SAE International Journal of Advances and Current Practices in Mobility* 288440. 2021 Apr 6;3(6):2863-71.
- [40] Pan W, Korkmaz M, Beeckmann J, Pitsch H. Nonlinear identification modeling for PCCI engine emissions prediction using unsupervised learning and neural networks. In *WCX SAE World Congress Experience 2020 Apr 14*. SAE Technical Paper.
- [41] AlRamadan AS, Al Ibrahim Z, Mohan B, Badra J. Machine learning model for spark-assisted gasoline compression ignition engine. *SAE International Journal of Advances and Current Practices in Mobility*. 2022 Mar 29;5(2022-01-0459):509-16.