



تخمین هوشمند آلاینده‌گی و مصرف سوخت یک خودرو سبک بنزینی با رویکرد مبتنی بر شبکه‌های عصبی عمیق حافظه‌دار در شرایط رانندگی واقعی

محمد پارسا شهابی نیا^۱، علی باغانی^{۲*}، امیرحسین وفا^۳، میثم صالحی^۴، احمد قاسمی قلعه بهمن^۵، محمد مومنی^۶

parsha.shahabiniya@semnan.ac.ir

alibaghani1377@gmail.com

parsha.shahabiniya@semnan.ac.ir

me_salehi@ip-co.com

ghasemi@semnan.ac.ir

m_momeni@ip-co.com

^۱دانشجوی کارشناسی، دانشکده مهندسی مکانیک، دانشگاه سمنان، سمنان، ایران

^{۲*}دانشجوی کارشناسی ارشد، دانشکده مهندسی مکانیک، دانشگاه صنعتی شریف، تهران، ایران

^۳کارشناس اداره طراحی دسته‌سیم و پشتیبانی آزمون‌ها، شرکت تحقیق، طراحی و تولید موتور ایران خودرو، تهران، ایران

^۴رئیس اداره آلاینده‌گی و EOB، شرکت تحقیق، طراحی و تولید موتور ایران خودرو، تهران، ایران

^۵دانشیار، دانشکده مهندسی مکانیک، دانشگاه سمنان، سمنان، ایران

^۶رئیس اداره کل نگاشت سامانه مدیریت موتور، شرکت تحقیق، طراحی و تولید موتور ایران خودرو، تهران، ایران

چکیده

در این پژوهش، مدلی مبتنی بر شبکه عصبی مصنوعی برای پیش‌بینی همزمان آلاینده‌گی و مصرف سوخت خودرو در شرایط رانندگی واقعی توسعه یافت. داده‌های چرخه استاندارد NEDC برای آموزش و اعتبارسنجی مدل استفاده شدند. ورودی‌های مدل شامل سرعت خودرو و موتور، زاویه پدال و دریچه گاز، دمای هوای ورودی موتور، آب رادیاتور، دود خروجی قبل از پالایشگر و مرکز پالایشگر، زاویه جرقه و میل‌بادامک و فشار ورودی هوا بعد از دریچه گاز بود که مستقیماً بر تولید آلاینده‌ها تأثیر دارند. نتایج نشان داد شبکه حافظه‌دار توانست روند تغییرات کلیدی آلاینده‌ها شامل کربن مونوکسید، اکسیدهای نیتروژن و مصرف سوخت را با دقت بالا بازتولید کند. مقایسه دو چرخه نشان داد آلاینده‌گی و مصرف سوخت در شرایط واقعی به‌طور قابل‌توجهی بالاتر است که ناشی از توقف‌های مکرر، شتاب‌گیری‌های ناگهانی و تأخیر فعال‌سازی کاتالیست است. یافته‌ها بیانگر آن است که شبکه‌های عصبی جایگزین مناسبی برای آزمون‌های پرهزینه اندازه‌گیری آلاینده‌گی هستند و می‌توانند ابزارهای پیش‌بینی دقیق برای حمل‌ونقل پایدار و سیاست‌های زیست‌محیطی فراهم کنند.

کلیدواژه‌ها: مصرف سوخت، آلاینده‌گی، مدلسازی، شبکه عصبی مصنوعی عمیق حافظه‌دار، آلاینده‌گی رانندگی واقعی



Intelligent Estimation of Emissions and Fuel Consumption of a Light-Duty Gasoline Vehicle Using a Deep Recurrent Neural Network under Real Driving Conditions

Mohammad Parsa Shahabiniya¹, Ali Baghani^{2*}, Amir Hossein Vafa³, Meysam Salehi⁴, Ahmad Ghasemi Ghalebahman⁵, Mohammad Momeni⁶

