



Semnan University



Research Article

Development of Machine Learning Models for Predicting the Severity and Length of Linear Cracks and the Area of Alligator Cracking in Pavements

Mohammad Sedighian-Fard ^a , Amir Golroo ^{b*} , Hananeh Dehghan-Tezerjani ^c

^a Ph.D. Candidate, Department of Civil and Environmental Engineering, Amirkabir University of Technology (Tehran Polytechnic), Tehran, I. R. Iran.

^b Associate Professor, Department of Civil and Environmental Engineering, Amirkabir University of Technology (Tehran Polytechnic), Tehran, I. R. Iran.

^c M.Sc. Student, Department of Civil and Environmental Engineering, Amirkabir University of Technology (Tehran Polytechnic), Tehran, I. R. Iran.

PAPER INFO

Paper history:

Received: 2025-12-03

Revised: 2025-12-18

Accepted: 2025-12-25

Keywords:

Pavement management system;

Pavement distress prediction;

Long-term pavement performance (LTPP);

Machine learning.

ABSTRACT

Linear and alligator cracking are critical indicators of asphalt pavement performance. Accurate prediction of these critical cracking distresses are of significant importance in effective and efficient pavement maintenance planning. This study proposes a data-driven framework based on multimodal data from the Long-Term Pavement Performance (LTPP) database, incorporating traffic, climatic, and performance-related variables to predict distress severity, length, and area. Key features, including surface distress indices, overlay thickness, traffic characteristics, and climatic indicators, were extracted and refined through feature engineering. Machine learning-based models were developed for severity classification and quantitative distress prediction using Artificial Neural Networks (ANNs). Addressing class imbalance with SMOTE improved severity classification accuracy from 0.782 to 0.843 for linear cracking and from 0.845 to 0.930 for alligator cracking. The models demonstrated strong predictive performance, achieving R^2 values of 0.941 for linear crack length and 0.954 for alligator crack area, supporting their applicability in preventive maintenance and pavement life-cycle management.

* Corresponding author.

E-mail address: agolroo@aut.ac.ir

How to cite this article: Sedighian-Fard, M., Golroo, A., & Dehghan-Tezerjani, H. . (2026). Development of Machine Learning Models for Predicting the Severity and Length of Linear Cracks and the Area of Alligator Cracking in Pavements. *Journal of Transportation Infrastructure Engineering*, 11(4), 79-106.

<https://doi.org/10.1022075/jtie.2025.39921.1749>



مقاله پژوهشی

توسعه مدل‌های یادگیری ماشین برای پیش‌بینی شدت و طول ترک‌های خطی و مساحت ترک‌های پوست سوسماری روسازی

محمد صدیقیان فرد^۱، امیر گل‌رو^{۲*}، حنا دهقان‌طزرجانی^۳

^۱ دانشجوی دکتری، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران)، تهران، ایران.

^۲ دانشیار، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران)، تهران، ایران.

^۳ دانشجوی کارشناسی ارشد، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران)، تهران، ایران.

چکیده

ترک‌های خطی و پوست سوسماری از مهم‌ترین شاخص‌های عملکرد روسازی آسفالتی هستند و پیش‌بینی دقیق آن‌ها نقش کلیدی در برنامه‌ریزی نگهداری دارد. در این پژوهش، با استفاده از داده‌های چندماژوله پایگاه داده عملکرد بلندمدت روسازی (LTPP) شامل متغیرهای ترافیکی، اقلیمی و عملکردی، یک چارچوب داده‌محور برای پیش‌بینی شدت، طول و مساحت خرابی‌های آسفالتی ارائه شده است. ویژگی‌های مؤثر نظیر شاخص‌های خرابی سطحی، ضخامت روکش، مشخصات ترافیکی و شاخص‌های اقلیمی استخراج و پس از مهندسی ویژگی، در مدل‌های یادگیری ماشین شامل طبقه‌بندی شدت و شبکه عصبی مصنوعی به کار گرفته شد. استفاده از روش اسموت (SMOTE) موجب افزایش صحت طبقه‌بندی شدت ترک خطی از ۰/۷۸۲ به ۰/۸۴۳ و ترک پوست سوسماری از ۰/۸۴۵ به ۰/۹۳۰ گردید. نتایج حاکی از عملکرد مناسب مدل‌ها با ضرایب تعیین ۰/۹۴۱ برای پیش‌بینی طول ترک خطی و ۰/۹۵۴ برای مساحت ترک پوست سوسماری بوده و قابلیت کاربرد آن‌ها در نگهداری پیشگیرانه و مدیریت چرخه عمر روسازی را نشان می‌دهد.

اطلاعات مقاله

دریافت مقاله: ۱۴۰۴/۰۹/۱۲

بازنگری مقاله: ۱۴۰۴/۰۹/۲۷

پذیرش مقاله: ۱۴۰۴/۱۰/۰۴

واژه‌های کلیدی:

سیستم مدیریت روسازی، پیش‌بینی خرابی روسازی، برنامه عملکرد بلند مدت روسازی، یادگیری ماشین.

* پست الکترونیک نویسنده مسئول: agolroo@aut.ac.ir

استناد به این مقاله: صدیقیان فرد، م، گل‌رو، ا. و دهقان‌طزرجانی، ح. (۱۴۰۴). توسعه مدل‌های یادگیری ماشین برای پیش‌بینی شدت و طول ترک‌های خطی و مساحت ترک‌های پوست سوسماری روسازی. مهندسی زیرساخت‌های حمل و نقل، ۱۱(۴)، ۷۹-۱۰۶.

<https://doi.org/10.10.22075/jtie.2025.39921.1749>

This is an open access article under the CC-BY 4.0 license. (<https://creativecommons.org/licenses/by/4.0/>)

۱. مقدمه

شبکه‌های روسازی بخش اساسی زیرساخت‌های حمل و نقل به شمار می‌روند و ارزش اقتصادی بسیار بالایی برای جوامع دارند؛ چرا که امکان جابه‌جایی ایمن، سریع و مقرون به صرفه افراد و کالاها را فراهم می‌کنند. عملکرد نامطلوب روسازی نه تنها موجب کاهش ایمنی و افزایش احتمال تصادفات می‌شود (لیو و همکاران، ۲۰۱۹)، بلکه هزینه‌های بهره‌برداری، مصرف سوخت، اثرات محیطی و هزینه‌های نگهداری را نیز افزایش می‌دهد (کنگ و همکاران، ۲۰۲۱). از آنجا که روسازی‌ها برای دوره‌های خدمت طولانی طراحی می‌شوند، تدوین برنامه‌های بهینه نگهداری و بهسازی نیازمند درک دقیق روند تغییرات عملکرد روسازی و پیش‌بینی قابل اتکای رفتار آینده آن است. این امر اهمیت توسعه مدل‌های پیش‌بینی را دوچندان می‌کند، زیرا تصمیم‌گیری‌های مدیریتی و تخصیص منابع مالی به شدت به خروجی این مدل‌ها وابسته است (لیدیگر و همکاران، ۲۰۱۳).

