Semnan University

Journal of Modeling in Engineering

Journal homepage: https://modelling.semnan.ac.ir/

ISSN: 2783-2538



Research Article

Prediction of Emissions from a Dual-Fuel Compression Ignition Engine Using a Deep Convolutional Neural Network

Farnaz Hoseini [a,*], **Yasser Niknam** [b]

[a] *Department of Computer Engineering, Technical and Vocational University (TVU), Tehran, Iran*
[b] *Department of Mechanical Engineering, Technical and Vocational University (TVU), Tehran, Iran*

UNCORRECTED PROOF

PAPER INFO

Paper history:

Received: 2024-00-00
Revised: 2024-00-00
Accepted: 2024-00-00

Keywords:

Convolutional Neural Network; DCNN; Compression Ignition Engine; Nitrogen Oxide; Dual-Fuel Engine.

ABSTRACT

One of the promising approaches to reducing pollutant emissions in diesel engines is the application of dual-fuel combustion using compressed natural gas (CNG) alongside diesel fuel. In this study, a conventional compression ignition (CI) engine (MT440C model) was structurally modified to operate under a dual-fuel mode without the need for a spark-ignition system. The primary objective is to investigate the feasibility of using CNG in CI engines and to compare key operational and emission characteristics—including engine power output and exhaust emissions—under different engine speeds (1200, 1400, 1600, 1800, and 2000 rpm). To enable accurate and real-time prediction of nitrogen oxides (NOx) emissions, a novel deep convolutional neural network (DCNN) architecture was proposed. The model is designed to extract high-dimensional temporal-spatial features from the multi-variable time-series dataset and model complex nonlinear dependencies in dual-fuel combustion. Experimental results demonstrate superior predictive performance, achieving a root mean square error (RMSE) of 21.70 and a coefficient of determination (R^2) of 0.997, significantly outperforming existing baseline models in the literature. The outstanding accuracy and robustness of the proposed DCNN model underscore its applicability for integration into real-time smart engine control systems aimed at optimizing emissions in hybrid combustion platforms.

DOI: https://doi.org//

© 2024 Published by Semnan University Press.
This is an open access article under the CC-BY 4.0 license.(https://creativecommons.org/licenses/by/4.0/)

مقاله پژوهشی

*** Corresponding author.**
E-mail address: f-hoseini@tvu.ac.ir

How to cite this article:

پیش‌بینی میزان آلاینده‌های خروجی از یک موتور احتراق تراکمی دوگانه‌سوز با استفاده از شبکه عصبی کانولوشنی عمیق

فرناز حسینی[۱،*]، یاسر نیکنام[۲]

اطلاعات مقاله

دریافت مقاله: ۱۴۰۳/۰۰/۰۰
بازنگری مقاله: ۱۴۰۳/۰۰/۰۰
پذیرش مقاله: ۱۴۰۳/۰۰/۰۰

واژگان کلیدی:
شبکه عصبی کانولوشنی عمیق، DCNN، موتور احتراق تراکم، اکسید نیتروژن، موتور دوگانه سوز.

چکیده

یکی از رویکردهای نوین و کارآمد در کاهش آلایندگی موتورهای دیزلی، بهره‌گیری از فناوری احتراق دوگانه‌سوز (دیزل–گاز طبیعی فشرده، CNG) است. در این پژوهش، یک موتور احتراق تراکمی مدل MT440C با اصلاحات ساختاری به‌صورت دوگانه‌سوز طراحی و پیاده‌سازی گردید تا عملکرد حرارتی و زیست‌محیطی آن مورد ارزیابی قرار گیرد. هدف اصلی مطالعه، تحلیل رفتار احتراقی و بررسی دقیق الگوی انتشار آلاینده‌های خروجی، به‌ویژه اکسیدهای نیتروژن (NOx)، در پنج سرعت عملکردی (۱۲۰۰، ۱۴۰۰، ۱۶۰۰، ۱۸۰۰ و ۲۰۰۰ دور بر دقیقه) تحت شرایط پایدار عملیاتی است. جهت پیش‌بینی دقیق و بلادرنگ میزان NOx، یک معماری نوآورانه یادگیری عمیق مبتنی بر شبکه عصبی کانولوشنی عمیق (DCNN) توسعه داده شد. این مدل، ضمن استخراج ویژگی‌های پیچیده از داده‌های چندبُعدی و سری‌زمانی، قادر به مدل‌سازی دقیق روابط دینامیکی در فرآیند احتراق ترکیبی است. نتایج تجربی حاصل از پیاده‌سازی مدل پیشنهادی حاکی از دقت پیش‌بینی بسیار بالا با ضریب تعیین R^2 معادل ۰.۹۹۷ و خطای RMSE معادل ۲۱.۷۰ است که به‌طور معناداری از تمامی مدل‌های مقایسه‌ای موجود در ادبیات پیشین دقیق‌تر عمل کرده است. کارایی بالای مدل پیشنهادی، نه‌تنها در کاهش پیچیدگی محاسباتی بلکه در افزایش دقت پیش‌بینی و تعمیم‌پذیری آن، پتانسیل بالای این روش را برای استقرار در سامانه‌های کنترل هوشمند بلادرنگ در موتورهای احتراق داخلی دوگانه‌سوز به‌وضوح نمایان می‌سازد.

DOI: https://doi.org/ /

© 2024 Published by Semnan University Press.
This is an open access article under the CC-BY 4.0 license.(https://creativecommons.org/licenses/by/4.0/)

UNCORRECTED PROOF

۱-مقدمه[۱]

امروزه جهان با بحران منابع انرژی مواجه است و منابع محدود سوخت‌های فسیلی (سنگواره‌ای) قادر به پاسخگویی به تقاضای رو به افزایش انرژی نمی‌باشند [۱]. این مسأله با افزایش قیمت سوخت‌های فسیلی و آلودگی زیست محیطی مواجه است که محققان را به جستجوی منابع جایگزین انرژی که تجدیدپذیر، ایمن و غیرآلوده باشند ترغیب می‌کند [۲]. در حال حاضر موتورهای دیزل که نقشی اساسی در تأمین نیروی محرکه‌ی خودروهای جاده‌ای و غیر جاده‌ای دارند، به عنوان یکی از اصلی‌ترین مصرف کننده‌های سوخت فسیلی به حساب می‌آیند [۳]. این موتورها خود یکی از عوامل مهم ایجاد کننده آلودگی‌های صوتی و زیست محیطی می‌باشند [۴]. استفاده از سوخت‌های متنوع در موتورهای دیزل باعث شده تا این دسته از موتورها به صورت دوگانه سوز مورد استفاده قرار گیرند. کاهش آلایندگی و مصرف سوخت کمتر، از ویژگی‌های موتورهای دیزل دوگلنه سوزی است که از ترکیب گاز-دیزل بهره می‌گیرند [۵]. موتورهای دیزل کاربردهای مختلفی در صنعت و کشاورزی دارند. توسعه به کارگیری آنها در شرایط مختلف باعث شده تا مطالعات

* پست الکترونیک نویسنده مسئول: f-hoseini@tvu.ac.ir
۱. گروه مهندسی کامپیوتر، دانشگاه ملی مهارت، تهران، ایران
۲. گروه مهندسی مکانیک، دانشگاه ملی مهارت، تهران، ایران