¹Bachelors student, Faculty of Mechanical Engineering, Semnan University, Semnan, Iran

parsa.shahabiniya@semnan.ac.ir

^{2*}Master's student, Faculty of Mechanical Engineering, Sharif University of Technology, Tehran, Iran

alibaghani1377@gmail.com

³Technician in wiring harness design and maintenance department, Iran Khodro Engine Research, Design and Production Co. Tehran, Iran

parsa.shahabiniya@semnan.ac.ir

³Head of Emissions and EOBD Department, Iran Khodro Engine Research, Design and Production Co. Tehran, Iran

me_salehi@ip-co.com

⁵Associate Professor, Faculty of Mechanical Engineering, Semnan University, Semnan, Iran

ghasemi@semnan.ac.ir

⁶Head of Engine Management System Mapping Department, Iran Khodro Engine Research, Design and Production Company, Tehran, Iran

mailto:m_momeni@ip-co.com

Abstract

In this study, a neural network-based model was developed to simultaneously predict vehicle emissions and fuel consumption under real-world driving conditions. The standard NEDC cycle data were used for training and validation of the model. The input variables included vehicle and engine speed, pedal and throttle position, intake air and coolant temperature, exhaust gas before and after the catalytic converter, spark timing, camshaft angle, and intake manifold pressure after the throttle, all of which directly influence pollutant formation. The results showed that the recurrent neural network successfully reproduced the key variations in carbon monoxide, nitrogen oxides, and fuel consumption with high accuracy. A comparison between the two driving cycles revealed that both emissions and fuel consumption were considerably higher in real-world conditions, mainly due to frequent stops, sudden accelerations, and catalyst activation delays. The findings indicate that neural networks can serve as an effective alternative to costly emission measurement tests and can provide accurate prediction tools to support sustainable transportation and environmental policymaking.

Keywords: fuel consumption, emissions, modeling, deep recurrent neural network, real driving emissions



۱. مقدمه

احتراق سوخت‌های فسیلی به‌ویژه در بخش حمل‌ونقل از مهم‌ترین منابع آلودگی هوا و گازهای گلخانه‌ای به‌شمار می‌رود که سلامت انسان و پایداری محیط‌زیست را تهدید می‌کند [۱]. سهم قابل توجه بخش حمل‌ونقل جاده‌ای در انتشار آلاینده‌هایی نظیر اکسیدهای نیتروژن^۱، کربن مونوکسید^۲ و هیدروکربن^۳ سبب شده است کنترل آلاینده‌گی وسایل نقلیه به یکی از چالش‌های اصلی سیاست‌گذاران حوزه انرژی و محیط زیست بدل شود [۳،۲]. اگرچه پیشرفت خودروهای برقی در سال‌های اخیر قابل توجه بوده است، پیش‌بینی‌ها نشان می‌دهد که در دهه‌های آتی همچنان موتورهای احتراق داخلی غالب‌ترین فناوری در صنعت حمل‌ونقل باقی خواهند ماند [۴]. از این‌رو توسعه روش‌های نوین برای پایش و پیش‌بینی آلاینده‌گی خودروها تحت شرایط واقعی رانندگی ضروری به نظر می‌رسد. روش‌های مرسوم آزمون آلاینده‌گی، نظیر آزمون‌های شاسی‌دینامومتر با چرخه‌های استاندارد مانند NEDC و WLTC، اغلب قادر به بازنمایی دقیق شرایط واقعی رانندگی شامل رفتار راننده، وضعیت ترافیک، شرایط جاده و اقلیم نیستند و بنابراین برآوردی کمتر از مقادیر واقعی انتشار آلاینده‌ها ارائه می‌کنند [۵]. به همین دلیل، سیستم‌های قابل حمل اندازه‌گیری آلاینده‌گی^۴ معرفی شدند که امکان سنجش آلاینده‌ها را در شرایط واقعی رانندگی فراهم می‌سازند [۷،۶]. با این وجود، هزینه بالای تجهیزات اندازه‌گیری آلاینده‌گی قابل حمل و نیاز به نگهداری ویژه، کاربرد گسترده آن‌ها را محدود کرده است. در دهه گذشته، شبکه‌های عصبی مصنوعی^۵ و به‌طور کلی یادگیری ماشین به‌عنوان ابزاری قدرتمند در تحلیل داده‌های پیچیده و غیرخطی در حوزه خودرو مورد توجه ویژه قرار گرفته‌اند [۹،۸]. کاربردهای این روش‌ها از مدیریت انرژی و مصرف سوخت تا پایش سلامت خودرو و پیش‌بینی عمر مفید باقی‌مانده اجزا گسترش یافته است [۱۰]. در زمینه آلاینده‌گی نیز پژوهش‌های متعددی نشان داده‌اند که شبکه عصبی مصنوعی می‌تواند رفتار انتشار آلاینده‌ها را به‌خوبی یاد بگیرد و حتی برای طراحی راهبردهای کنترلی به‌کار گرفته شود [۱۱-۱۳].