زوال روسازی^۱ فرآیندی است که طی آن کیفیت ساختاری و عملکردی روسازی جاده‌ها در طول زمان کاهش می‌یابد و منجر به بروز خرابی‌هایی مانند ترک‌خوردگی، شیارشدگی، شن‌زدگی و ناهمواری می‌شود. این مفهوم بر پایه تغییرات تدریجی در خواص مکانیکی لایه‌های روسازی، از جمله لایه آسفالتی یا بتنی، تعریف می‌شود که تحت تأثیر عوامل متعددی مانند بارهای ترافیکی مکرر، شرایط محیطی (مانند تغییرات دما، بارندگی و یخبندان)، کیفیت مصالح اولیه و سن روسازی رخ می‌دهد. زوال روسازی نه تنها ایمنی تردد را کاهش می‌دهد، بلکه هزینه‌های نگهداری و تعمیر را افزایش می‌دهد و می‌تواند منجر به از دست رفتن کارایی اقتصادی شبکه حمل و نقل شود. در مهندسی عمران، مدل‌های زوال برای پیش‌بینی این تغییرات استفاده می‌شوند تا مدیران بتوانند برنامه‌های نگهداری پیشگیرانه

را تدوین کنند و عمر مفید روسازی را به حداکثر برسانند. بر اساس بررسی‌های انجام شده، زوال روسازی اغلب به صورت تابعی از زمان، بار معادل محور و عوامل محیطی مدل‌سازی می‌شود که امکان ارزیابی عملکرد آینده روسازی را فراهم می‌کند (جورج و همکاران، ۱۹۸۹).

در سال‌های اخیر، در دسترس بودن داده‌های میدانی گسترده و ناهمگن، به ویژه داده‌های پایگاه داده عملکرد بلندمدت روسازی^۲ (LTPP)، همراه با پیشرفت الگوریتم‌های یادگیری ماشین، مسیر جدیدی برای مدل‌سازی زوال روسازی ایجاد کرده است. این روش‌ها با توانایی استخراج الگوهای پیچیده، مدل‌سازی روابط غیرخطی و تحلیل برهم‌کنش چندین متغیر ساختاری، ترافیکی و اقلیمی، امکان پیش‌بینی تفکیکی انواع خرابی‌ها و شدت آن‌ها را فراهم می‌کنند؛ قابلیت‌هایی که در روش‌های سنتی کمتر قابل دستیابی بوده است. بر این اساس، پژوهش حاضر با هدف توسعه مدل‌های پیش‌بینی شدت و مقدار خرابی‌های آسفالتی، شامل ترک خطی و ترک پوست سوسماری، مبتنی بر داده‌های چندماژوله LTPP و الگوریتم‌های یادگیری ماشین انجام گرفته است. هدف نهایی این پژوهش، افزایش دقت پیش‌بینی، بهبود قابلیت اعتماد مدل‌ها و فراهم‌سازی اطلاعاتی کاربردی برای پشتیبانی از تصمیم‌گیری در سیستم‌های مدیریت روسازی است.

۲. پیشینه پژوهش و مبانی نظری پیش‌بینی

خرابی روسازی

پیش‌بینی زوال روسازی از دهه‌های گذشته یکی از محورهای اصلی مدیریت روسازی بوده و ادبیات آن به‌طور کلی در چهار شاخه عمده قابل طبقه‌بندی است: مدل‌های قطعی، مدل‌های احتمالاتی و تصادفی، مدل‌های مکانیکی-تجربی و مدل‌های پیشرفته مبتنی بر یادگیری

2- Long-Term Pavement Performance (LTPP)

1- Pavement Deterioration

۲۰۲۵). با این حال، چالش‌هایی مانند فرض مارکوف که در آن وضعیت آینده تنها به وضعیت فعلی وابسته است و حساسیت به کمبود داده طولی موجب شده است دقت این مدل‌ها در شرایط اقلیمی و ترافیکی متنوع محدود باشد.

۲-۳. مدل‌های مکانیکی-تجربی

با گسترش داده‌های گسترده و چندمازوله (ترافیک، اقلیم، مصالح، ساختار و عملکرد)، رویکردهای مکانیکی-تجربی^۶ به سرعت به جریان اصلی تحقیقات تبدیل شده‌اند.

مدل‌های مکانیکی-تجربی با استفاده از پاسخ‌های سازه‌ای (تنش، کرنش، تغییرشکل دائم، رفتار خستگی) و واسنجی با داده‌های میدانی، قادر به نمایش واقعی‌تری از مکانیسم‌های ایجاد ترک، شیاردگی و چاله هستند، اما محاسبات پیچیده و نیاز به داده‌های ورودی گسترده مانند خواص مصالح و شرایط محلی از محدودیت‌های آن‌هاست (سودی و همکاران، ۲۰۲۳).

۲-۴. مدل‌های یادگیری ماشین و هوش مصنوعی

در سال‌های اخیر، مدل‌های یادگیری ماشین و یادگیری عمیق شامل شبکه‌های عصبی (رابرتز و آتوه-اوکاین، ۱۹۹۸؛ حمیدی و همکاران، ۲۰۱۷)، درخت‌های تصمیم، XGBoost و مدل‌های ترکیبی به دلیل توانایی نمایش روابط غیرخطی و تعامل دینامیک بین عوامل، دقت بالاتری در پیش‌بینی انواع خرابی از خود نشان داده‌اند (هو و همکاران، ۲۰۲۲). مطالعات جدید با استفاده از داده‌های برنامه LTPP ثابت کرده‌اند که ترکیب داده‌های ترافیکی، اقلیمی و ساختاری در قالب مدل‌های یادگیری ماشین می‌تواند نسبت به روش‌های کلاسیک بهبود قابل توجهی ایجاد کند (خوستو-سیلوا و همکاران، ۲۰۲۱؛ تاماگوسکو و همکاران، ۲۰۲۴).

همچنین، روند جدید پژوهش‌ها به سمت توسعه مدل‌های تفکیکی برای انواع خرابی به جای شاخص‌های

ماشین. هر یک از این رویکردها با فرضیات و کارکردهای متفاوتی توسعه یافته‌اند و درک تکامل آن‌ها برای طراحی مدل‌های کاربردی و قابل اتکا ضروری است.

۲-۱. مدل‌های قطعی

مدل‌های قطعی^۱ بر روابط مستقیم و معادلات ریاضی تکیه دارند و زوال را به صورت تابعی خطی یا غیرخطی از متغیرهای ورودی پیش‌بینی می‌کنند. برای مثال، در این مدل‌ها، کاهش شاخص عملکرد روسازی با استفاده از رگرسیون چندمتغیره^۲ بر اساس سن روسازی و بار ترافیکی محاسبه می‌شود که فرض می‌کند روابط بین عوامل ثابت و بدون عدم قطعیت است. این رویکرد ساده و محاسباتی کم‌هزینه است، اما در مواجهه با تغییرات تصادفی محیطی دقت کمتری دارد. در پژوهش‌های جدید نشان داده شده است که زوال روسازی به شدت تابع تعامل همزمان شرایط ساختاری، ترافیکی و محیطی بوده و مدل‌های قطعی قادر به شبیه‌سازی کامل این تعاملات نیستند (خوستوسیلوا و همکاران، ۲۰۲۱).