گسترده‌ای روی این دسته از موتورها انجام شود [۶]. پیچیدگی پدیده خود اشتعالی و همچنین معضلات انتشار آلایندگی، موجب شده تا کارکرد موتورهای دیزل در قالب پارامترهای عملکردی و انتشار آلایندگی مورد توجه محققان قرار گیرد. امروزه به کارگیری موتورهای دیزل دوگانه سوز در بالا بردن کیفیت اشتعال[۲] (احتراق یا جرقه‌زنی)، پارامترهای عملکردی و کاهش آلایندگی مؤثر واقع شده است. از جمله سوخت‌های گازی که قابلیت استفاده در موتورهای دیزل دوگانه سوز را داراست، گاز فشرده طبیعی (CNG[۳]) است [۷]. نظر به قوانین زیست محیطی، اثرات مخرب آلاینده‌های زیست محیطی، گران قیمت بودن و فرآوری پر هزینه‌ی سوخت‌های معمول مانند دیزل و بنزین، استفاده از گاز طبیعی به خصوص در کشور ایران که از منابع غنی گاز برخوردار است و قیمت ارزان‌تری دارد بسیار مورد توجه و تحقیق است [۸]. در موتورهای اشتعال جرقه‌ای (SI[۴]) به دلیل اشتعال مخلوط سوخت و هوا به واسطه‌ی جرقه‌زنی، گاز طبیعی به راحتی قابل استفاده است؛ اما در موتورهای اشتعال تراکمی (CI[۵]) به دلیل عدد بالای اکتانِ گاز طبیعی و عدم وجود جرقه‌زنی، برای اشتعال خود به خودی گاز طبیعی نیاز به نسبت‌های تراکم بالا می‌باشد. به کارگیری سوخت گاز طبیعی در موتورهای اشتعال جرقه‌ای سال‌هاست که مرحله‌ی تحقیق و توسعه‌ی خود را سپری کرده و هم اینک به طور وسیعی در برخی کشورها از جمله ایران بر روی موتورهای احتراقی به کار می‌رود [۹]. با این حال استفاده از سوخت گاز طبیعی در موتورهای اشتعال تراکمی بدون به کارگیری سامانه‌ی جرقه‌زنی مراحل پژوهشی خود را طی می‌کند و هنوز به طور وسیع به مرحله‌ی صنعتی شدن نرسیده است. در موتورهای اشتعال جرقه‌ای یا اصطلاحا موتورهای بنزینی به دلیل تراکم کمترِ اینگونه موتورها، جایگزینی کامل سوخت بنزین با گاز امکان پذیر است. با در نظر گرفتن این نکته که به دلیل بالابودن عدد اکتان گاز طبیعی (عدد اکتان گاز متان حدود ۱۳۰بوده، در حالیکه این عدد برای بنزین بدون سرب حدود ۸۵ می‌باشد) برای اشتعال مخلوط گاز با هوا همچنان نیاز به جرقه الکتریکی خواهد بود [۱۰]. از طرفی با توجه به ضریب تراکم نسبتاً پایین اینگونه موتورها (بین ۸ تا ۱۳) می‌توان از ایمنی جایگزینی سوخت بنزین با گاز با اعمال تغییرات جزئی در موتور مطمئن بود. اما در موتورهای اشتعال تراکمی نمی‌توان سوخت دیزل (گازوئیل) را به طور کامل با سوخت گاز جایگزین کرد؛ چرا که این موتورها دارای سیستم جرقه‌زنی الکتریکی نبوده و از تزریق سوخت دیزل با فشار بالا به درون هوای فشرده برای آغاز اشتعال استفاده می‌کنند. بنابراین در بهترین شرایط نیز در یک موتور اشتعال تراکمی دوگانه سوز نیاز به تزریق درصدی سوخت دیزل به درون مخلوط فشرده شده‌ی گاز و هوا خواهد بود. از جمله مشکلات مربوط به استفاده از سوخت گاز طبیعی در موتورهای اشتعال تراکمی رایج، هزینه‌ی بالای تبدیل این موتورها به یک موتور اشتعال جرقه‌ای می‌باشد [۱۱]. این تبدیل نیازمند به‌کارگیری اجزای سامانه‌ی جرقه‌زنی نظیر کوئل، دلکو، وایر و شمع در سامانه‌های پاشش الکترونیکی، پردازنده‌ها و حسگرهای مربوطه بوده و تغییرات سرسیلندر و نصب شمع در آن نیز کاری نسبتا دشوار است. سوخت دیزل در مقایسه با دیگر سوخت‌های قابل استفاده در موتورهای اشتعال تراکمی دارای عدد سیتان (CN[۶]) کمتر، مصرف انرژی چاه تا چرخ[۷] کمتر و میزان انتشار مونوکسید کربن (CO) و هیدروکربن (HC) نسبتاً پایین می‌باشد، اما میزان انتشار اکسید نیتروژن (NO_X[۸]) و ذرات معلق چاه تا چرخ آن بالاست [۱۲]. عدد سیتان اندازه‌گیری نسبی زمان تاخیر بین تزریق سوخت به محفظه احتراق و شروع احتراق است. نسبت چاه به چرخ نیز روشی برای تجزیه و تحلیل مبتنی بر چرخه عمر موتورهای اشتعال تراکمی می‌باشد [۱۳]. با توجه به اینکه فرمول مولکولی گاز طبیعی فشرده نسبت به دیزل ساده‌تر و چرخه‌ی احتراقِ آن کامل‌تر است، لذا آلاینده‌های CO و HC کمتری منتشر می‌کند. از دلایل افزایش NO_X می‌توان به دمای احتراق بالا، تمرکز دمایی در محفظه احتراق و عدم خنک کاری صحیح موتور اشاره کرد. پیش‌تر با تمرکز بر امکان به‌کارگیری گاز طبیعی فشرده در موتورهای اشتعال تراکمی، اثرات بکارگیریِ این سوخت ترکیبی بر عملکرد موتور و میزان انتشار آلاینده‌ها بررسی شده است [۱۴]. در

2 Ignition
3 Compressed Natural Gas (CNG)
4 Spark Ignition
5 Compression Ignition

6 Cetane Number
7 Well-to-Wheels
8 Nitrogen Oxide

UNCORRECTED PROOF

این مطالعه ابتدا یک موتور اشتعال تراکمی به موتور دوگانه سوز (دیزل + CNG) تبدیل شده و آزمایش‌های عملکرد و انتشار آلاینده‌ها در مرکز تحقیق و توسعه‌ی شرکت موتورسازان تبریز انجام شده است [۱۵]. تمامی آزمون‌های عملکرد و آلایندگی پس از ۱۰ دقیقه کار در جای موتور انجام گرفته است. به منظور پیش‌بینی دقیق انتشار NO_X از موتور احتراق تراکمی دوگانه سوز ترکیبی، یک معماری شبکه عصبی کانولوشنی عمیق (DCNN[9]) پیشنهاد شد. شبکه‌های عصبی همگشتی(CNN)[10] یک نوع از مدل‌های عمیق هستند که در آن فیلترهای قابل تعویض و عملیات تلفیقیِ محلی به طور متناوب روی مقادیر ورودی خام اعمال می‌شوند و سلسله مراتبی از ویژگی‌های به هم پیچیده را به وجود می‌آورند [۱۶]. CNNها معمولا از تعداد زیادی لایه‌های کانولوشنی متصل به هم و تعدادی لایه‌ی تجمعی ساخته شده‌اند. قدرت اصلی CNN در معماری عمیق آن است که اجازه می‌دهد تا مجموعه‌ای از ویژگی‌های متمایز و ناهمسان را در سطوح مختلف انتزاع استخراج کنیم. یکی دیگر از خصوصیات CNNتوانایی آن برای گرفتن عکس العمل‌های غیر خطی بین ورودی‌ها و خروجی‌هاست [۱۷]. قابلیت‌هایی همچون اتصالات محلی[11]، اشتراک وزن‌ها[12] و ادغام[13]، CNNها را قادر می‌سازد تا ویژگی‌های مکانی داده‌ها را به بهترین شکل ضبط کنند. در نتیجه وقتی با همبستگی فضایی[14] بین پارامترهای کنترل موتور دیزل مواجه می‌شویم، CNNها می‌توانند به طور موثر اطلاعات ویژگی‌های مربوطه را استخراج کنند [۱۸]. در حال حاضر بدست آوردنِ نقشه اصلی انتشار NO_X از طریق آزمایش‌های کالیبراسیون[15] گسترده انجام می‌شود که به دلیل هزینه بالای حسگرهای NO_X، اینکار هم زمان‌بر[16] بوده و هم نیازمند سرمایه‌گذاری قابل توجهی است [۱۹]. بنابراین دستیابی به یک روش ساده‌تر برای پیش‌بینی میزان انتشار NO_X در موتورهای اشتعال تراکمی بیش از پیش احساس می‌شود. برای تخمین میزان انتشار NO_X در شرایط حالت پایدار[17] می‌توان از روش‌های پیش‌بینی مبتنی بر مدل‌های فیزیکی استفاده کرد، اما پیش‌بینی دقیق انتشار NO_X در شرایط گذرا به دلیل تغییرات سریع در سرعت موتورهای اشتعال تراکمی، گشتاور و تزریق سوخت‌های ترکیبی با چالش‌های مختلفی مواجه است [۲۰]. بر اساس مشکلات مطرح شده، برای افزایش دقت پیش‌بینی انتشار NO_X از موتور اشتعال تراکمی دوگانه‌سوز، مدلی مبتنی بر DCNN پیشنهاد شده است. مدل پیشنهادی در ابتدا با بهره‌گیری از قابلیت‌های استخراج داده‌های مکانی CNN، مجموعه‌ای از ویژگی‌های ارزشمند را تولید کرده، سپس با دریافت این ویژگی‌ها از قابلیت‌های بکارگیری الگوهای زمانی LSTM برای تکمیل فرآیند آموزش استفاده می‌کند. بدین ترتیب امکان بررسی جامع داده‌های انتشار گذرا و نمایش دقیق دینامیک غیرخطی مرتبط با انتشارات گذرا در موتور اشتعال تراکمی دوگانه‌سوز فراهم می‌گردد. هدف از ارائه مدل DCNN پیشنهادی افزایش دقت پیش‌بینی انتشار NO_X است. در این مطالعه مقادیر ثبت‌شده توسط حسگرها برای متغیر انتشار NO_X از موتور اشتعالی تراکمی دوگانه‌سوز، شامل انتشار سری‌های زمانی[18] هستند که مدل DCNN پیشنهادی می‌تواند به طور موثر ویژگی‌ها را از این داده‌ها استخراج کرده و دقت پیش‌بینی را افزایش دهد. در این پژوهش، استفاده از شبکه عصبی تنها ابزار اولیه بوده و نوآوری صرفاً در انتخاب آن نیست، بلکه در ترکیب ساختار CNN عمیق با LSTM چندلایه با تنظیم ساختاری دقیق و استخراج ویژگی سلسله‌مراتبی است. برخلاف مدل‌های سطحی موجود، در این مدل ابتدا ویژگی‌های سطح پایین با چندین لایه کانولوشن استخراج شده و سپس با گذر از لایه‌های فشرده و Dropout، به بلوک LSTM منتقل می‌شود که وابستگی زمانی را تحلیل می‌کند. این ساختار، با هدف مدلسازی روابط غیرخطی، ناپایدار و وابسته به زمان در انتشار NO_X طراحی شده است. نوآوری دیگر، در بهره‌گیری از تنظیم خودکار پارامترهای یادگیری، استفاده از الگوریتم بهینه‌سازی جدید AdaptAhead، و بررسی چندجانبه ارزیابی عملکرد با ابزارهای تحلیلی تکمیلی است که در مدل‌های پیشین به‌طور کامل لحاظ نشده است.

9 Deep Convolutional Neural Network
10 Convolutional Neural Networks
11 Local Connections
12 Weight Sharing
13 Pooling
14 Spatial Correlation
15 Calibration Tests
16 Time-consuming
17 Steady-state Conditions
18 Time-series Emissions

UNCORRECTED PROOF

۲-پیشینه تحقیق

در سال‌های اخیر، استفاده از تکنیک‌های یادگیری عمیق در زمینه‌های مختلف افزایش قابل توجهی داشته است. الگوریتم‌های مورد استفاده در یادگیری عمیق کاربرد گسترده‌ای در پیش بینی آلاینده‌های گذرا از جمله NO_X در موتورهای دیزلی داشته‌اند. در این بخش برخی از مطالعات انجام شده در حوزه پیش بینی انتشار NO_X توسط یادگیری عمیق مورد بررسی قرار گرفته است.

در [۲۱] سال ۲۰۲۳ برای پیش بینی مقدار NO_X در شرایط گذرا بر روی یک موتور دیزلی مدل D25TCIF از ترکیب دو مدل CNN و LSTM استفاده شد. مدل پیشنهادی در این مطالعه بر روی داده‌های جمع‌آوری‌شده تحت یک چرخه حرارتی مطابق با استاندارد جهانی WHTC[19] آزمایش و اعتبارسنجی شد. دقت مدل با توجه به نتایج بدست آمده برای دو معیار RMSE =35.6 و R^2= 0.97 مورد ارزیابی قرار گرفت.