چالش اصلی در پیش‌بینی آلاینده‌گی واقعی خودرو، پیچیدگی فرآیند تشکیل آلاینده‌ها و نقش کلیدی مبدل کاتالیستی سواره در کاهش آن‌هاست. کارایی این مبدل به‌طور مستقیم به دمای کاتالیست وابسته است؛ به‌ویژه در شرایط سرد بودن موتور^۶ که بازدهی حذف آلاینده‌ها بسیار پایین است [۱۴]. پژوهش‌های متعددی تلاش کرده‌اند با استفاده از شبکه عصبی مصنوعی انتشار آلاینده‌هایی نظیر اکسیدهای نیتروژن، کربن مونوکسید و هیدروکربن را در شرایط گذرا یا واقعی مدل‌سازی

کنند. به‌عنوان مثال، فانگ^۷ و همکاران [۱۵] و شین^۸ و همکاران [۱۶] به پیش‌بینی اکسیدهای نیتروژن در موتورهای دیزلی با استفاده از شبکه‌های عصبی پرداختند. تو^۹ و همکاران [۱۷] با بهره‌گیری از دستگاه اندازه‌گیری آلاینده‌گی قابل حمل آلاینده‌گی پنج خودروی بنزینی و هیبریدی را اندازه‌گیری و با چرخه‌های استاندارد مقایسه کردند.

وانگ^{۱۰} و همکاران [۱۸] و پان^{۱۱} و همکاران [۱۹] نیز از ترکیب الگوریتم‌های بهینه‌سازی و مدل‌های شبکه عصبی مصنوعی برای پیش‌بینی آلاینده‌های مختلف در خودروهای شهری و اتوبوس‌ها استفاده کردند. با وجود این تلاش‌ها، اکثر مطالعات موجود یا متکی به داده‌های پرهزینه دستگاه اندازه‌گیری آلاینده‌گی قابل حمل بوده‌اند یا اثر دمای کاتالیست سواره را در پیش‌بینی آلاینده‌گی نادیده گرفته‌اند. این در حالی است که شواهد تجربی نشان می‌دهد دمای کاتالیست نقشی حیاتی در تعیین مقادیر کربن مونوکسید، اکسیدهای نیتروژن و هیدروکربن در لوله اگزوز دارد، به‌ویژه در شروع رانندگی که آلاینده‌ها چندین برابر مقادیر پایدار خود تولید می‌شوند [۲۱،۲۰]. در همین راستا، نیاز به رویکردی نوین برای پیش‌بینی آلاینده‌گی واقعی بر اساس داده‌های چرخه‌های استاندارد آزمایشگاهی و با لحاظ کردن اثر دمای کاتالیست امری ضروری است.

۲. روش پژوهش

در مطالعه حاضر، آلاینده‌گی واقعی خودرو بدون استفاده از سیستم‌های قابل حمل اندازه‌گیری آلاینده‌گی پیش‌بینی می‌شود. در این راستا، آلاینده‌های خروجی اگزوز خودرو در مرکز آزمون آلاینده‌گی تحت چرخه‌های رانندگی استاندارد مختلف اندازه‌گیری شدند. این داده‌ها برای آموزش یک شبکه عصبی مصنوعی در پیش‌بینی آلاینده‌گی واقعی رانندگی مورد استفاده قرار گرفتند. لازم به ذکر است در حدود یازده هزار مجموعه داده مستخرج از آزمایشات صورت گرفته بر یک خودرو به دو شبکه عصبی متوالی داده شدند. شبکه نخست دمای کاتالیست را در طول رانندگی پیش‌بینی می‌کند. خروجی این شبکه، به‌همراه سرعت خودرو، شتاب، و شماره دنده، به‌عنوان ورودی به شبکه دوم داده می‌شود تا آلاینده‌های خروجی اگزوز پیش‌بینی گردد. در شکل ۱ انتخاب ویژگی‌ها، معماری شبکه، ورودی‌های هر یک از شبکه‌ها و ارزیابی عملکرد و به‌طور کلی نمایی از این پژوهش نشان داده شده است.