۲-۲. مدل‌های احتمالاتی

مدل‌های احتمالی^۳ با هدف غلبه بر محدودیت قطعیت‌گرایی توسعه یافته‌اند. مدل‌های زنجیره مارکوف^۴ (پولوگورتا و همکاران، ۲۰۰۹؛ کوبایاشی و همکاران، ۲۰۱۰)، مدل‌های نیمه‌مارکوف و مدل‌های احتمال انتقال^۵ از پرکاربردترین این روش‌ها هستند. این دسته از مدل‌ها وضعیت روسازی را به صورت مجموعه‌ای از حالت‌های گسسته (مانند «خوب»، «متوسط»، «ضعیف») تعریف کرده و احتمال گذار بین حالت‌ها را بر اساس داده تاریخی تخمین می‌زنند. مطالعات مختلف نشان داده‌اند که این روش‌ها برای تحلیل بلندمدت و سناریوسازی عملکرد آتی روسازی مناسب هستند و می‌توانند عدم قطعیت در داده‌های واقعی را مدل‌سازی کنند (شهید و همکاران،

4- Markov Chain

5- Transition-probability-based

6- Mechanistic-Empirical Models

1 - Deterministic

2- Multiple Regression

3- Probabilistic

توجه قرار گرفته‌اند، اما بسیاری از پژوهش‌ها هنوز داده کافی یا روش مناسب برای این سطح جزئیات ندارند. در جدول ۱، خلاصه انواع مدل‌های پیش‌بینی زوال روسازی، مفهوم اصلی، مزایا، معایب و مثال‌های موردی آورده شده است.

کلی مانند PCI یا IRI حرکت کرده است، زیرا رفتار هر نوع خرابی دارای دینامیک متفاوت و حساسیت ویژه نسبت به ترافیک، اقلیم یا ساختار روسازی است. پیش‌بینی‌های مبتنی بر مقدار (مانند طول ترک یا مساحت پوست سوسماری) و شدت خرابی نیز در سال‌های اخیر مورد

جدول ۱. خلاصه‌ای از انواع مدل‌های پیش‌بینی زوال روسازی

نوع مدل	مفهوم اصلی	مزایا	معایب	مثال
قطعی	روابط ریاضی مستقیم	ساده و سریع	عدم در نظر گرفتن عدم قطعیت	رگرسیون خطی برای پیش‌بینی شاخص ناهمواری بین‌المللی
احتمالی	فرآیندهای تصادفی	مدل‌سازی عدم قطعیت	نیاز به داده‌های احتمالی	زنجیره مارکوف برای وضعیت روسازی
مکانیکی-تجربی	ترکیب فیزیک و داده‌های تجربی	دقیق و واقعی	پیچیده و داده‌محور	مدل طراحی روسازی مکانیکی-تجربی برای شیارشدگی
مبتنی بر یادگیری ماشین	استخراج الگو از داده‌ها	تطبیقی و غیرخطی	نیاز به داده‌های آموزشی زیاد	شبکه‌های عصبی برای پیش‌بینی ترک

شاخص‌های عملکردی مانند شاخص وضعیت روسازی یا شاخص ناهمواری بین‌المللی^۱ است که با استفاده از داده‌های جمع‌آوری شده از ارزیابی‌های میدانی اندازه‌گیری می‌شود. درک این مفهوم ضروری است زیرا اجازه می‌دهد تا مدل‌های پیش‌بینی بر اساس روابط ریاضی یا آماری، رفتار آینده روسازی را شبیه‌سازی کنند و نقاط بحرانی را شناسایی نمایند (شتایت و همکاران، ۲۰۲۲).

ادبیات اخیر تأکید دارد که تعامل میان متغیرهای فوق عامل اصلی غیرخطی بودن و پیچیدگی زوال روسازی است و برخلاف فرض مدل‌های کلاسیک، نمی‌توان تأثیر هر عامل را به صورت مستقل ارزیابی کرد (باسنت و همکاران، ۲۰۲۳). همین موضوع ضرورت طراحی مدل‌های چندعاملی و یادگیری‌محور را تقویت کرده است.

۲-۵. عوامل مؤثر بر زوال روسازی

عوامل مؤثر بر زوال روسازی را می‌توان به دو دسته اصلی عوامل داخلی و خارجی تقسیم نمود. عوامل داخلی شامل کیفیت طراحی و ساخت روسازی، مانند ضخامت لایه‌ها، نوع مصالح و روش‌های اجرا است که پایه مقاومت اولیه روسازی را تشکیل می‌دهند. عوامل خارجی، مانند حجم ترافیک (اندازه‌گیری شده با بار معادل محور استاندارد)، شرایط آب‌وهوایی (مانند چرخه‌های ذوب و یخبندان که منجر به ترک‌های حرارتی می‌شود) و آلودگی‌های زیست‌محیطی، نقش اصلی در تسریع زوال ایفا می‌کنند. برای مثال، بارهای سنگین ترافیکی باعث ایجاد تنش‌های برشی و فشاری در لایه‌های روسازی می‌شوند که به مرور زمان منجر به خستگی سازه‌ای و کاهش سختی می‌گردد. مفهوم اضمحلال در این زمینه به معنای کاهش

¹ International Roughness Index

۲-۶. خلاصه‌های پژوهش

با وجود رشد چشمگیر مدل‌های پیش‌بینی، چند کاستی کلیدی در ادبیات باقی مانده است:

- بیشتر مطالعات بر شاخص‌های کلی مانند IRI یا PCI تمرکز دارند و مدل‌سازی تفکیکی خرابی‌ها (مانند طول ترک خطی، مساحت پوست سوسماری) کمتر انجام شده است؛
- تعامل عوامل ساختاری، ترافیکی و اقلیمی در بسیاری از مدل‌ها ساده‌سازی شده یا لحاظ نشده است؛
- داده‌های واقعی معمولاً نامتعادل، ناقص یا محدود هستند؛
- کمتر مدلی به صورت هم‌زمان شدت خرابی و مقدار خرابی را پیش‌بینی می‌کند.

پژوهش حاضر به طور مستقیم این شکاف‌ها را با استفاده از داده‌های چندماژوله LTTP، مهندسی ویژگی گسترده، مدیریت داده‌های نامتوازن و توسعه مدل‌های یادگیری ماشین برای پیش‌بینی شدت و طول/مساحت انواع خرابی، هدف قرار داده است. این رویکرد بر نیازهای عملی مدیریت روسازی در مقیاس شبکه‌ای تمرکز دارد.

۳. جمع‌آوری داده‌ها

داده‌های مورد استفاده در این پژوهش از پایگاه داده عملکرد بلندمدت روسازی استخراج شده است (ال‌تی‌پی‌پی، ۲۰۲۳؛ پراکا و همکاران، ۲۰۲۱)؛ مجموعه‌ای جامع و بلندمدت که توسط نهادهای فدرال راه ایالات متحده طراحی و پشتیبانی شده و هدف اصلی‌اش جمع‌آوری و نشر داده‌های طولی و ساختاری در مورد بخش‌های روسازی در ایالات متحده و کانادا است. این مجموعه بیش از ۲۵۰۰ قطعه روسازی را شامل می‌شود و برای هر بخش اطلاعاتی همچون مشخصات سازه‌ای و لایه‌ای، مصالح به کار رفته، تاریخچه اجرای عملیات، داده‌های ترافیکی، اطلاعات اقلیمی محلی،

پروفیل و ناهمواری سطح، مشاهدات و گزارش‌های خرابی و شدت آن‌ها و برخی اندازه‌گیری‌های عملکردی ارائه می‌دهد. جمع‌آوری داده‌ها از اوایل دهه ۱۹۹۰ آغاز شده و تا به امروز ادامه دارد. با وجود آن که LTTP شامل مجموعه‌ای از تصاویر و نقشه‌های خرابی نیز هست، ساختار داده‌ای آن عمدتاً جدولی و ویژگی‌محور است. بنابراین برای کاربردهای مبتنی بر یادگیری ماشین (به ویژه مدل‌های