در [۲۲] سال ۲۰۲۲ برای پیش بینی مقدار NO_X خروجی از وسایل نقلیه سنگین[20] در دو حالت خروج از موتور[21] و خروج از لوله اگزوز[22] از یک شبکه عصبی عمیق (DNN[23]) استفاده شد. مدل پیشنهادی در این مطالعه بر روی مجموعه داده‌هایی که توسط دینامومتر اندازه گیری و به ثبت رسیده بود، مورد آزمایش و اعتبارسنجی قرار گرفت. دقت مدل با توجه به نتایج بدست آمده برای دو حالت خروج از موتور و خروج از لوله اگزوز توسط معیار R^2= 0.92-0.95 مورد ارزیابی قرار گرفت.

در [۲۳] سال ۲۰۲۲ برای پیش بینی مقدار NO_X و پیش بینی زمان محاسبات از یک مدل CNN یک بعدی استفاده شد. مدل 1D-CNN پیشنهادی در این مطالعه بر روی داده‌های جمع‌آوری‌شده از یک نیروگاه ۵۰۰ مگاواتی زغال سنگ[24] مورد آزمایش و اعتبارسنجی قرار گرفت. دقت مدل با توجه به نتایج بدست آمده برای معیار RMSE =70.6 مورد ارزیابی قرار گرفت.

در [۲۴] سال ۲۰۲۱ برای پیش بینی انتشار آنی[25] NO_X در یک موتور دیزلی از مدل LSTM استفاده شد. داده‌های مورد استفاده در این مطالعه با تجزیه کامل حالت تجربی مجموعه با نویز تطبیقی (CEEMDAN[26]) جمع آوری و برای آزمایش و اعتبارسنجی مدل LSTM مورد استفاده قرار گرفت. دقت مدل با توجه به نتایج بدست آمده برای دو معیار RMSE =46.11 و R^2= 0.98 مورد ارزیابی قرار گرفت.

در [۲۵] سال ۲۰۲۰ برای پیش بینی مقدار NO_X از یک دیگ بخار زغال سنگ[27] از یک مدل CNN استفاده شد. مدل پیشنهادی در این مطالعه بر روی داده‌های جمع‌آوری‌شده از یک دیگ بخار نیروگاهی ۳۳۰ مگاواتی که به طور مماس با زغال سنگ کار می‌کند مورد آزمایش و اعتبارسنجی قرار گرفت. دقت مدل با توجه به نتایج بدست آمده برای معیار RMSE =68 مورد ارزیابی قرار گرفت.

در [۲۶] سال ۲۰۲۰ برای پیش بینی مقدار NO_X در یک واحد ترک خوردگی کاتالیزوری سیال (FCC[28]) از ترکیب دو مدل CNN و LSTM استفاده شد. مدل پیشنهادی در این مطالعه بر روی داده‌های جمع‌آوری‌شده از یک سیستم کنترل توزیع شده (DCS[29]) در یک پالایشگاه مورد آزمایش و اعتبارسنجی قرار گرفت. دقت مدل با توجه به نتایج بدست آمده برای دو معیار RMSE =23.70 و R^2= 0.82 مورد ارزیابی قرار گرفت.

در [۲۷] سال ۲۰۱۵ برای پیش بینی مقدار NO_X و Soot بر روی یک موتور مرسدس بنز چهار سیلندر مدل OM355 از ترکیب شبکه عصبی مصنوعی (ANN[30]) با الگوریتم بهینه سازی کلونی مورچه‌ها (ACO[31]) استفاده شد. داده‌های جمع‌آوری‌شده برای آزمایش و اعتبارسنجی مدل پیشنهادی با اندازه‌گیری و ثبت پارامترهای مختلف در سرعت و قدرت‌های مختلف موتور به دست آمد. دقت مدل با توجه به نتایج بدست آمده برای دو معیار MSE = 0.0028 و R^2= 0.911 مورد ارزیابی قرار گرفت.

۳-روش پیشنهادی

[19] World Harmonized Transient Cycle
[20] Heavy-duty Vehicle
[21] Engine-out
[22] Tailpipe
[23] Deep Neural Network
[24] 500MW Coal-Fired Power Plant
[25] Instantaneous
[26] Complete Ensemble Empirical Mode Decomposition with Adaptive Noise
[27] Coal-fired Boiler
[28] Fluid Catalytic Cracking
[29] Distributed Control System
[30] Artificial Neural Network
[31] Ant Colony Optimization

UNCORRECTED PROOF

در این بخش ابتدا جزئیات مربوط به مجموعه داده جمع آوری شده برای این مطالعه تشریح می‌گردد، سپس پیش‌پردازش‌های انجام شده بر روی این داده‌ها بررسی می‌شوند. در ادامه ساختار کلی و جزئیات مربوط به دو مدل CNN و LSTM مورد بحث و بررسی قرار گرفته و در نهایت مدل پیش پینی DCNN پیشنهادی که ترکیبی از دو مدل CNN و LSTM است ارائه می‌گردد.

۳-۱-بانک داده

در این بخش جمع آوری داده‌های ورودی برای مدل DCNN پیشنهادی از یک موتور اشتعال تراکمی دوگانه‌سوز انجام می‌شود. تمام آزمایش‌های عملکردی و اندازه‌گیری‌های مربوط به انتشار آلاینده‌ها در مرکز تحقیق و توسعه‌ی شرکت موتورسازان تبریز در کشور ایران انجام شد. هدف از به‌کارگیری گاز طبیعی فشرده در موتورهای اشتعال تراکمی در یک موتور چهار سیلندر اشتعال تراکمی بررسی امکان مصرف گاز طبیعی فشرده به عنوان سوخت اصلی و به‌کارگیری سوخت دیزل به عنوان آتش‌زنه (جرقه‌زن) می‌باشد. بررسی امکان به کارگیری این سوخت ترکیبی در یک موتور اشتعال تراکمی بدون بهره‌مندی از سامانه‌ی جرقه‌زنی و مقایسه متغیرهایی نظیر توان خروجی موتور و نیز میزان انتشار آلاینده‌های حاصل از احتراق انجام شد. هدف از تامینِ بخش اصلیِ توان موتور توسطِ گاز طبیعی فشرده، کاهش آلاینده‌های CO، NO_X، HC، CO_2، O_2 و Soot با بکارگیریِ سوخت ترکیبی نسبت به سوخت دیزل بود. در این مطالعه به منظور آموزش[۳۲] و اعتبارسنجی[۳۳] مدل پیشنهادی، جمع آوری داده‌ها در یک چرخه زمانی استاندارد (۱۰ دقیقه) انجام شده است. تمامی آزمون‌های عملکردی که شامل اندازه‌گیری و ثبت آلاینده‌ها و پارامترهای ورودی می‌باشند، در حین کارکرد موتور در پنج سطح سرعت دورانی ۱۲۰۰، ۱۴۰۰، ۱۶۰۰، ۱۸۰۰ و ۲۰۰۰ دور بر دقیقه و در سه تکرار صورت گرفت. در هر پنج ثانیه از بازه زمانی مشخص شده (۱۰ دقیقه)، مقادیر مربوط به ۱۱ پارامتر توسط حسگرهای فیزیکی اندازه‌گیری و به ثبت رسیدند. در پایانِ هر تکرار ۱۲۰ مقدار جدید برای هر پارامتر بدست آمد که با تکمیل تکرارها (۳ تکرار)، این مقدار به ۳۶۰ افزایش یافت. در نهایت با در نظر گرفتن پنج سطح سرعت مختلف، ۱۸۰۰ نقطه داده مختلف اندازه گیری و در مجموعه داده مورد نظر به ثبت رسید. پارامترهای مورد استفاده در این مجموعه داده در جدول ۱ نمایش داده شده است.

جدول ۱- پارامترهای جمع آوری شده برای مجموعه داده

نام پارامتر (فارسی)	واحد
سرعت	rpm
گشتاور	N.m
جریان هوای ورودی	Kg.h-1
زمانبندی قبل از پاشش	°CA
مقدار قبل از پاشش	Kg.h-1
مقدار کل پاشش سوخت	Kg.h-1
دمای سوخت	°C
فشار سوخت	bar
دمای اتمسفری	°C
رطوبت اتمسفری	٪
اکسید نیتروژن	ppm

۳-۲-مدل DCNN پیشنهادی

مدل DCNN پیشنهادیِ معرفی شده در این مطالعه از ترکیب دو مدل CNN و LSTM بدست آمده است. این مدل عمیق از قابلیت‌های CNN برای استخراج ویژگی‌ها و از قابلیت‌های LSTM برای پیش‌بینی سری‌های زمانی بهره برده است. در ادامه جزئیات مربوط به این مدل عمیق پیشنهادی ارائه می‌شود.

ورود داده‌ها

در گام اول ورود داده‌ها از مجموعه داده جمع آوری شده انجام می‌شود. برای استخراج ویژگی‌های فضایی[۳۴] از داده‌های پیش پردازش شده، داده‌های بدست آمده از پارامترهای موتور و آلاینده‌ها به عنوان ورودی به مدل داده می‌شوند. داده‌های پیش پردازش شده به سه مجموعه داده آموزش، آزمایش و اعتبارسنجی تقسیم می‌شوند. ۷۵ درصد

[32] Training
[33] Verification
[34] Extracting Spatial Feature

UNCORRECTED PROOF

داده‌ها به فرآیند آموزش، ۱۰ درصد داده‌ها به فرآیند تست و ۱۵ درصد به فرآیند اعتبارسنجی مدل اختصاص داده می‌شود.