⁷ Fang

⁸ Shin

⁹ Tu

¹⁰ Wang

¹¹ Pan

¹ NOx

² CO

³ HC

⁴ PEMS


⁵ ANN

⁶ cold-start



جدول ۱: مشخصات فنی خودرو


ردیف	نوع مشخصه	مقدار	واحد
۱	نوع موتور	TU5	-
۲	حجم موتور	۱۵۸۷	cc
۳	حداکثر توان	۱۰۵	hp
۴	حداکثر گشتاور	۱۴۲	Nm
۵	سیستم انژکتور	پاشش چند نقطه ای	-
۶	نوع سوخت	بنزین	-
۷	تعداد سوپاپ	۱۶	-
۸	وزن	۱۰۸۷	kg



شکل ۱: شماتیک پیش‌بینی آلاینده‌گی واقعی رانندگی در مطالعه حاضر

۱.۲. آزمایش

آزمایش‌ها بر روی خودروی پژو ۲۰۷ اتوماتیک از محصولات شرکت ایران خودرو در شرکت تحقیق، طراحی و تولید موتور ایران خودرو (ایپکو) انجام شد. به منظور آموزش یک شبکه عصبی مصنوعی^۱ پایدار و دقیق، نیاز به مجموعه داده‌های تجربی جامع وجود دارد. در این راستا مقادیر آلاینده‌های خروجی آگروز خودرو در چرخه رانندگی استاندارد NEDC اندازه‌گیری و استخراج شد. علاوه بر آلاینده‌ها، پارامترهای دیگر خودرو نظیر شماره دنده، سرعت و شتاب خودرو نیز از واحد کنترل الکترونیکی موتور^۲ استخراج شدند. در این راستا از نرم‌افزار INCA جهت برداشت داده‌ها از واحد کنترل الکترونیکی موتور استفاده گردید. مشخصات فنی خودروی آزمون در جدول ۱ و تصویری از آن در شکل ۲ قابل مشاهده است.



شکل ۳: تصویری از خودرو ۲۰۷ اتوماتیک در آزمایشگاه آلاینده‌گی شرکت تحقیق، طراحی و تولید موتور ایران خودرو (ایپکو)

۲.۲. شبکه عصبی مصنوعی

به منظور پیش‌بینی دقیق آلاینده‌گی‌های خروجی خودرو در شرایط رانندگی واقعی، از شبکه‌های عصبی مصنوعی بهره گرفته شده است. انتخاب این روش به دلیل توانایی بالای آن در مدل‌سازی روابط غیرخطی و پیچیده میان متغیرهای ورودی و خروجی است. لازم به ذکر است فرآیند طراحی و پیاده‌سازی مدل شامل سه گام اساسی است: انتخاب ویژگی‌ها، پیش‌پردازش داده‌ها و تعیین معماری شبکه و ارزیابی عملکرد است. در مرحله نخست، بر اساس مرور مطالعات پیشین و تحلیل داده‌های تجربی، متغیرهای ورودی اصلی شامل سرعت خودرو، شتاب، شماره دنده و دمای کاتالیست در نظر گرفته شدند. اهمیت این پارامترها از آن جهت است که هر یک اثر مستقیمی بر تولید آلاینده‌ها



شکل ۲: تصویری از خودرو ۲۰۷ اتوماتیک

² ECU


¹ ANN



جدول ۲: مشخصات لایه های شبکه های عصبی مصنوعی


ردیف	تعداد مشخصه ها	فرمت خروجی	لایه
۱	0	(None, 10, 10)	Input Layer
۲	1,071,104	(None, 10, 512)	LSTM
۳	2,099,200	(None, 10, 512)	LSTM_1
۴	2,099,200	(None, 10, 512)	LSTM_2
۵	0	(None, 512)	Sum Layer
۶	131,328	(None, 256)	Dense
۷	32,896	(None, 128)	Dense_1
۸	8,256	(None, 64)	Dense_2
۹	520	(None, 8)	Dense_3

همان‌طور که در جدول ۲ درج شده است ساختار شبکه عصبی مصنوعی مورد استفاده از نوع شبکه بازگشتی حافظه‌دار طولانی مدت یا LSTM است که قابلیت نگهداری و یادآوری وابستگی‌های زمانی داده‌ها را دارد. وجود سه لایه‌ی متوالی با ۵۱۲ نورون در هر لایه، امکان درک و تحلیل توالی زمانی متغیرهای دینامیکی رانندگی مانند سرعت، شتاب و دمای مبدل را فراهم کرده است. پس از این لایه‌ها، چند لایه‌ی کاملاً متصل^۴ برای استخراج ویژگی‌های نهایی و تولید خروجی مورد استفاده قرار گرفته است. در این ساختار، در نظر گرفتن حافظه‌ی درونی شبکه و لایه‌ی جمع نقش مهمی در بهبود دقت پیش‌بینی دمای کاتالیست و به تبع آن، تخمین دقیق آلاینده‌های خروجی دارد. لازم به ذکر است در شکل ۵ مجموعه داده‌های چرخه‌های رانندگی به کار رفته در فرآیند آموزش و اعتبارسنجی شبکه، شامل سیکل استاندارد NEDC و سیکل رانندگی نشان داده شده است.