شبکه عصبی مصنوعی^۱ (ANN) و طبقه‌بندی شدت خرابی)، داده‌ها باید از ماژول‌های مختلف (ساختار، ترافیک، اقلیم و عملکرد) استخراج، هم‌تراز و ادغام شوند. در این پژوهش، برای هر نوع خرابی، داده‌های خام بر اساس شناسه یکتای مقطع و سال بازرسی یکپارچه شده و ویژگی‌های مرتبط از منابع مختلف LTTP ترکیب شده است. این فرآیند امکان ایجاد یک مجموعه داده منسجم، پاک‌سازی شده و مناسب برای مدل‌سازی را فراهم کرده است. داده‌های مورد استفاده در این پژوهش از پایگاه داده LTTP استخراج شده‌اند که پوشش جغرافیایی گسترده‌ای را شامل می‌شود. این داده‌ها برای همه ایالت‌های ایالات متحده آمریکا (با کدهای ایالتی از ۰۱ تا ۵۶) و استان‌های کانادا (با کدهای استانی از ۸۱ تا ۹۰) گردآوری شده‌اند که در مجموع حدود ۶۶ ایالت و استان را تشکیل می‌دهند. این پوشش مکانی متنوع، امکان بررسی رفتار روسازی در شرایط اقلیمی، ترافیکی و ساختاری گوناگون را فراهم می‌کند، از مناطق سردسیر شمالی کانادا گرفته تا مناطق گرم و مرطوب جنوبی ایالات متحده، که این تنوع به تعمیم‌پذیری مدل‌های پیش‌بینی کمک شایانی می‌نماید. قطعات روسازی مورد بررسی شامل دو دسته اصلی مطالعات عام روسازی^۲، که بر ارزیابی عملکرد کلی روسازی در شرایط استاندارد تمرکز دارد) و مطالعات

خاص روسازی^۱ (که به بررسی تأثیر عوامل خاص مانند مصالح نوین یا بارهای سنگین می‌پردازد) می‌شوند.

با توجه به حجم بالای اطلاعات (بیش از ۲۵۰۰ قطعه روسازی در کل پایگاه)، ارائه جزئیات همه قطعات در یک جدول واحد چالش‌برانگیز است و منجر به جدولی بسیار بزرگ و غیرکاربردی می‌گردد. بنابراین، برای خلاصه‌سازی، جدول ۲ به صورت کلی کلاس عملکردی راه‌ها، طول متوسط قطعات، عرض متوسط راه و شرایط زهکشی را ارائه می‌دهد. کلاس عملکردی راه‌ها بر اساس سیستم طبقه‌بندی عملکردی راه‌های ایالات متحده و کانادا تعریف شده‌اند و شامل دسته‌هایی مانند راه‌های محلی روستایی، راه‌های جمع‌کننده اصلی روستایی، راه‌های شریانی فرعی روستایی، راه‌های جمع‌کننده فرعی روستایی، راه‌های شریانی اصلی روستایی - بین‌ایالتی، راه‌های شریانی اصلی روستایی - سایر، راه‌های جمع‌کننده شهری، راه‌های شریانی فرعی شهری، راه‌های شریانی اصلی دیگر شهری، راه‌های شریانی اصلی شهری - بین‌ایالتی و راه‌های شریانی اصلی شهری - سایر بزرگراه‌ها یا راه‌های سریع‌السیر می‌شوند.

طول متوسط قطعات راه‌ها حدود ۴۷/۲۲ متر و عرض متوسط آن‌ها حدود ۳/۶ متر است که این ابعاد استاندارد برای ارزیابی‌های میدانی در پایگاه داده LTPP محسوب می‌شوند و امکان مقایسه دقیق بین قطعات مختلف را فراهم می‌کنند.

در خصوص شرایط زهکشی که نقش کلیدی در جلوگیری از تجمع آب و کاهش ترک‌خوردگی ایفا می‌کند، موارد متنوعی مشاهده می‌شود: در برخی قطعات، محل زهکشی بدون زهکشی است و نوع زهکشی زیرسطحی ندارد که اغلب در مناطق خشک‌تر دیده می‌شود. در قطعات دیگر، محل زهکشی پیوسته یا متناوب^۲ است و نوع زهکشی شامل پتوی زهکشی همراه با زهکش‌های طولی، پتوی زهکشی به صورت تنها یا زهکش‌های طولی می‌باشد. همچنین در موارد پیشرفته‌تر، محل زهکشی پیوسته با نوع پتو زهکشی همراه با زهکش‌های طولی ترکیب شده است که این سیستم‌ها در مناطق پربارش برای افزایش عمر روسازی ضروری هستند. این شرایط زهکشی بر اساس ارزیابی‌های میدانی پایگاه LTPP ثبت شده‌اند.

جدول ۲. خلاصه کلاس عملکردی راه‌ها، طول و عرض متوسط قطعات و شرایط زهکشی

شرایط زهکشی (محل و نوع)	کلاس عملکردی راه‌ها
بدون زهکشی زیرسطحی	راه‌های جمع‌کننده محلی روستایی
پیوسته یا متناوب؛ پتوی زهکشی همراه با زهکش‌های طولی یا پتوی زهکشی (به صورت تنها)	راه‌های جمع‌کننده اصلی روستایی
پیوسته؛ پتوی زهکشی همراه با زهکش‌های طولی	راه‌های شریانی فرعی روستایی
بدون زهکشی زیرسطحی	راه‌های جمع‌کننده فرعی روستایی
پیوسته یا متناوب؛ پتوی زهکشی همراه با زهکش‌های طولی یا لایه زهکشی (به صورت تنها)	راه‌های شریانی اصلی روستایی - بین‌ایالتی
پیوسته؛ پتوی زهکشی همراه با زهکش‌های طولی	راه‌های شریانی اصلی روستایی - سایر
بدون زهکشی زیرسطحی	راه‌های جمع‌کننده شهری
پیوسته یا متناوب؛ پتوی زهکشی همراه با زهکش‌های طولی یا لایه زهکشی	راه‌های شریانی فرعی شهری
پیوسته؛ پتوی زهکشی همراه با زهکش‌های طولی	راه‌های شریانی اصلی شهری - سایر
بدون زهکشی زیرسطحی	راه‌های شریانی اصلی شهری - بین‌ایالتی
پیوسته یا متناوب؛ پتوی زهکشی همراه با زهکش‌های طولی یا لایه زهکشی	راه‌های شریانی اصلی شهری - سایر بزرگراه‌ها یا راه‌های سریع‌السیر

توجهی ایجاد می‌کند. علاوه بر این، ادغام این متغیرها با عوامل اقلیمی و ساختاری، مدل‌ها را برای کاربردهای عملی در مدیریت روسازی‌های ملی مناسب می‌سازد.

۴. روش‌شناسی

در این بخش، مدل برای ارزیابی و تخمین خرابی‌های روسازی آسفالتی توسعه داده شده است. این مدل بر پایه داده‌های پایگاه داده برنامه عملکرد بلندمدت روسازی ساخته شده و از ماژول‌های مختلف این پایگاه، شامل ساختار روسازی و ساخت^۲، آب‌وهوا^۳، ترافیک^۴ و عملکرد^۵، برای استخراج ویژگی‌های مرتبط استفاده شده است. تمرکز اصلی بر پیش‌بینی طول ترک خطی (که شامل ترک‌های طولی و عرضی می‌شود) و مساحت ترک پوست سوسماری است. روش‌شناسی شامل مراحل استخراج داده‌ها، پیش‌پردازش، مهندسی ویژگی، اعمال فیلترها و داده‌افزایی و در نهایت توسعه مدل‌های طبقه‌بندی و شبکه عصبی مصنوعی است. این رویکرد با هدف افزایش دقت پیش‌بینی در شرایط داده‌های نامتوازن و پراکنده طراحی شده و از روش‌های یادگیری عمیق برای مدل‌سازی بهره می‌برد.