استخراج ویژگی‌ها و آموزش مدل

CNN یک بعدی می‌تواند متغیرهای داده را به فضایی با ابعاد بالا نگاشت کرده و ویژگی‌های محلی را بر اساس همبستگی‌های سری مکانی و زمانی استخراج کند. در 1D-CNN از ضرب ماتریس برای انجام محاسبات کانولوشن روی داده‌های سری زمانی استفاده می‌شود. این نوع از CNNها برای پردازش داده‌های سری زمانی ثبت شده توسط حسگرها بسیار مناسب هستند. از آنجایی که داده‌های انتشار NO_X از موتور اشتعال تراکمی دوگانه‌سوز شامل انتشار سری‌های زمانی ثبت‌شده توسط حسگرهاست، بنابراین 1D-CNN می‌تواند به طور موثر ویژگی‌ها را از داده‌های انتشار استخراج کند و دقت پیش‌بینی مدل را افزایش دهد. در فرآیند اشکال‌زدایی ساختار CNN، اگر تعداد لایه‌های کانولوشن خیلی کم باشد ممکن است مدل به دلیل قابلیت‌های ناکافی استخراج ویژگی دچار مشکل پیش برازش[۳۵] گردد؛ برعکس اگر تعداد لایه‌های کانولوشن بیش از حد باشد می‌تواند منجر به مشکل بیش برازش[۳۶] گردد. در حالی که لایه ادغام می‌تواند تا حدی مشکل برازش بیش از حد را کاهش دهد، اما استفاده از لایه‌های ادغامِ بیش از حد نیز می‌تواند منجر به کاهش تعداد ابعاد ویژگیِ ورودی برای شبکه LSTM شود. این کاهش می‌تواند بر استخراج ویژگی‌های سری زمانی توسط LSTM تأثیر منفی گذاشته و در نتیجه کارایی اتصالات شبکه را کاهش دهد. با تکرارهای متعدد برای فرآیند اشکال‌زدایی CNN، یک ساختار پیشنهادی با چهار لایه کانولوشن، یک لایه ادغام حداکثری و یک لایه مسطح تماما متصل برای بخش اول مدل عمیق پیشنهادی انتخاب شد. در این مرحله مجموعه داده آموزشی که شامل هفت ویژگی ورودی و یک برچسب خروجی می‌باشد برای استخراج ویژگی‌ها به یک 1D-CNN وارد شده و چهار بار عمل کانوالو انجام می‌شود. به دنبال عملیات کانولوشن از یک تابع فعال‌ساز ReLU برای نگاشت ویژگی‌ها به فواصل غیرخطی با ابعاد بالا استفاده می‌شود. متعاقبا از یک لایه ادغام حداکثری (Max Pooling) نیز برای کاهش ابعاد خروجی استفاده می‌شود. تعداد هسته‌های کانولوشن به ترتیب ۱۶، ۳۲، ۶۴ و ۱۲۸ در نظر گرفته شده است. اندازه هسته‌ها برای هر دو لایه کانولوشن و ادغام ۳×۱ با گام یک تنظیم شده است. با تکمیل سه عمل کانولوشن متوالی و یک عملیات ادغام حداکثری ماتریس ویژگی با سایز ۲۸*۱۶ بدست می‌آید. سپس این ماتریس به یک بردار یک بعدیبه طول ۲۰۴۸ مسطح شده و به عنوان ورودی به مدل LSTM اعمال می‌شود. برای اطمینان از افزایش دقت مدلِ عمیق پیشنهادی، فراپارامترهای بهینه با روش grid search (جستجوی شبکه‌ای) به ورودی LSTM اعمال می‌شوند. این رویکرد محدوده جستجو را به یک شبکه تقسیم می‌کند و به طور سیستماتیک تمام تقاطع‌های درون آن را بررسی می‌کند. با ارزیابی نتایج بازخورد از این تقاطع‌ها، می‌توان بهترین ترکیب فراپارامترها را تعیین کرد. در این مرحله محدوده جستجوی فراپارامترها برای LSTM تعیین شده، سپس این محدوده به تابع grid search اعمال می‌شود تا تمام ترکیبات ممکن را در محدوده مشخص شده سازماندهی کند. محدوده جستجوی فراپارامترهای مورد استفاده در ساختار LSTM برای عمیق ۱ تا ۱۰، برای تعداد نورون‌های لایه پنهان ۱۰ تا ۲۰۰ و برای اندازه دسته (BC[۳۷]) ۱۰ تا ۳۰۰ در نظر گرفته شد. ساختار LSTM در مدلِ عمیق پیشنهادی شامل یک لایه ورودی، دو لایه پنهان (۴۰ نورون برای هر لایه)، یک لایه خروجی و یک لایه تماما متصل است. LSTM به طور مکرر دروازه ورودی، دروازه فراموشی و دروازه خروجی را آموزش می‌دهد تا فراپارامترهای مربوطه خود را تنظیم کند. با تکمیل فرآیند آموزش بعد از ۵۰ ایپاک، مقادیر نهایی برای عمق ۲، تعداد نورون‌های لایه پنهان ۴۰ و اندازه دسته‌ها ۱۰۰ تعیین شد. تعداد تکرار برای فرآیند آموزش و اعتبارسنجی مدل ۵۰ ایپاک[۳۸] (دور) در نظر گرفته شده است. با تکرار و بهینه سازی مداوم ترکیب‌های مختلف فراپارامترهای مدل پیش بینی توسط تابع grid search، فراپارامترهای نهایی برای مدل پیشنهادی به دست می‌آیند. جزئیات مربوط به فراپارامترهای مورد استفاده در مدل DCNN پیشنهادی در جدول ۲ نمایش داده شده است.

جدول ۲- فراپارامترهای مورد استفاده در مدل DCNN پیشنهادی

[35] Underfitting
[36] Overfitting
[37] Batch Size
[38] Epoch

UNCORRECTED PROOF

نام فراپارامتر (فارسی)	مقدار
تعداد لایه‌های کانولوشن	۴
تعداد لایه‌های ادغام	۱
تابع فعال‌ساز	ReLU
تعداد کرنل‌های کانولوشن	۱۶، ۳۲، ۶۴ و ۱۲۸
سایز کرنل‌ها	۳ × ۱
نرخ یادگیری	۰.۰۰۱
گام	۱
عمق	۲
تعداد نورون‌های لایه پنهان	۴۰
تعداد تکرارها (ایپاک)	۵۰
تابع بهینه‌ساز	AdaptAhead
تابع ضرر	Binary Cross Entropy
بهینه‌سازی فراپارامترها	grid search

بهینه‌سازی توسط الگوریتم AdaptAhead

بردارهای ویژگی استخراج شده توسط DCNN آموزش داده شده‌اند و وزن‌های شبکه در هر گام توسط الگوریتم AdaptAhead به روز می‌شود [۲۸]. نرخ یادگیری[۳۹] اولیه روی ۰.۰۰۱ تنظیم شده است. وزن‌ها و بایاس‌های هر نورون به طور مداوم با استفاده از این الگوریتم به روز می‌شوند که این بروزرسانی در نهایت منجر به خروجی بهینه از تابع ضرر (Loss) می‌گردد. تعداد تکرار برای فرآیند آموزش و اعتبارسنجی مدل ۵۰ ایپاک (دور) در نظر گرفته شده است. با تعریف یک تابع هدف برای الگوریتم، سعی می‌شود مقادیر پارامترهای قابل تنظیم بگونه‌ای محاسبه گردند که تابع هدف مورد نظر، با توجه به مجموعه داده‌های آزمایشی کمینه شوند.

نوآوری اصلی این پژوهش در طراحی یک معماری عمیق و بهینه‌سازی‌شده بر پایه شبکه‌های CNN و LSTM نهفته است که به‌صورت هدفمند و ساختارمند ترکیب شده‌اند. برخلاف تحقیقات پیشین که تنها از CNN یا LSTM به صورت مستقل بهره گرفته‌اند، در این مدل، ابتدا لایه‌های کانولوشن عمیق با هدف استخراج دقیق ویژگی‌های فضایی از داده‌های دینامیکی استفاده شده و سپس خروجی این بخش به یک ساختار LSTM چندلایه متصل شده که روابط زمانی متغیرهای ورودی را به‌خوبی مدل‌سازی می‌کند. استفاده از Grid Search برای بهینه‌سازی هایپرپارامترها، به‌کارگیری Dropout جهت کاهش بیش‌برازش، و نیز بهره‌گیری از الگوریتم AdaptAhead در فرآیند یادگیری، اجزای مکمل این نوآوری هستند. این ساختار از نظر عمق، پیوستگی لایه‌ها، روش آموزش، و کنترل خطا، نسبت به ساختارهای گزارش‌شده در مقالات مورد بررسی در بخش پیشینه تحقیق کاملاً متمایز است و قابلیت تعمیم‌پذیری بالایی در داده‌های واقعی صنعتی دارد.

۴-نتایج تجربی

موتور اشتعال تراکمی دوگانه‌سوز (مدل MT440C) مورد استفاده در این مطالعه یک موتور چهار سیلندر ساخت شرکت موتورسازان تبریز می‌باشد که با استانداردهای آلایندگی ملی مطابقت دارد. بیشینه توان ترمزی این موتور در سرعت دورانی مشخصه ۲۰۰۰ دور بر دقیقه، ۸۲ اسب بخار است. در حالت دوگانه‌سوز از سوخت CNG به عنوان سوخت اصلی و از دیزل (با استاندارد Euro 4) به عنوان سوخت آتش‌زنه استفاده شده است.