شکل ۵: چرخه های رانندگی برای آموزش شبکه عصبی مصنوعی

دارند؛ به‌ویژه آلاینده‌های کلیدی نظیر مونوکسید کربن، هیدروکربن‌های نسوخته و اکسیدهای نیتروژن به شدت تحت تأثیر شرایط دمایی کاتالیست و وضعیت گذرای موتور قرار دارند. در گام دوم، داده‌های خام جمع‌آوری‌شده از چرخه‌های رانندگی، با استفاده از روش Z-Score نرمال‌سازی شدند تا از بروز عدم‌تعادل در مقیاس متغیرها جلوگیری شود و پایداری آموزش شبکه بهبود یابد. سپس در گام سوم، معماری شبکه طراحی و بهینه‌سازی گردید. لایه‌های ورودی شامل پارامترهای انتخاب‌شده رانندگی و شرایط عملکردی خودرو بودند، در حالی که خروجی شبکه مقادیر پیش‌بینی‌شده آلاینده‌های خروجی اگزوز را نشان می‌داد. انتخاب تعداد نورون‌ها در لایه‌های میانی و تنظیم ابرپارامترها با استفاده از روش‌های جستجوی تصادفی انجام شد تا ضمن کاهش هزینه‌های محاسباتی، دقت مدل در پیش‌بینی بهینه گردد. به منظور ارزیابی عملکرد مدل، شاخص‌های متداول از جمله ریشه میانگین مربعات خطا^۱، میانگین قدرمطلق خطا^۲ و ضریب همبستگی^۳ مورد استفاده قرار گرفتند. نتایج نشان دادند که شبکه طراحی‌شده قادر است با دقت بالا روند تغییرات آلایندگی‌ها را در شرایط واقعی بازتولید نماید. ساختار کلی شبکه عصبی به همراه لایه‌های ورودی، پنهان و خروجی در شکل ۴ ارائه شده است، لازم به ذکر است مشخصه‌های ورودی به شبکه عصبی مصنوعی در شکل ۱ نیز درج شده است.



شکل ۴: ساختار شبکه‌های عصبی مصنوعی


همچنین در جدول ۲ مشخصات لایه های شبکه عصبی مصنوعی درج شده است.

^۴ Dense

^۱ RMSE

^۲ MAE


^۳ R²



شکل ۶: مسیرهای آزمون رانندگی شهری

۳. بحث و نتایج

به منظور ارزیابی کارایی شبکه عصبی طراحی‌شده، مقادیر پیش‌بینی‌شده با داده‌های تجربی مقایسه گردید. همان‌گونه که در شکل ۷ قابل مشاهده است، داده‌های آموزشی و اعتبارسنجی تطابق بالایی با خروجی شبکه دارند و روند تغییرات آلاینده‌ها به‌خوبی بازتولید شده است. ضریب همبستگی میان مقادیر واقعی و پیش‌بینی‌شده ارائه شده که نشان‌دهنده همبستگی قوی و خطای پایین مدل است. نتایج بیانگر آن است که شبکه عصبی قادر است روابط پیچیده میان متغیرهای دینامیکی رانندگی و آلاینده‌های خروجی را با دقت مناسب شبیه‌سازی نماید.



شکل ۷: نتایج صحنه‌گذاری شبکه عصبی مصنوعی

در مجموع، نتایج حاصل از پیاده‌سازی شبکه عصبی مصنوعی نشان داد که این روش قادر است با دقت قابل قبول، روند تغییرات آلاینده‌ها و مصرف سوخت را در شرایط رانندگی واقعی پیش‌بینی کند. به‌ویژه استفاده از پارامترهای کلیدی نظیر دمای کاتالیست و دینامیک رانندگی در بهبود عملکرد مدل نقش تعیین‌کننده‌ای داشت. بدین ترتیب، بخش حاضر نشان‌دهنده آن است که شبکه‌های عصبی می‌توانند به عنوان ابزاری توانمند برای جایگزینی روش‌های سنتی و پرهزینه اندازه‌گیری آلاینده‌گی مورد استفاده قرار گیرند و بستری مناسب برای تحلیل‌های بعدی فراهم سازند.