در این پژوهش، داده‌های مورد استفاده از ماژول‌های مختلف پایگاه داده LTPP شامل ساختار روسازی، ترافیک، اقلیم و عملکرد استخراج شده‌اند که هر ماژول حداقل ۱۳۰۰۰ ردیف داده در بازه زمانی ۱۹۹۷ تا ۲۰۲۴ را پوشش می‌دهد. این داده‌ها شامل ویژگی‌های متنوعی نظیر ضخامت لایه‌ها، بار ترافیکی، پارامترهای اقلیمی (مانند دما، بارش و چرخه‌های یخبندان-ذوب) و شاخص‌های عملکرد روسازی هستند. به منظور توسعه مدل‌های پیش‌بینی خرابی، داده‌های استخراج شده از ماژول‌های مختلف با استفاده از شناسه‌های مشترک نظیر شناسه بخش، سال بازرسی، کد ایالت و شماره بخش با یکدیگر تطبیق داده شدند تا یک

همچنین شرایط ترافیکی در داده‌های پایگاه داده LTPP نقش محوری در مدل‌سازی زوال روسازی ایفا می‌کنند، زیرا بارهای ترافیکی مستقیماً بر تنش‌های وارد بر لایه‌های آسفالتی تأثیرگذار هستند. روند تغییر سالانه بار ترافیکی معادل محور منفرد ۱۸ کیپ^۱ (ESAL) در بازه مورد بررسی از حداقل ۱۸ تا حداکثر ۳۷۸۱۳۲۷ ESAL در سال متغیر است که این دامنه گسترده نشان دهنده تنوع از راه‌های کم‌تردد محلی تا بزرگراه‌های پرترافیک بین‌ایالتی می‌باشد و امکان ارزیابی تأثیر بارهای سبک تا سنگین بر ترک‌خوردگی را فراهم می‌کند. به طور میانگین، ESAL سالانه حدود ۱۵۰۰۰۰ تا ۳۰۰۰۰۰ واحد است، اما در سال‌های پرترافیک (مانند دوره‌های رشد اقتصادی) به سطوح بالایی می‌رسد که این نوسانات واقعی دنیای واقعی را شبیه‌سازی می‌کند و مدل‌ها را برای پیش‌بینی در شرایط متغیر مقاوم می‌سازد. همچنین روند تغییر سالانه ترافیک متوسط روزانه کامیون‌ها (AADTT) از ۱ تا ۱۲۳۱۰ وسیله نقلیه سنگین در روز متغیر است که این بازه از ترافیک ناچیز در راه‌های روستایی تا حجم بالای کامیون‌ها در مسیرهای تجاری را پوشش می‌دهد و میانگین آن حدود ۲۰۰۰ تا ۵۰۰۰ وسیله در روز است که این تنوع به تحلیل تأثیر وسایل سنگین بر خستگی روسازی کمک می‌کند. نسبت حجم به ظرفیت (V/C) نیز بر اساس داده‌ها محاسبه شده و در بازه ۰/۰۵ تا ۱/۲ قرار دارد که مقادیر بالای ۱ نشان دهنده ترافیک اشباع شده است و می‌تواند تسریع‌کننده زوال باشد، در حالی که مقادیر پایین‌تر شرایط پایدارتری را نشان می‌دهند. این شرایط ترافیکی برای پژوهش بسیار مناسب هستند، زیرا دامنه گسترده ESAL و AADTT اجازه می‌دهد تا مدل‌های یادگیری ماشین روابط غیرخطی بین بار ترافیکی و خرابی‌ها را به خوبی استخراج کنند و این تنوع داده‌ها می‌تواند دقت پیش‌بینی را افزایش داده که در مقایسه با مطالعات محدود به ترافیک یکنواخت، برتری قابل

4- Traffic
5-Performance

1- Kip
2- Pavement Structure and Construction
3- Climate

جدول ۳. خلاصه دسته‌بندی ویژگی‌ها و ویژگی‌های

انتخاب شده

ویژگی	دسته‌بندی ویژگی
طول خرابی	خرابی روسازی
مساحت خرابی	
شدت خرابی	
میانگین روزانه ترافیک سالانه ^۱	ترافیک
بار محوری تک معادل ^۲	
دما	آب و هوا
بارش	
چرخه‌های یخبندان-ذوب	
نوع روسازی	ساختار روسازی
ضخامت روسازی	
طول قطعه ^۳	اطلاعات قطعه
عرض قطعه ^۴	
شارپ آیدی ^۵	
تاریخ بازرسی ^۶	

مجموعه داده یکپارچه متناسب با خرابی‌های مورد مطالعه ایجاد شود. پس از انجام فرآیند تطبیق، فیلترینگ و تمرکز بر داده‌های کامل و مرتبط، تعداد نهایی داده‌های قابل استفاده برای طول ترک خطی (طول و عرضی) برابر با ۴۰۲۹ ردیف و برای مساحت ترک پوست سوسماری ۷۱۸ ردیف به دست آمد. تعداد ویژگی‌ها برای هر ماژول حداقل ۲۰ ویژگی در نظر گرفته شد، در حالی که برای ماژول عملکرد، ۳۴ ویژگی مرتبط با طول و مساحت خرابی‌ها شامل شدت خرابی در سطوح کم، متوسط و زیاد و شاخص‌هایی مانند ضریب زبری سطح مورد استفاده قرار گرفت. این داده‌ها پس از انجام مراحل پیش‌پردازش و مهندسی ویژگی از جمله نرمال‌سازی، جایگزینی مقادیر گم‌شده با میانه و مقیاس‌دهی استاندارد، برای آموزش مدل‌ها به کار گرفته شدند تا امکان استخراج و مدل‌سازی روابط پیچیده بین عوامل محیطی، ساختاری و ترافیکی فراهم شود.

داده‌ها از فایل‌های ام‌دی‌بی^۷ و اکسل پایگاه برنامه عملکرد بلندمدت روسازی بارگذاری شده‌اند. جدول اصلی نتایج خرابی‌های روسازی‌های آسفالتی^۸ به عنوان پایه استفاده شده و با داده‌های ترافیک تی‌آراف ترند^۹، نتایج آزمایش‌های مصالح^{۱۰} و آب و هوا شیت‌های مرا^{۱۱} ادغام می‌گردد. برای ادغام، از کلیدهای شارپ آیدی، کد ایالت^{۱۲}، شماره ساخت^{۱۳} و سال^{۱۴} استفاده شده است. در موارد عدم تطابق سال‌ها، از مقادیر پیش‌فرض با نوبت تصادفی برای پر کردن استفاده شده تا مدل بتواند با تنوع واقعی داده‌ها سازگار باشد.