برای اندازه‌گیری آلاینده‌های حاصل از احتراق موتور مورد آزمایش از دستگاه آلاینده‌سنج AVL 415S استفاده شد. این دستگاه محصول شرکت AVL Ditest ساخت کشور آلمان بوده و قابلیت اندازه‌گیری آلاینده‌های احتراق خودروهای اشتعال جرقه‌ای و تراکمی در گاز خروجی اگزوز را دارد. این دستگاه مقادیر NO_X، HC، CO_2، O_2 و Soot خروجی از موتور را به صورت دیجیتالی نمایش می‌دهد. برای جمع آوری داده‌های مورد استفاده در این مطالعه، گاز خروجی از اگزوز موتور توسط یک لوله به دستگاه آلاینده‌سنج AVL 415S انتقال یافته و مقدار انتشار NO_X در هر ثانیه به صورت جداگانه توسط این دستگاه اندازه‌گیری و ثبت می‌شود. سایر پارامترهای مورد استفاده در مجموعه داده‌ی ورودیِ مدل DCNN پیشنهادی توسط دستگاه

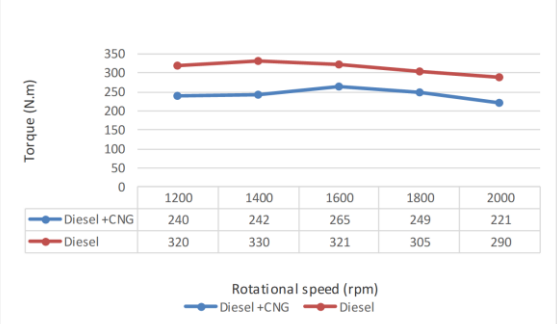
[39] Learning Rate

UNCORRECTED PROOF

دینامومتر SCHENCK مدل W230 اندازه‌گیری و به ثبت رسیدند. این دستگاه نیز محصول کشور آلمان و از نوع مغناطیسی با جریان گردابی[۴۰] ، بیشینه توان 230 KW ، بیشینه سرعت 7500 rpm و بیشینه گشتاور 750 N.m می‌باشد. از یک دبی‌سنج مکانیکی نیز برای اندازه‌گیری میزان مصرف سوخت گاز طبیعی فشرده استفاده گردید. دبی‌سنج مورد استفاده در این مطالعه از نوع پروانه‌ای بوده و قادر به اندازه‌گیری دبی در محدوده ۰/۱ تا ۱۶ مترمکعب در ساعت بود. در ادامه‌ی این بخش نتایج آزمایشگاهی به دست آمده از آزمون عملکرد و آلایندگی موتور در مقایسه با نتایج کارخانه‌ای جهت اعتبار بخشیِ مدل آزمایشگاهی گشتاور برای اهداف اعتبارسنجی با نتایج کارخانه سازنده مقایسه و نمایش داده شده است.

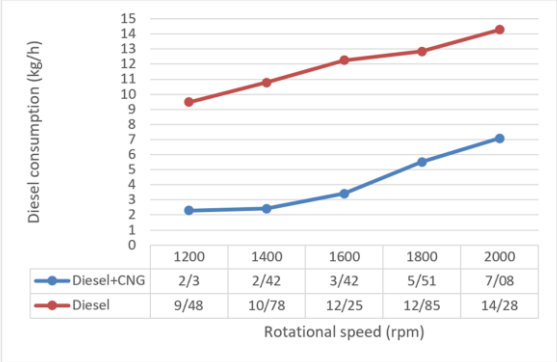
۴-۱-بررسی میزان آلاینده‌ها در حالت دیزل تنها و سوخت ترکیبی (دیزل+ CNG)

مدل DCNN شکل ۱ در پنج سرعت دورانی مختلف موتور، میزان گشتاور تولیدی در حالت استفاده از سوخت دیزل و در حالت استفاده از سوخت ترکیبی (دیزل و گاز طبیعی فشرده) نشان داده است. با توجه به نمودار نشان داده شده بیشینه میزان گشتاور تولیدی در حالت استفاده از سوخت دیزل ۳۳۰ نیوتن‌متر در سرعت دورانی ۱۴۰۰ دور بر دقیقه موتور و بیشینه گشتاور تولیدی در حالت استفاده از سوخت ترکیبی ۲۶۵ نیوتن‌متر در سرعت دورانی ۱۶۰۰ دور بر دقیقه موتور می‌باشد و چون بیشینه گشتاور تولیدی در هر دو سامانه در دورهای متفاوت حاصل شد، لذا برای محاسبه توان برای هر سامانه و مقایسه با یکدیگر از بیشترین سرعت دورانی مشخصه (۲۰۰۰ دور بر دقیقه) استفاده شد.



شکل ۱- گشتاور تولیدی در حالت دیزل تنها و سوخت ترکیبی در سرعت‌های دورانی مختلف

در شکل ۲ میزان مصرف سوخت دیزل در حالت سوخت ترکیبی و در حالت دیزل تنها نشان داده شده است که در پنج سرعت دورانی مختلف موتور اندازه‌گیری شده است. میزان مصرف سوخت دیزل در حالت ترکیبی در سرعت‌های پایین تا ۱۶۰۰ دور بر دقیقه، نسبتاً کم بوده به گونه‌ای که به طور متوسط در این سرعت دورانی حدود ۸۰ درصد کاهش مصرف سوخت دیزل نسبت به همان سرعت دورانی موتور در حالت دیزل تنها مشاهده شد و برای تمامی حالات سرعت دورانی موتور، به طور متوسط حدود ۶۵ درصد کاهش مصرف سوخت دیزل حاصل شد.

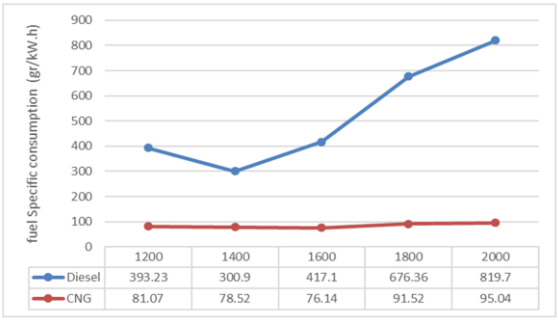


شکل ۲- میزان مصرف دیزل در حالت سوخت ترکیبی و دیزل تنها

در شکل ۳ میزان مصرف ویژه سوخت CNG و دیزل در سامانه سوخت ترکیبی به طور جداگانه نمایش داده شد. در نقطه‌ای که بیشترین گشتاور تولیدی حاصل شد، مصرف ویژه سوخت کمترین مقدار را داشت؛ لذا از آنجاییکه در سامانه ترکیبی بیشینه گشتاور تولیدی در سرعت‌های دورانی ۱۶۰۰ دور بر دقیقه (بر اساس شکل ۱) حاصل شد. مصرف ویژه سوخت به دلیل توان تولیدی بیشتر، مقدار کمتری را دارا بود. از آنجاییکه در حالت سوخت دوگانه، گاز طبیعی فشرده در نقش سوخت اصلی است لذا مشاهده شد که با افزایش سرعت دورانی موتور، مصرف ویژه گاز طبیعی فشرده افزایش یافت. این بدان معناست که با افزایش سرعت دورانی موتور نسبت به سوخت مصرف شده (گاز طبیعی فشرده) کاهش یافته است.

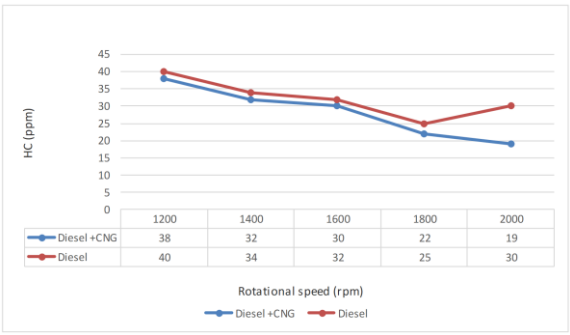
[40] Eddy Current

UNCORRECTED PROOF



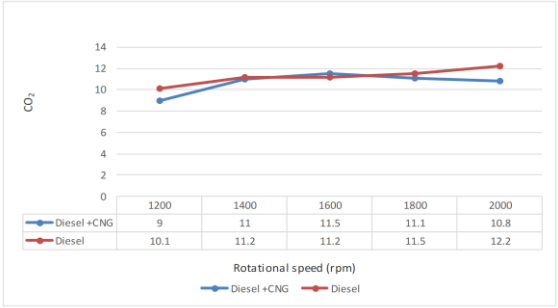
شکل ۳- میزان مصرف ویژه سوخت ترکیبی (دیزل + CNG)

شکل ۴ میزان آلایندگی HC موتور را برای هر دو حالت استفاده از سوخت دیزل تنها و سوخت ترکیبی نمایش می‌دهد. میزان آلایندگی HC در سوخت ترکیبی کمتر از حالت دیزل تنها می‌باشد. در ضمن با افزایش دور موتور از مقدار این آلایندگی کاسته شد. از دلایل ایجاد آلایندگی هیدروکربن، غنی بودن مخلوط سوخت و احتراق ناقص می‌باشد.



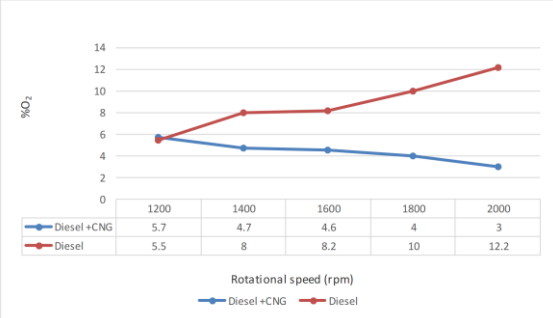
شکل ۴- میزان آلایندگی هیدروکربن (HC) در حالت دیزل و ترکیبی

شکل ۵ میزان آلاینده دی‌اکسیدکربن (CO_2) تولیدی موتور را برای سامانه دیزل تنها و سامانه ترکیبی نمایش می‌دهد. طبق نتایج به‌دست آمده میزان دی اکسیدکربن تولیدی موتور در هر دو حالت تقریبا نزدیک به هم بوده و در دورهای ۱۲۰۰ و ۲۰۰۰ دی اکسیدکربن تولیدی سوخت ترکیبی کمتر از سوخت دیزل می‌باشد و در دورهای میانی میزان دی اکسید کربن تولیدی در هر دو حالت سوخت ترکیبی و دیزل تنها تقریبا یکسان می باشد.



شکل ۵- میزان آلایندگی دی‌اکسیدکربن (CO_2) در حالت دیزل و ترکیبی

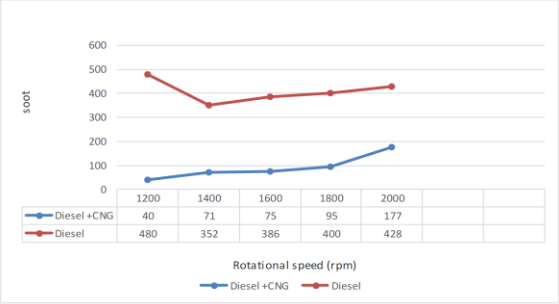
شکل ۶ میزان اکسیژن (O_2) تولیدی موتور را در سرعت‌های دورانی مختلف برای سوخت دیزل و سوخت ترکیبی نمایش می‌دهد. میزان O_2تولیدی موتور در دور ۱۲۰۰ در هر دو حالت تقریبا یکسان بوده و با افزایش دور موتور میزان خرجی از موتور در حالت استفاده از سوخت ترکیبی به طور میانگین ۵۰ درصد کمتر از حالت استفاده از سوخت دیزل تنها می‌باشد. اگرچه O_2 در گازهای خروجی از اگزوز، آلایندگی محسوب نمی شود ولی میزان آن می تواند نشان دهنده کیفیت احتراق باشد. با افزودن گاز طبیعی به دیزل، میزان O_2 خروجی نسبت به دیزل خالص کاهش می یابد. کاهش O_2 نشان دهنده کیفیت بهتر احتراق و اکسیداسیون بیشتر سوخت می باشد. با شدیدتر شدن احتراق، میزان O_2 خروجی کاهش می یابد.