۳.۲. مسیر رانندگی واقعی و چرخه NEDC

برای آموزش و اعتبارسنجی شبکه عصبی، دو نوع چرخه رانندگی به کار گرفته شد: چرخه استاندارد NEDC و یک چرخه رانندگی واقعی شهری. چرخه NEDC به دلیل ماهیت یکنواخت و تکراری خود، بیشتر بازتاب‌دهنده شرایط آزمایشگاهی است و توانایی محدودی در شبیه‌سازی دینامیک واقعی رانندگی دارد. در مقابل، چرخه واقعی حاصل ثبت داده‌های رانندگی در شرایط شهری بوده و شامل تغییرات ناگهانی سرعت، توقف‌های متعدد و تغییر دنده‌های پی‌درپی است که بیانگر شرایط عملیاتی خودرو در جاده‌های واقعی است. به منظور مقایسه دقیق این دو چرخه، شاخص‌های کلیدی از جمله مسافت طی‌شده، حداقل و حداکثر سرعت، میانگین شتاب مثبت و منفی و درصد زمان شتاب‌گیری در جدول ۳ ارائه شده است. این مقایسه نشان می‌دهد که چرخه واقعی به مراتب متغیرتر از چرخه NEDC است و قابلیت بالاتری در بازنمایی رفتار واقعی آلاینده‌گی خودرو دارد.

جدول ۳: مقایسه مشخصات رانندگی واقعی با سیکل رانندگی NEDC

اندازه‌گیری شده

ردیف	مشخصه	رانندگی واقعی	NEDC	واحد
۱	مسافت	۱۹۵/۰۳	۴۴/۱۴	km
۲	حداقل سرعت	۴۳/۵۸	۳۳/۶۷	km/h
۳	حداکثر سرعت	۱۷۰/۹۵	۱۲۱/۶۳	km/h
۴	شتاب مثبت میانگین	۰/۱۷	۰/۱۶	m/s ²
۵	شتاب منفی میانگین	-۰/۲	-۰/۲	m/s ²
۶	زمان شتاب‌گیری	۳۷/۷۸	۳۳/۹۴	%

همچنین، مسیرهای رانندگی که در طی ۴ روز آزمون رانندگی در آن مسیرها انجام شده در شکل ۶ قابل مشاهده است.



می‌شود. این افزایش به‌ویژه در غلظت آلاینده‌های کربن مونوکسید و اکسیدهای نیتروژن مشهود بوده و می‌توان آن را به ماهیت ناپایدار رانندگی واقعی، توقف‌های مکرر، و تأخیر در رسیدن مبدل کاتالیستی به دمای فعال‌سازی نسبت داد. در مقابل، چرخه‌ی استاندارد NEDC به دلیل ماهیت شبه‌پایدار و یکنواخت خود، مقادیر آلایندگی و مصرف سوخت را کمتر از واقعیت برآورد می‌کند. نتایج حاصل از شبکه‌ی عصبی نشان داد که مدل قادر است اختلاف میان شرایط واقعی و استاندارد را با دقت مناسبی بازتولید نماید؛ به‌گونه‌ای که علاوه بر بازنمایی روند تغییرات، شدت انحراف مقادیر در شرایط واقعی نیز به‌درستی پیش‌بینی شده است. این یافته‌ها بر اهمیت به‌کارگیری ترکیبی داده‌های تجربی واقعی و روش‌های هوش مصنوعی برای دستیابی به مدل‌های پیش‌بینی دقیق و قابل‌اعتماد در تحلیل عملکرد موتور و سامانه‌های پس‌پردازش آلاینده‌ها تأکید دارد.


۴. نتیجه‌گیری

در این پژوهش، رویکردی مبتنی بر شبکه عصبی مصنوعی برای پیش‌بینی آلایندگی‌ها و مصرف سوخت خودرو در شرایط رانندگی واقعی ارائه شد. نتایج نشان داد که مدل طراحی‌شده توانست با دقت بالا روند تغییرات آلاینده‌های کلیدی شامل کربن مونوکسید، هیدروکربن و اکسیدهای نیتروژن را بازتولید کند و علاوه بر آن اختلاف محسوس میان چرخه استاندارد NEDC و چرخه رانندگی واقعی را به‌طور کمی و کیفی آشکار سازد. بر اساس یافته‌ها، مقادیر آلایندگی و مصرف سوخت در چرخه واقعی به‌طور معناداری بیشتر از مقادیر متناظر در چرخه NEDC هستند، که این امر بیانگر محدودیت‌های ذاتی چرخه‌های آزمایشگاهی در بازنمایی شرایط واقعی جاده است. شبکه عصبی مورد استفاده در این مطالعه نه تنها توانست پویایی داده‌های رانندگی واقعی را به‌خوبی در مدل منعکس سازد، بلکه امکان ارزیابی دقیق‌تر اثرات دما، شتاب‌گیری‌های ناگهانی و دینامیک رانندگی بر آلایندگی‌ها را فراهم کرد. این ویژگی نشان می‌دهد که استفاده از روش‌های هوش مصنوعی می‌تواند جایگزین مناسبی برای اندازه‌گیری‌های پرهزینه و زمان‌بر آلایندگی در مقیاس وسیع باشد. در نهایت، نتایج این تحقیق مسیر تازه‌ای را برای توسعه ابزارهای پیش‌بینی مبتنی بر یادگیری ماشین در حوزه حمل‌ونقل پاک ترسیم می‌کند و می‌تواند مبنای تصمیم‌سازی در جهت بهبود سیاست‌های زیست‌محیطی و طراحی نسل آینده سیستم‌های پیشران کم‌آلاینده قرار گیرد.