جدول ۳ خلاصه‌ای از دسته‌بندی ویژگی‌ها و ویژگی‌های منتخب را ارائه می‌دهد. این جدول بر اساس دسته‌بندی‌های اصلی (مانند خرابی روسازی، ترافیک، آب و هوا، ساختار روسازی و اطلاعات بخش) تدوین شده و ویژگی‌هایی را برجسته می‌کند که مستقیماً بر پیش‌بینی خرابی‌ها تأثیرگذار هستند. این ویژگی‌ها از داده‌های ماژول‌های پایگاه داده برنامه عملکرد بلندمدت روسازی استخراج شده و در مهندسی ویژگی مدل استفاده می‌شوند تا دقت پیش‌بینی افزایش یابد.

پیش‌پردازش داده‌ها با بهینه‌سازی حافظه آغاز شده،

- 9- TRF_TREND 1, TRF_TREND
- 10- ANALYSIS_TST_AC
- 11- MERRA_PRECIP_YEAR, MERRA_TEMP_YEAR, MERRA_GRID_SECTION
- 12- STATE_CODE
- 13- CONSTRUCTION_NO
- 14- YEAR

- 1- Annual Average Daily Traffic (AADT)
- 2- Equivalent Single Axle Load (ESAL)
- 3- SECTION_LENGTH
- 4- SECTION_WIDTH
- 5- SHRP_ID
- 6- Inspection Date
- 7- Microsoft Database (MDB)
- 8- ANALYSIS_DIS_AC

می‌تواند مدل را به سمت الگوهای مصنوعی سوق دهد)، نویز گاوسی با انحراف استاندارد کم (حدود ۳ تا ۵ درصد از مقدار میانگین) به مقادیر پُر شده اضافه شد تا تنوع طبیعی داده‌های واقعی شبیه‌سازی شود. برای داده‌های کاملاً گم‌شده در یک بخش برای سال خاص (مانند نبود اندازه‌گیری ترافیکی در سالی که داده عملکردی موجود است)، از روش برون‌یابی خطی بین سال‌های مجاور استفاده گردید، مگر این که بیش از دو سال متوالی گم‌شده باشد که در این صورت رکورد مربوطه حذف می‌شد تا از معرفی خطاهای بزرگ جلوگیری شود. این رویکرد حذف تنها در کمتر از پنج درصد موارد اعمال گردید و عمدتاً برای حفظ کیفیت بدنه داده بود. همچنین برای ویژگی‌های اقلیمی که کمتر متغیر هستند (مانند دمای میانگین سالانه)، از جایگزینی مقادیر گم‌شده با میانگین کل مجموعه داده استفاده شد تا تأثیر سوگیری‌های محلی کاهش یابد. این مراحل نه تنها هم‌ترازی زمانی را تضمین کرده‌اند، بلکه سوگیری‌های احتمالی مانند بیش‌هموارسازی^۵ ناشی از جایگزینی مقادیر گم‌شده ساده را با افزودن نویز مدیریت کرده و تعمیم‌پذیری مدل را در مواجهه با داده‌های ناقص واقعی افزایش داده که این امر در ارزیابی‌های حساسیت مدل (با مقایسه عملکرد قبل و بعد از جایگزینی مقادیر گم‌شده) تأیید شد.

فیلترهای مختلفی برای تمرکز بر داده‌های مرتبط اعمال شده است. برای هر خرابی، داده‌های غیرصفر (نشان دهنده وجود خرابی) شناسایی و داده‌های صفر نمونه‌برداری شده تا تعادل ایجاد شود. همچنین برای افزایش داده‌های کم‌تعداد (مانند موارد شدت بالا)، از روش داده‌افزایی استفاده شده است. نویز گاوسی با انحراف استاندارد پنج درصد به ویژگی‌های عددی اضافه شده و مقادیر منفی به صفر محدود گردیده‌اند. این نویز گاوسی برای افزایش تنوع

جایی که نوع داده‌ها به فلوت^{۱۳۲} و اینت^{۱۳۳} تبدیل می‌شوند تا مصرف حافظه کاهش یابد. سپس مساحت قطعه^۳ محاسبه می‌شود؛ اگر طول مقطع و عرض باند^۴ موجود نباشند، از مقدار پیش‌فرض ۱۷۰ متر مربع استفاده می‌شود. برای خرابی‌های مورد نظر، مقادیر طول ترک خطی (با جمع طول ترک‌های طولی و عرضی در سطوح شدت مختلف) و مساحت خرابی پوست سوسماری استخراج و نرمال‌سازی شده‌اند. شدت خرابی‌ها به صورت بدون شدت، کم، متوسط و زیاد تقسیم شده و بر اساس بیشترین چگالی در هر نوع تعیین شده و به صورت عددی نگاشت شده‌اند (صفر برای بدون شدت تا سه برای شدت زیاد). مقادیر نامتناهی یا ناعدده^۵ با میانگین جایگزین شده و داده‌ها با مقیاس‌دهی استاندارد^۶ مقیاس‌بندی می‌شوند تا توزیع استاندارد داشته باشند.

همچنین ادغام داده‌های عملکردی، ترافیکی و اقلیمی از ماژول‌های مختلف پایگاه LTPP با استفاده از شناسه‌های کلیدی مانند شارپ آیدی (شناسه منحصر به فرد مقطع روسازی)، کد ایالت، شماره ساخت (که به تغییرات ساختاری در طول زمان اشاره دارد) و سال بازرسی انجام گردید تا مجموعه‌ای یکپارچه و هم‌تراز زمانی تشکیل شود. این فرآیند ادغام بر پایه تطبیق دقیق رکوردها صورت گرفت، اما با توجه به طبیعت ناهمگن داده‌های LTPP (که برخی ماژول‌ها مانند ترافیک ممکن است در فواصل زمانی متفاوتی جمع‌آوری شوند)، موارد ناهماهنگی زمانی (مانند عدم تطابق دقیق سال‌ها بین ماژول عملکرد و ماژول اقلیم) با رویکردی سیستماتیک مدیریت شدند. در چنین مواردی، ابتدا سال‌های نزدیک‌ترین (معمولاً سال قبل یا بعد) برای رکورد مربوطه شناسایی شده و مقادیر پیش‌فرض بر اساس میانگین وزنی این سال‌ها محاسبه گردیدند. سپس برای جلوگیری از ایجاد سوگیری ناشی از تکرار مقادیر ثابت (که

5- NaN
6- StandardScaler
7- Over-Smoothing

1- float3
2- int32
3- section_area_m2
4- LANE_WIDTH

داده‌های موجود و بهبود تعمیم‌پذیری مدل در مواجهه با تغییرات واقعی محیطی (مانند نوسانات آب و هوایی یا ترافیکی) اضافه شده و مقادیر منفی به صفر محدود می‌گردند تا مقادیر فیزیکی معقول باقی بمانند. این روش برای تمام داده‌های افزوده شده، به ویژه در ویژگی‌های عددی مانند ضخامت لایه‌ها، دما و بار ترافیکی، اعمال گردیده تا مدل بتواند با داده‌های نویزی واقعی سازگار شود. برای عدم تعادل کلاس‌ها در شدت‌ها، از اسموت^۱ با استراتژی نمونه‌برداری از کلاس‌های اقلیت (مانند شدت‌های متوسط و بالا) بهره گرفته شده تا توزیع کلاس‌ها متعادل شود.