شکل ۶- میزان اکسیژن (O_2) تولیدی در حالت دیزل و ترکیبی

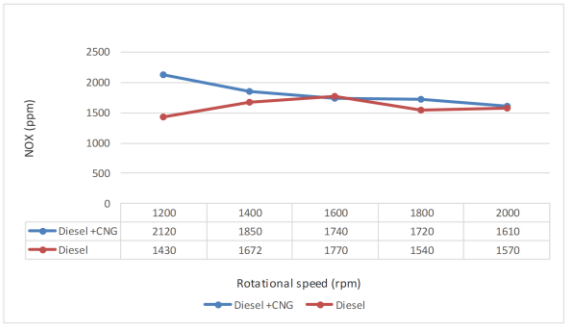
شکل ۷ میزان دوده (Soot) تولید شده (خروجی از اگزوز) موتور را برای سامانه دیزل و سوخت ترکیبی نمایش می‌دهد. همانگونه که ملاحظه می‌شود تقریبا در تمام سرعت‌های دورانی موتور میزان انتشار دوده در حالت ترکیبی نسبت به دیزل تنها کاهش شگرفی یافته است. علت این امر، این است که در موتور با بکارگیری گاز طبیعی فشرده ارزش حرارتی سوخت بیشتر شده و به همان میزان، دمای کاری موتور افزایش یافته و با توجه به نسبت معکوس دما و تولید دوده لذا در حالت سوخت ترکیبی با ازدیاد دمای کاری موتور منجر به کاهش دوده تولیدی می‌شود

UNCORRECTED PROOF



شکل ۷- میزان دوده (Soot) در حالت دیزل و ترکیبی

شکل ۸ میزان آلایندگی NO_X را با هر دو حالت سوخت دیزل و سوخت ترکیبی نمایش می‌دهد. میزان NO_X تولیدی موتور در حالت دیزل کمتر از حالت ترکیبی بود و این به دلیل احتراق ناقص مخلوط سوخت دیزل و CNG بود. کمترین مقدار آن که برای سوخت دیزل به دست آمده است به دلیل پایین بودن دمای محفظه احتراق، در اثر کاهش ارزش حرارتی و افزایش زمان تاخیر در اشتعال می‌باشد. از دلایل ایجاد اکسیدهای نیتروژن مخلوط فقیر سوخت، کاهش زمان تأخیر در اشتعال و دمای بالای احتراق می‌باشد. در سامانه سوخت ترکیبی به دلیل دمای بالای کاری موتور، ارزش بالای حرارتی سوخت گاز طبیعی و افزایش تأخیر در اشتعال نسبت به سامانه دیزل تنها، NO_X تولیدی بیشتر بود.



شکل ۸- میزان اکسید نیتروژن (NO_X) در حالت دیزل و ترکیبی

۴-۲-محیط شبیه‌سازی

برای شبیه‌سازی مدل عمیق پیشنهادی از یک سیستم کامپیوتری با پردازنده Intel(R) Core(TM) i7 با حافظه RAM ۸ گیگابایت، پردازنده گرافیکی NVIDIA GeForce 940M و زبان برنامه‌نویسی پایتون[41] استفاده شد. توسعه مدل توسط زبان پایتون با کمک کتابخانه Keras و پشتیبانی TensorFlow انجام شد. قطعه کد زیر بخشی از فرآیندِ مربوط به ساختِ مدل و انتخاب الگوریتم مورد نظر برای بهینه‌سازیِ مدل می‌باشد:

```
DCNN = Model (input_data, x)
DCNN.compile (optimizer= Adaptahead, loss='binary_crossentropy')
```

مربوط به ساختن مدل با Model در قطعه کد بالا دستور نهایی به x به عنوان لایه ورودی و input_data انتخاب عنوان لایه خروجی تعریف می‌شوند. بعد از ساختن مدل برای Compile می‌بایست آن را کامپایل کنیم. از دستور اجرا و کامپایل مدل استفاده می‌شود که پارامترهای مورد نظر به ترتیب مربوط به انتخاب الگوریتم بهینه‌سازی و تابع برای انتخاب تابع optimizer هزینه می‌باشند. از پارامتر برای انتخاب تابع هزینه loss بهینه‌سازی و از پارامتر "AdaptAhead"استفاده می‌کنیم؛ که در این کار پارامتر به عنوان الگوریتم بهینه‌سازی و تابع به عنوان تابع هزینه انتخاب binary_Crossentropy می‌شوند. لازم به ذکر است که در فرآیند آموزش باید نظارت پیوسته‌ای بر دقت عملکرد مدل برای داده‌های اعتبارسنجی وجود داشته باشد و برای جلوگیری از بیش‌برازش با مشاهده عدم بهبود دقت در یک ایپاک، فرآیند آموزش، خاتمه داده شود. قطعه کد زیر مربوط به شروع فرآیند آموزش مدل می‌باشد:

```
n_epocks = 50
n_batch_size = 100
DCNN.fit (
        x_train,
    epochs = n_epochs,
    batch_size = n_batch_size,
    shuffle = True,
    validation_data = (x_test_val)
    )
```

در قطعه کد بالا قبل از ورود به فاز آموزشِ مدل، ابتدا تعداد گام یا ایپاک‌ها و سپس اندازه دسته‌ها را مشخص می‌کنیم. ایپاک‌ها تعداد مراحلی هستند که در هر کدام از آنها مدل تمام داده‌ها را می‌بینند. تعداد ایپاک‌ها ۵۰ و اندازه دسته‌ها ۱۰۰ در نظر گرفته شده، سپس فرآیند آموزش مدل با دستور fit آغاز می‌شود. از پارامتر shuffle برای تغییر چینش داده‌ها و در واقع بُر خوردن داده‌ها استفاده می‌شود. True کردن مقدار این پارامتر باعث می‌شود مدل از تاثیر دادنِ توالی داده‌ها در نتیجه جلوگیری کند. پارامتر آخر

[41] Python

UNCORRECTED PROOF

Validation مربوط به داده‌های پیش‌بینی می‌باشد. در این بخش می‌توان از مجموعه داده ارزیابی برای پیش‌بینی مقدار انتشار NO_X برای موتور اشتعال تراکمی دوگانه‌سوز استفاده کرد. در انتهای هر دور آموزش، داده‌های (x_test_val) که مربوط به داده‌های ارزیابی هستند را به مدل می‌دهیم تا در پایان هر دور آموزش، نتایج را بر روی این داده‌ها نیز عرضه کند و شاهد نتایج واقعی‌تر باشیم.

۴-۳-معیارهای ارزیابی

برای ارزیابی عملکرد مدل DCNN پیشنهادی، در این مطالعه از چهار شاخص مهم که به طور معمول برای بررسی عملکرد صحیح شبکه‌های عصبی به کار می‌روند، استفاده شده است. این چهار شاخص عبارتند از میانگین خطای مطلق (MAE)، شاخص مجذور میانگین مربعات خطا (RMSE)، ضریب تبیین (R^2) و میانگین مطلق خطای پیش بینی (MAPE). R^2 معمولا بین صفر و یک در نظر گرفته می‌شود. نحوه برآورد دقت مدل پیشنهادی توسط این چهار شاخص به ترتیب در عبارت ۱، ۲، ۳ و ۴ نمایش داده شده است. در تمام عبارت‌های زیر n تعداد کل نمونه، y_a^i مقدار واقعی، y_p^i مقدار پیش بینی شده و y_b^i میانگین پاسخ‌های واقعی است.

$$MAE = \frac{1}{n}\sum_{i=1}^{n}\left|y_a^i - y_p^i\right| \quad (۱)$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(y_a^i - y_p^i\right)} \quad (۲)$$

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_a^i - y_p^i}{y_b^i}\right| \times 100\ \% \quad (۳)$$

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_a^i - y_p^i)^2}{n\sum_{i=1}^{n}(y_a^i - y_b^i)^2} \quad (۴)$$

۴-۴-نتایج خروجی و مقایسات

با تکمیل فرآیند آموزش، مدل DCNN پیشنهادی توسط معیارهای ارزیابی مختلف اعتبارسنجی شد. میانگین نتایج بدست آمده برای معیارهای MAE، RMSE، R^2 و MAPE در جدول ۳ نمایش داده شده است.

جدول ۳- نمایش دقت بدست آمده برای مدل DCNN پیشنهادی

DCNN	
معیارهای ارزیابی	**مقادیر**
MAE	۶.۶۱۳
RMSE	۲۱.۷۰۸
R^2	۰.۹۹۷
MAPE	۱۲.۱۹۴

بخشی از نتایج مربوط به پیش‌بینی انتشار NO_X موتور اشتعالی تراکمی دوگانه‌سوز در دوحالت واقعی و پیش‌بینی توسط مدل DCNN پیشنهادی، در گام‌های زمانی مختلف در جدول ۴ نمایش داده شده است.