تشکر و قدردانی

نویسندگان این مقاله مراتب سپاس و قدردانی خود را از شرکت تحقیق، طراحی و تولید موتور ایران خودرو (ایپکو) به دلیل حمایت و همکاری ارزشمند در انجام این پژوهش ابراز می‌دارند.

در مرحله بعد، عملکرد مدل در پیش‌بینی مقادیر مصرف سوخت و آلاینده‌ها مورد بررسی قرار گرفت. در شکل ۸ روند تغییرات آلاینده‌های اصلی شامل CO، NOx و HC تحت چرخه‌های رانندگی مختلف نشان داده شده است. همچنین مقایسه مقادیر عددی میان چرخه NEDC و چرخه واقعی در جدول ۴ ارائه گردیده است. نتایج حاکی از آن است که مقادیر آلایندگی و مصرف سوخت در چرخه واقعی به‌طور محسوسی بالاتر از چرخه NEDC هستند که این امر ناشی از شرایط پویای رانندگی شهری، شتاب‌گیری‌های ناگهانی و تأخیر در فعال‌سازی کاتالیست در شروع رانندگی است. به‌طور خاص، شبکه عصبی توانست با دقت مناسب اختلاف میان این دو چرخه را پیش‌بینی کند و نشان دهد که استفاده صرف از چرخه‌های استاندارد، تصویر کاملی از آلایندگی‌های واقعی خودرو ارائه نمی‌دهد. این یافته اهمیت استفاده از داده‌های واقعی را در کنار مدل‌سازی هوشمند برای دستیابی به برآوردهای دقیق‌تر آشکار می‌سازد.



شکل ۸: مقادیر آلایندگی پیش‌بینی شده

جدول ۴: مقایسه مشخصه‌های رانندگی واقعی و NEDC

ردیف	مشخصه	رانندگی واقعی	NEDC	واحد
۱	مصرف سوخت	۲۰/۷۵	۷/۰۵	L/100
۲	کربن مونوکسید	۲/۴۲	۰/۰۷۸	g/km
۳	اکسیدهای نیتروژن	۰/۸	۰/۰۲	g/km

مصرف سوخت محاسبه‌شده بر اساس داده‌های استخراجی از واحد کنترل الکترونیکی موتور^۱ برابر با ۲۳/۳۳ لیتر در هر ۱۰۰ کیلومتر به‌دست آمد. در مقابل، مقدار مصرف سوخت پیش‌بینی‌شده توسط شبکه‌ی عصبی مصنوعی ۲۰/۷۵ لیتر در هر ۱۰۰ کیلومتر گزارش گردید که بیانگر دقت بالای مدل در تخمین مصرف سوخت تحت شرایط عملیاتی متغیر است. به‌طور کلی، مقایسه‌ی نتایج نشان داد که چرخه‌ی رانندگی واقعی^۲ منجر به افزایش قابل‌ملاحظه در میزان آلایندگی و مصرف سوخت نسبت به چرخه‌ی استاندارد NEDC

² RDE

¹ ECU



پیوست

شکل ۱ با استفاده هوش مصنوعی تولید شده است.