برای مقابله با عدم تعادل در توزیع داده‌ها، به ویژه در موارد شدت بالا که تعداد کمتری دارند (مانند شدت‌های متوسط و زیاد در ترک‌های خطی و پوست سوسماری که اغلب در شرایط ترافیکی شدید یا اقلیم‌های نامساعد رخ می‌دهند)، از روش داده‌افزایی مبتنی بر نویز گاوسی و نمونه‌برداری هوشمند استفاده شد. در این روش، ابتدا داده‌های موجود با شدت کم تعداد شناسایی شدند، سپس نویز گاوسی با انحراف استاندارد حدود پنج درصد به ویژگی‌های عددی مانند ضخامت لایه، دمای سالانه و بار ترافیکی اضافه گردید تا نمونه‌های جدیدی ایجاد شود که شبیه به داده‌های واقعی باشند اما تنوع بیشتری داشته باشند. این نویز به گونه‌ای اعمال شد که مقادیر منفی به صفر محدود شوند تا جنبه‌های فیزیکی داده‌ها حفظ گردد و این فرآیند برای تمام ویژگی‌های مرتبط تکرار شد تا مجموعه داده حدود ۲۰-۳۰ درصد افزایش یابد. علاوه بر این، از روش اسموت برای کلاس‌های اقلیت استفاده شد که نمونه‌های مصنوعی را با ترکیب خطی نزدیک‌ترین همسایگان ایجاد می‌کند و توزیع کلاس‌ها را متعادل می‌سازد. این رویکرد نه تنها تعداد داده‌های شدت بالا را افزایش داد، بلکه تعمیم‌پذیری مدل را در مواجهه با سناریوهای نادر بهبود بخشید، بدون این که ساختار اصلی

داده‌ها را مختل کند.

همچنین برای ارزیابی تأثیر روش‌های متعادل‌سازی کلاس‌ها بر کیفیت نمونه‌های تولید شده و جلوگیری از ایجاد داده‌های ناسازگار با توزیع اصلی، ابتدا توزیع ویژگی‌های کلیدی (مانند ضخامت لایه روسازی، دمای متوسط سالانه و بار ترافیکی معادل محور) در نمونه‌های اصلی و نمونه‌های تولید شده با استفاده از روش اسموت مورد مقایسه قرار گرفت. این ارزیابی با استفاده از آزمون‌های آماری مانند آزمون کولموگروف-اسمیرنوف (KS) انجام شد که نتایج آن نشان دهنده عدم تفاوت معنادار (با سطح معناداری ۰/۰۵) بین توزیع‌های دو مجموعه بوده، به این معنا که نمونه‌های اسموت در فضای ویژگی اصلی باقی مانده و از تولید داده‌های خارج از توزیع جلوگیری شده است. علاوه بر این، افزودن نویز گاوسی با انحراف استاندارد حدود پنج درصد به ویژگی‌های عددی، نه تنها تنوع نمونه‌ها را افزایش داد، بلکه با محدود کردن مقادیر منفی به صفر، سازگاری فیزیکی داده‌ها (مانند جلوگیری از مقادیر منفی برای بار ترافیکی) را حفظ کرد. انتخاب ترکیب اسموت و نویز گاوسی به جای روش‌های صرفاً درون‌نمونه مانند وزن‌دهی کلاس‌ها یا تنها استفاده از تابع ضرر فوکال، به دلیل طبیعت نامتوازن شدید داده‌های LTPP (با کلاس‌های شدت بالا که کمتر از حدود ۱۰ درصد کل داده‌ها را تشکیل می‌دهند) بود. روش‌های درون‌نمونه در چنین مواردی ممکن است به بیش‌برازش کلاس‌های اکثریت منجر شوند، در حالی که ترکیب پیشنهادی با ایجاد نمونه‌های مصنوعی واقع‌گرا، مدل را برای سناریوهای نادر مقاوم‌تر می‌سازد. تأثیر این ترکیب بر نتایج اعتبارسنجی با مقایسه عملکرد مدل طبقه‌بندی شدت خرابی‌ها (برای ترک خطی و پوست سوسماری) با و بدون اعمال اسموت و نویز ارزیابی شد. جدول ۴ زیر نتایج معیارهای طبقه‌بندی (شامل صحت، دقت، فراخوانی و امتیاز افوان) را برای هر دو حالت نشان می‌دهد که بهبود

1- SMOTE

و نشان می‌دهد که اعمال اسموت و نویز نه تنها تعادل کلاس‌ها را بهبود بخشیده، بلکه عملکرد کلی مدل را در داده‌های اعتبارسنجی (۲۰ درصد داده‌های زمانی انتهایی) بهبود داده است، به ویژه در کلاس‌های شدت متوسط و بالا که پیش از متعادل‌سازی، فراخوانی پایین‌تری داشتند.

قابل توجهی (به طور میانگین حدود ۱۵ درصد در امتیاز امتیاز افوان برای کلاس‌های اقلیت) در حالت با اسموت و نویز مشاهده می‌شود، بدون افزایش خطای اعتبارسنجی که نشان دهنده عدم بیش‌برازش است. این جدول بر اساس میانگین معیارها در کلاس‌های شدت مختلف محاسبه شده

جدول ۴. مقایسه نتایج معیارهای طبقه‌بندی شدت خرابی با و بدون اسموت و نویز گوسی

نوع ترک	حالت مدل	صحت	دقت	فراخوانی	امتیاز افوان
خطی	بدون اسموت	۰/۷۸۲	۰/۷۸۵	۰/۷۸۲	۰/۷۸۳
خطی	با اسموت و نویز گوسی	۰/۸۴۳	۰/۸۴۵	۰/۸۴۳	۰/۸۴۳
پوست سوسماری	بدون اسموت	۰/۸۴۵	۰/۸۴۷	۰/۸۴۵	۰/۸۴۶
پوست سوسماری	با اسموت و نویز گوسی	۰/۹۳۰	۰/۹۳۲	۰/۹۲۹	۰/۹۳۰

موارد عمومی و ۱/۵ برای موارد پراکنده) به کار رفته تا حساسیت به داده‌های پرت^۹ کاهش یابد.

انتخاب پارامترهای تابع زیان فوکال برای مدل‌های طبقه‌بندی شدت خرابی (با گامای برابر با ۲ و آلفای برابر با ۰/۳۵) بر پایه نیاز به تمرکز بیشتر بر نمونه‌های دشوار طبقه‌بندی و مدیریت نامتوازنی کلاس‌ها (که در داده‌های LTPP، کلاس‌های با شدت بالا کمتر از ۱۵ درصد کل داده‌ها را تشکیل می‌دهند) انجام شد. گامای برابر با دو برای کاهش وزن نمونه‌های آسان و تأکید بر موارد چالش‌برانگیز انتخاب شد، زیرا مقادیر بزرگ‌تر گاما می‌تواند مدل را بیش از حد نسبت به نمونه‌های نادر حساس کرده و موجب ناپایداری در فرآیند آموزش شود، در حالی که مقادیر کوچک‌تر مانند صفر یا یک اثر تعادلی کمتری دارند. آلفای برابر با ۰/۳۵ نیز بر اساس نسبت تقریبی کلاس‌های اقلیت (شدت متوسط و شدت زیاد) تنظیم شد تا وزن بیشتری به این کلاس‌ها اختصاص داده شود و از سوگیری مدل به سمت کلاس‌های غالب (مانند شدت کم یا بدون شدت) جلوگیری گردد. همچنین نتایج آزمون‌های حساسیت نشان