جدول ۴- نمایش پیش‌بینی انتشار NO_X در دوحالت واقعی و پیش‌بینی توسط مدل

پارامتر		**مقادیر**				
زمان (s)	سرعت (rpm)	۱۲۰۰	۱۴۰۰	۱۶۰۰	۱۸۰۰	۲۰۰۰
در ثانیه (۲۵) دور اول	NO_X واقعی	۲۱۰۰	۱۸۰۰	۱۶۹۰	۱۷۰۰	۱۵۷۰
	NO_X پیش بینی شده	۲۰۱۱	۱۸۳۰	۱۶۷۰	۱۶۹۰	۱۵۳۵
در ثانیه (۴۰) دور دوم	NO_X واقعی	۲۲۰۰	۱۹۶۰	۱۷۰۰	۱۸۲۰	۱۵۰۰
	NO_X پیش بینی شده	۲۳۳۱	۱۹۰۹	۱۷۹۸	۱۷۹۰	۱۵۰۰
در ثانیه (۶۵) دور سوم	NO_X واقعی	۲۸۹۰	۲۱۰۰	۱۷۰۰	۱۷۹۸	۱۳۶۰
	NO_X پیش بینی شده	۲۷۳۷	۲۰۶۴	۱۰۰۹	۱۷۸۰	۱۳۲۵
در ثانیه (۱۲۰) دور سوم	NO_X واقعی	۲۱۲۰	۱۸۵۰	۱۷۴۰	۱۷۲۰	۱۶۱۰
	NO_X پیش بینی شده	۲۰۲۱	۱۸۰۰	۱۶۹۰	۱۶۵۰	۱۶۲۰

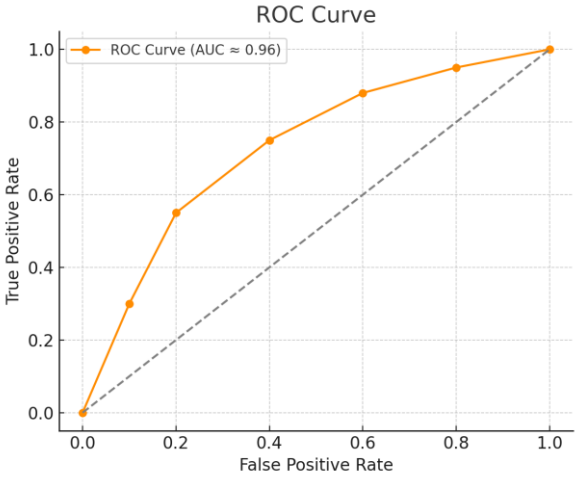
UNCORRECTED PROOF

جدول ۵ نتایج مربوط به مقایسه مدل پیشنهادی با برخی از مطالعات انجام شده در سال‌های اخیر در حوزه پیش‌بینی انتشار NO_X را نشان می‌دهد. نتایج حاصل از این جدول نشان می‌دهد مدل DCNN پیشنهادی عملکرد بهتری نسبت به روش‌های معرفی شده در کارهای گذشته داشته است. در راستای افزایش شفافیت مقایسه و تحلیل فنی، معماری مدل‌های مرجع مورد بررسی در مقالات [۲۱] تا [۲۷] به‌صورت دقیق در جدول ۵ آورده شده‌اند. این معماری‌ها شامل ساختارهای CNN تکی، LSTM ساده، CNN-LSTM ترکیبی اما با عمق محدود، و در برخی موارد استفاده از الگوریتم‌های فرابتکاری مانند ACO یا مدل‌های D-CNN۱ برای داده‌های ساده‌تر هستند. در هر مورد، تعداد لایه‌ها، توالی شبکه‌ها، و نوع خروجی ذکر شده تا مقایسه عادلانه صورت پذیرد.

جدول ۵- مقایسه مدل DCNN پیشنهادی با کارهای پیشین

ردیف	رفرنس	سال چاپ	معماری	معیارهای ارزیابی	
				RMSE	R^2
۱	-	#	DCNN	۲۱.۷۰	۰.۹۹
۲	[۲۱]	۲۰۲۳	CNN-LSTM	۳۳.۴۹	۰.۹۷
۳	[۲۲]	۲۰۲۲	Deep Learning		۰.۹۲-۰.۹۵
۴	[۲۳]	۲۰۲۲	1D-CNN	۷۰.۶	-
۵	[۲۴]	۲۰۲۱	CNN	۴۶.۱۱	۰.۹۸
۶	[۲۵]	۲۰۲۰	CNN	۶۸	-
۷	[۲۶]	۲۰۲۰	CNN-LSTM	۲۳.۷۰	۰.۸۲
۸	[۲۷]	۲۰۱۵	ANN+ACO	-	۰.۹۱

مدل پیشنهادی DCNN از لحاظ دقت پیش‌بینی، تعمیم‌پذیری، و پایداریِ عملکرد، نسبت به سایر مدل‌های معرفی شده مربوط به سال‌های اخیر مزیت قابل‌توجهی دارد. بر اساس نتایج به‌دست‌آمده، شاخص‌های MAE و RMSE در مدل حاضر به‌مراتب پایین‌تر و مقدار R^2 نزدیک به یک است که نشان از تطابق بالا با داده‌های واقعی دارد. همچنین، نمودار ROC رسم‌شده (شکل ۹) نشان می‌دهد که توانایی مدل در طبقه‌بندی وضعیت‌های بحرانی و غیربحرانی انتشار NOx به‌صورت دقیق و کارا صورت گرفته است. در مقایسه با مدل‌های [۲۱] تا [۲۷] که عمدتاً دارای معماری سطحی‌تر، بدون تنظیم دقیق پارامترها یا بدون طراحی ویژه برای داده‌های ناپایدار زمانی بوده‌اند، مدل حاضر با ساختار کانولوشن عمیق و کنترل توالی‌های زمانی برتری عملیاتی و نظری دارد. به‌علاوه، در شکل مقایسه‌ای خروجی مدل‌ها، پیش‌بینی مدل DCNN در اکثر مقاطع زمانی به مقدار واقعی نزدیک‌تر یا بهینه‌تر از سایر روش‌هاست. در شکل‌های ۹ تا ۱۱ Round به معنی دور، RPM نشان دهنده سرعت موتور و PPM واحد اندازه‌گیری میزان انتشار اکسید نیتروژن NO_X می‌باشد. به‌منظور ارزیابی عملکرد مدل DCNN پیشنهادی در دسته‌بندی صحیح سطوح انتشار NOx، از نمودار مشخصه عملکرد گیرنده (ROC) استفاده شد. سطح زیر منحنی (AUC) بسیار نزدیک به مقدار ۱، دقت طبقه‌بندی مدل را در شناسایی سطوح مختلف آلاینده تأیید می‌کند.



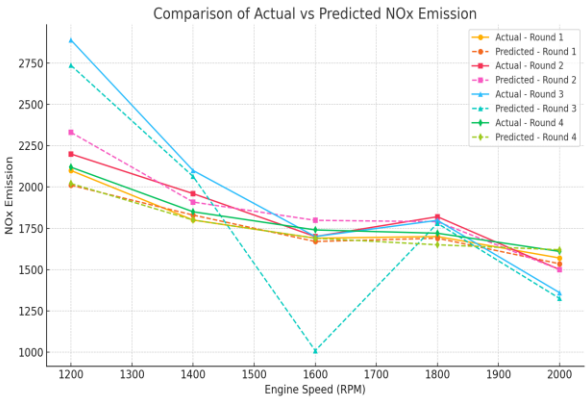
شکل ۹- نمودار ROC مدل DCNN پیشنهادی

برای پیشگیری از بیش‌برازش (Overfitting) و افزایش اطمینان از تعمیم‌پذیری مدل، چندین رویکرد مکمل اتخاذ شده است. نخست، داده‌ها به‌صورت جداگانه به سه مجموعه آموزش (۷۰٪)، آزمون (۱۵٪)، و اعتبارسنجی (۱۵٪) تقسیم شده‌اند. دوم، از تکنیک Dropout با نرخ مناسب در لایه‌های LSTM استفاده شده تا وابستگی بیش‌ازحد به داده‌های آموزش کاهش یابد. همچنین تفاوت عملکرد میان آموزش و تست در شاخص‌های ارزیابی در

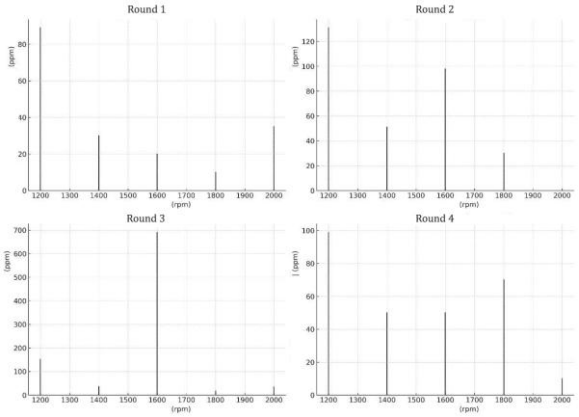
UNCORRECTED PROOF

حداقل مقدار قرار دارد که نشـان از تعادل در آموزش مدل دارد.

برای اثبات علمی برتری مدل پیشـنهادی، نخسـت، تحلیل عددی دقیق روی چهار متریک اصـلی (MAE، RMSE، R^2، MAPE) صـورت گرفته و در جدول ۳ ارائه شـده اسـت. دوم، نمودار مقایسـه مقادیر پیش‌بینی‌شـده و واقعی (شـکل ۱۰) در چند بازه زمانی مختلف (s۲۵، s۴۰، s۶۵، s۱۲۰) و نمودار خطای مطلق در هر سـرعت (شـکل ۱۱) نشـان می‌دهد که مدل در بازسـازی رفتار دینامیک انتشـار NOx به‌طور دقیق عمل کرده اسـت. سـوم، اسـتفاده از نمودار ROC (شکل ۹) نیز شواهد تصویری واضحی برای صـحت عملکرد مدل فراهم می‌کنند. در نهایت، بررسـی دقیق معماری مـدل‌هـا در جـدول ۵ اثبـات می‌کنـد کـه ساختار پیشنهادی از سایر مدل‌های معرفی شده پیچیده‌تر، منسجم‌تر و از نظر ریاضی بهینه‌تر است. شکل ۱۰ مقایسه گرافیکی بین مقادیر واقعی و پیش‌بینی‌شـده NOx در دورهای مختلف موتور را نمایش می‌دهد. همان‌طور که مشـاهده می‌شـود، مدل پیشـنهادی در تمامی دورها رفتار دینامیکی NOx را با دقت بالا بازتولید کرده و انحراف پیش‌بینی‌ها در حداقل مقدار ممکن قرار دارد برای تحلیل دقت موضـعی مدل در شـرایط عملیاتی متنوع، خطای مطلق پیش‌بینی برای هر دور موتور محاسـبه و به‌صـورت نمودار در شـکل ۱۱ ارائه شـده اسـت. مقادیر پایین خطای مطلق در اکثر بازه‌ها مؤید تعمیم‌پذیری مناسـب مدل و عملکرد پایدار آن تحت شرایط مختلف بارگذاری است.