مراجع و منابع

- <https://doi.org/10.1016/j.apenergy.2022.118573>
- [9] Khalil M, Yang H, Hu J, et al. Fuel economy optimization using machine learning approaches. *Energy*. 2022;238:121708. <https://doi.org/10.1016/j.energy.2021.121708>
- [10] Shaheen M, Mehmood F, Hussain S, et al. Remaining useful life prediction using machine learning for automotive applications. *Reliab Eng Syst Saf*. 2023;233:109050. <https://doi.org/10.1016/j.ress.2022.109050>
- [11] Agarwal AK, Mustafi NN. Real-world automotive emissions: Monitoring methodologies and control measures. *Renew Sustain Energy Rev*. 2021;137:110624. <https://doi.org/10.1016/j.rser.2020.110624>
- [12] Norouzi A, Jafari S, Moghaddam M. ANN-based modeling for vehicle emissions prediction. *Energy Rep*. 2021;7:2058-67. <https://doi.org/10.1016/j.egyr.2021.04.036>
- [13] Kakati H, Bhowmick A, Borah DK. Prediction of exhaust emissions using ANN in spark ignition engine. *Fuel*. 2019;252:561-71. <https://doi.org/10.1016/j.fuel.2019.04.057>
- [14] Teymoori MM, Chitsaz I, Baghani A. Influence of catalyst temperature on tailpipe emissions. *Energy Convers Manag*. 2022;258:115470. <https://doi.org/10.1016/j.enconman.2022.115470>
- [15] Fang H, Zhang Y, Huang R, et al. Transient NOx prediction in diesel engines using ANN. *Appl Therm Eng*. 2022;203:117993. <https://doi.org/10.1016/j.applthermaleng.2021.117993>
- [16] Shin M, Lee Y, Park J. Prediction of NOx emissions in diesel engines with ANN. *Energies*. 2020;13(5):1234. <https://doi.org/10.3390/en13051234>
- [17] Tu R, Zhang X, Huang Y, et al. Real driving emissions test of gasoline and hybrid vehicles. *Transp Res Part D*. 2022;105:103214. <https://doi.org/10.1016/j.trd.2022.103214>
- [1] Gaffney JS, Marley NA. The impacts of combustion emissions on air quality and climate – From coal to biofuels and beyond. *Atmos Environ*. 2009;43(1):23-36. <https://doi.org/10.1016/j.atmosenv.2008.09.016>
- [2] Sun X, Zhao H, He L, Zhang Y, Xu H. Traffic congestion and urban air pollution: A global review. *Sci Total Environ*. 2022;806:150527. <https://doi.org/10.1016/j.scitotenv.2021.150527>
- [3] Pastorello C, Melios G. Road transport contribution to NOx emissions in the EU. *Atmos Environ*. 2016;141:234-43. <https://doi.org/10.1016/j.atmosenv.2016.06.031>
- [4] U.S. Energy Information Administration. Annual Energy Outlook 2021 with projections to 2050. Washington, DC: U.S. DOE/EIA; 2021.
- [5] Frey HC, Roupail NM, Zhai H, Farias TL, Gonçalves GA. Comparing real-world fuel consumption for diesel- and hydrogen-fueled transit buses and implication for emissions. *J Air Waste Manag Assoc*. 2008;58(7):914-25. <https://doi.org/10.3155/1047-3289.58.7.914>
- [6] Cha J, Lee J, Chon MS. Evaluation of real driving emissions for Euro 6 light-duty diesel vehicles. *Atmos Environ*. 2019;196:133-42. <https://doi.org/10.1016/j.atmosenv.2018.10.046>
- [7] Myung CL, Park S, Kwon S, et al. Real driving emissions using portable emission measurement system. *Appl Energy*. 2017;204:1474-85. <https://doi.org/10.1016/j.apenergy.2017.05.030>
- [8] Ansari A, Abediasl H, Patel PR, Hosseini V, Koch CR, Shahbakhti M. Estimating instantaneous fuel consumption using machine learning and real-time OBD data. *Appl Energy*. 2022;310:118573.



- [20] Fu J, Wang X, Liu Y. Predicting fuel consumption and emissions of SI engines using LM-BP ANN. Fuel. 2022; 310:122349.<https://doi.org/10.1016/j.fuel.2021.122349>
- [21] Wei X, Zhang H, Zhao L. Transient modeling of CO₂ and NO_x using super-learner model. Appl Energy. 2022;309:118426.<https://doi.org/10.1016/j.apenergy.2021.118426>
- [18] Wang Y, Zhang Z, Li J, et al. ANN-based vehicle-specific power model for emissions prediction. Energy. 2018;165:965-78.<https://doi.org/10.1016/j.energy.2018.09.040>
- [19] Pan W, Li Q, Zhang Y, et al. Emission prediction of LNG buses using GBRT. Appl Energy. 2019; 254:113648.<https://doi.org/10.1016/j.apenergy.2019.113648>