شکل ۱۰- مقایسه مقادیر پیش‌بینی‌شده و واقعی در بازه‌های زمانی مختلف (s۲۵، s۴۰، s۶۵، s۱۲۰)



شکل ۱۱- خطای مطلق در هر سرعت و در بازه‌های زمانی مختلف (s۲۵، s۴۰، s۶۵، s۱۲۰)

۵-نتیجه گیری و پیشنهادات آتی

در این مطالعه یک مدل عمیق DCNN برای پیش‌بینی میزان انتشار NOx از یک موتور اشتعالی تراکمی دوگانه‌سوز پیشنهاد شد. در مدل DCNN پیشنهادی با انتخاب فراپارامترهای بهینه، ویژگی‌های مهم توسط قابلیت‌های CNN استخراج و کشف رابطه‌ی بین سری‌های زمانی مختلف توسط قابلیت‌های LSTM انجام شد. برای آموزش مدل پیشنهادی یک مجموعه داده با انتخاب ویژگی‌های مهم و موثر در انتشار NOx از موتور اشتعالی تراکمی دوگانه‌سوز (مدل MT440C) تهیه و مورد استفاده قرار گرفت. جمع آوری داده با اندازه‌گیری و ثبت مقدار پارامترهای ورودی به موتور و میزان انتشار NOx در یک بازه زمانی استاندارد انجام شد. به منظور آماده‌سازی داده‌ها برای فرآیند آموزش برخی پیش پردازش‌های اولیه بر روی داده‌ها انجام شد. ادغام قابلیت‌های دو مدل CNN و LSTM، مدل پیشنهادی را قادر می‌سازد تا رابطه پیچیده بین ویژگی‌های داده‌های انتشارات گذرا را آشکار کند و دقت پیش‌بینی انتشار NOx موتور اشتعالی تراکمی دوگانه‌سوز را افزایش دهد. بیشترین گشتاور تولیدی موتور در حالت دیزل تنها، در سرعت دورانی ۱۴۰۰ دور بر دقیقه ۳۳۰ نیوتن‌متر و در حالت سوخت ترکیبی ۲۶۵ نیوتن‌متر در سرعت دورانی ۱۶۰۰ دور بر دقیقه بود که این نتایج نشان داد در حالت سوخت ترکیبی ۶۵ نیوتن‌متر کاهش گشتاور وجود داشت. به عنوان تحقیقات آتی، می‌توان از مجموعه داده‌های مختلف بر روی موتورهای مختلف برای بررسی عملکرد روش پیشنهادی یا از انواع الگوریتم‌های فرا ابتکاری استفاده کرد.

UNCORRECTED PROOF

مراجع

[1] Olujobi, O. J., Okorie, U. E., Olarinde, E. S., & Aina-Pelemo, A. D. (2023). Legal responses to energy security and sustainability in Nigeria's power sector amidst fossil fuel disruptions and low carbon energy transition. *Heliyon*, *9*(7).

[2] Matallah, S., Boudaoud, S., Matallah, A., & Ferhaoui, M. (2023). The role of fossil fuel subsidies in preventing a jump-start on the transition to renewable energy: Empirical evidence from Algeria. *Resources Policy*, *86*, 104276.

[3] Bhagat, R. N., Sahu, K. B., Ghadai, S. K., & Kumar, C. B. (2023). A review of performance and emissions of diesel engine operating on dual fuel mode with hydrogen as gaseous fuel. *International Journal of Hydrogen Energy*, *48*(70), 27394-27407.

[4] Bhagat, R. N., Sahu, K. B., Ghadai, S. K., & Kumar, C. B. (2023). A review of performance and emissions of diesel engine operating on dual fuel mode with hydrogen as gaseous fuel. *International Journal of Hydrogen Energy*, *48*(70), 27394-27407.

[5] Al-Yafei, H., Aseel, S., Kucukvar, M., Onat, N. C., Al-Sulaiti, A., & Al-Hajri, A. (2021). A systematic review for sustainability of global liquified natural gas industry: A 10-year update. *Energy Strategy Reviews*, *38*, 100768.

[6] Reji, A. K., Das, B., Ray, T. K., & Boral, E. (2025). Assessment of compressed natural gas as an alternative transportation fuel in reducing CO2 emission: a case of Agartala city. *Environment, Development and Sustainability*, 1-25.

[7] Cudjoe, D., & Zhu, B. (2025). Power generation from food waste bio-compressed natural gas: Economic feasibility. *Renewable and Sustainable Energy Reviews*, *209*, 115110.

[8] Ji, F., Meng, S., Han, Z., Dong, G., & Reitz, R. D. (2025). Progress in knock combustion modeling of spark ignition engines. *Applied Energy*, *378*, 124852.

[9] Dahham, R. Y., Wei, H., Zhang, R., Li, J., Shu, G., & Pan, J. (2025). Numerical study for the comparison between direct dual-fuel stratification and reactivity-controlled compression ignition of ammonia-based engines. *Applied Thermal Engineering*, *258*, 124624.

[10] Ghomashi, M. A. and Kazemi, R. (2024). Motion path following coordinated control for in-wheel motor electric vehicle via implementation robust control and optimal control. *Journal of Modeling in Engineering*, (in Persian)

[11] Ghayebi, H., Minaei, A. and Hasanzadeh, M. (2024). Cogeneration system based on combined Brayton and inverse Brayton cycle based on biogas fuel. *Journal of Modeling in Engineering*, (in Persian)

[12] Li, Y., Li, G., Li, H., Liu, W., Ji, J., Lu, S., ... & Peng, H. (2025). Promoting metal oxides–zeolite electron interaction on MnCeOx/HY catalyst for boosting nitrogen oxides reduction. *Applied Catalysis B: Environment and Energy*, *360*, 124535.

[13] Mohan, B., & AlRamadan, A. S. (2025). Estimation of cetane number using machine learning. *Fuel*, *381*, 133462.

[14] Niknam, Y. (2024). NOX Emission Prediction of a dual-fuel (Diesel+ CNG) Compression Ignition Engine Using the DCNN model. *Power System Technology*, *48*(1), 1034-1053.

[15] Niknam, Y., MohammadZamani, D., & Gholami Pareshkoohi, M. (2024). Converting compression ignition engine to dual-fuel (diesel+ CNG) engine and experimentally investigating its performance and emissions. *Open Agriculture*, *9*(1), 20220319.

[16] Hoseini, F., & Sepehrzadeh, H. (2024). Normal and Abnormal Masses Detection in Mammography Images Using Deep Convolutional Neural Network (DCNN). *Journal of Modeling in Engineering*, *22*(79), 29-43. (in Persian)

[17] Ramu, K., Patthi, S., Prajapati, Y. N., Ramesh, J. V. N., Banerjee, S., Rao, K. B., & Alzahrani, S. I. (2025). Hybrid CNN-SVM model for enhanced early detection of Chronic kidney disease. *Biomedical Signal Processing and Control*, *100*, 107084.

[18] Hoseini, F., & Yaghoobi Notash, A. (2024). Image Captioning by Using Bidirectional LSTM Neural Network. *Available at SSRN 4785040*.

[19] Hoseini, F., Shamlou, S., & Ahmadi-Gharehtoragh, M. (2024). Segmentation of MR images for brain tumor detection using autoencoder neural network. *Discover Artificial Intelligence*, *4*(1), 1-20.

[20] Seshan, S., Poinapen, J., Zandvoort, M. H., van Lier, J. B., & Kapelan, Z. (2025). Forecasting nitrous oxide emissions from a full-scale wastewater treatment plant using LSTM-based deep learning models. *Water Research*, *268*, 122754.

[21] Shen, Q., Wang, G., Wang, Y., Zeng, B., Yu, X., & He, S. (2023). Prediction Model for Transient NOx Emission of Diesel Engine Based on CNN-LSTM Network. *Energies*, *16*(14), 5347.

[22] Pillai, R., Triantopoulos, V., Berahas, A. S., Brusstar, M., Sun, R., Nevius, T., & Boehman, A. L. (2022). Modeling and predicting heavy-duty vehicle engine-out and tailpipe nitrogen oxide (NOx) emissions using deep learning. *Frontiers in Mechanical Engineering*, *8*, 11.

[23] Saif-Ul-Allah, M. W., Khan, J., Ahmed, F., Salman, C. A., Gillani, Z., Hussain, A., & Hasan, M. (2022). Computationally Inexpensive 1D-CNN for the Prediction of Noisy Data of NOx Emissions From 500 MW Coal-Fired Power Plant. *Frontiers in Energy Research*, *10*, 945769.

[24] Yu, Y., Wang, Y., Li, J., Fu, M., Shah, A. N., & He, C. (2021). A Novel Deep Learning Approach to Predict the Instantaneous NO_x Emissions from Diesel Engine. *Ieee Access*, *9*, 11002-11013.

[25] Li, N., & Hu, Y. (2020). The deep convolutional neural network for NOx emission prediction of a coal-fired boiler. *IEEE Access*, *8*, 85912-85922.

[26] He, W., Li, J., Tang, Z., Wu, B., Luan, H., Chen, C., & Liang, H. (2020). A novel hybrid CNN-LSTM scheme for nitrogen oxide emission prediction in FCC unit. *Mathematical Problems in Engineering*, *2020*, 1-12.

[27] Mohammadhassani, J., Dadvand, A., Khalilarya, S., & Solimanpur, M. (2015). Prediction and reduction of diesel engine emissions using a combined ANN–ACO method. *Applied Soft Computing*, *34*, 139-150.

[28] Hoseini, F., Shahbahrami, A., & Bayat, P. (2019). AdaptAhead optimization algorithm for learning deep CNN applied to MRI segmentation. *Journal of digital imaging*, *32*, 105-115.

UNCORRECTED PROOF