مدل‌سازی در دو بخش طبقه‌بندی شدت و شبکه عصبی مصنوعی برای پیش‌بینی طول و مساحت مقدار خرابی انجام شده است. برای طبقه‌بندی شدت هر خرابی (مانند شدت ترک خطی و پوست سوسماری)، از شبکه عصبی متراکم با لایه‌های پنهان استفاده شده است. این مدل با ورودی ویژگی‌ها (مانند ضخامت لایه، دمای متوسط، بارش، بار محور تکی معادل^۱ سالانه و ترافیک کامیون‌ها) آغاز شده و خروجی سافت‌مکس^۲ برای چهار کلاس شدت تولید می‌کند. تابع ضرر فوکال^۳ با پارامترهای گاما^۴ برابر دو (برای تمرکز بر نمونه‌های سخت، به طوری که مدل بیشتر بر نمونه‌های دشوار طبقه‌بندی شده تمرکز کرده و خطاهای آسان را کمتر وزن‌دهی می‌کند تا تعادل بهتری در یادگیری ایجاد شود) و آلفا^۵ برابر ۰/۳۵ (برای تعادل کلاس‌ها) به کار گرفته شده تا مشکل عدم تعادل کلاس‌ها حل شود. تابع بهینه‌ساز آدام با نرخ یادگیری اولیه ۰/۰۰۱ و کلیپ‌نرم^۶ برابر یک استفاده شده است. برای پیش‌بینی مقدار خرابی (طول ترک خطی و مساحت پوست سوسماری)، مدل مشابهی با خروجی خطی و تابع ضرر هوبر^۷ (با دلتا^۸ برابر یک برای

6- Clipnorm
7- Huber
8- Delta
9- Outliers

1- ESAL
2- Softmax
3- Focal
4- Gamma
5- Alpha

ناهمگنی واریانس معنادار بود. در چنین شرایطی، افزودن پیچیدگی این توابع می‌توانست به بیش‌برازش در داده‌های محدود LTPP منجر شود. از این رو، تابع زیان هوبر با سادگی و پایداری خود، عملکرد بهینه‌ای در پیش‌بینی خرابی‌های روسازی فراهم کرد که با معیارهای ارزیابی مدل سازگاری دارد.

همچنین برای مدیریت داده‌های ناقص و پرت در مجموعه داده‌های LTPP، رویکردی محتاطانه اتخاذ شد تا از حفظ اطلاعات ارزشمند جلوگیری شود. مقادیر گم‌شده با میانه ویژگی مربوطه جایگزین شدند تا سوگیری ناشی از میانگین (که ممکن است تحت تأثیر داده‌های پرت باشد) کاهش یابد و برای داده‌های نامتوازن زمانی (مانند عدم تطابق سال‌ها بین مازول‌ها)، از برون‌یابی خطی بین سال‌های مجاور یا میانگین وزنی با افزودن نویز گوسی کم (انحراف استاندارد حدود سه تا پنج درصد) استفاده شد تا تنوع طبیعی داده‌ها حفظ گردد. در خصوص نقاط پرت، هیچ حذف مستقیمی انجام نگرفت، زیرا چنین عملی می‌توانست الگوهای مهم مانند بخش‌های روسازی با خرابی شدید (که اغلب در شرایط ترافیکی سنگین یا اقلیم‌های نامساعد رخ می‌دهند و حاوی اطلاعات کلیدی برای پیش‌بینی هستند) را از دست بدهد. در عوض، معیار شناسایی داده‌های پرت بر اساس Z-score (بزرگ‌تر از سه یا کوچک‌تر از منفی سه برای ویژگی‌های عددی مانند ESAL یا طول ترک) و روش جعبه‌ای (IQR با ضریب ۱/۵) بوده، اما این نقاط با استفاده از تابع ضرر هوبر (با دلتا برابر یک برای موارد عمومی و دلتا برابر ۱/۵ برای پراکنده‌تر) در مدل‌ها مدیریت شدند تا حساسیت مدل به آن‌ها کاهش یابد بدون حذف؛ که این رویکرد قابلیت تعمیم‌دهی مدل را افزایش داده و اجازه داد تا الگوهای نادر (مانند ترک‌های شدید در روسازی‌های قدیمی) در آموزش حفظ شوند. برای ارزیابی تأثیر این استراتژی‌ها، آزمون حساسیت انجام شد که شامل مقایسه عملکرد مدل (با معیارهایی مانند ضریب تعیین و

داد که این تنظیم موجب بهبود حدود ۱۰ تا ۲۰ درصدی در نرخ فراخوانی کلاس‌های اقلیت شده است. این پارامترها از طریق جستجوی شبکه‌ای بر روی بازه‌های گاما برابر با [۰/۲۵، ۰/۳۵، ۰/۵، ۰/۷۵] و آلفا برابر با [۰/۵، ۱، ۲، ۳، ۵] و با استفاده از اعتبارسنجی متقاطع پنج‌تایی روی مجموعه آموزشی تعیین شدند که در آن معیار بهینه‌سازی، امتیاز افوان وزنی بوده تا تعادل میان دقت و فراخوانی حفظ شده و بهترین ترکیب با کمترین خطای اعتبارسنجی انتخاب شود.

همچنین برای تابع زیان هوبر در مدل‌های شبکه عصبی مصنوعی (با دلتا برابر با یک برای پیش‌بینی‌های عمومی و دلتا برابر با ۱/۵ برای حالت‌هایی با پراکندگی بیشتر مانند مساحت ترک پوست سوسماری)، مقدار دلتا برابر با یک به عنوان نقطه تعادل میان حساسیت میانگین مربعات خطا نسبت به خطاهای کوچک و پایداری میانگین مطلق خطا در برابر داده‌های پرت انتخاب شد، زیرا در داده‌های LTPP اغلب خطاها در بازه‌های محدود قرار دارند، اما داده‌های پرت ناشی از شرایط اقلیمی شدید نیز مشاهده می‌شود. مقدار دلتا برابر با ۱/۵ برای موارد با پراکندگی بالاتر این امکان را فراهم می‌کند که اثر داده‌های پرت بیشتر کاهش یابد، بدون آن که مدل کاملاً به سمت معیار میانگین مطلق خطا متمایل شود. این مقادیر نیز با استفاده از جستجوی شبکه‌ای روی بازه دلتا برابر با [۰/۵، ۱، ۱/۵، ۲، ۳] و اعتبارسنجی متقاطع پنج‌تایی تعیین شدند، به گونه‌ای که معیارهای بهینه‌سازی شامل میانگین مطلق خطا و ضریب تعیین^۱ بوده تا عملکرد مدل در مواجهه با داده‌های پرت و غیرپرت به صورت متعادل ارزیابی شود. به‌کارگیری گزینه‌های جایگزین مانند تابع خطای چارکی (که برای مدل‌سازی توزیع‌های نامتقارن خطا مناسب است) یا تابع زیان ناهمسان واریانس (برای پیش‌بینی واریانس متغیر) مدنظر قرار نگرفت، زیرا تحلیل باقی‌مانده‌ها (از جمله آزمون‌های ناهمسانی واریانس ارائه شده در بخش نتایج) نشان دهنده تقارن نسبی خطاها و نبود

1- Coefficient of determination (R^2)

حذف داده‌های پرت) داشت که این امر بیان‌گر حفظ الگوهای مهم بدون کاهش دقت است و تغییرات جزئی (کمتر از ۵ درصد در معیارها) در استراتژی‌های جایگزین، پایداری مدل را نشان می‌دهد. جزئیات مدل‌های طبقه‌بندی شدت و ابرپارامترهای آنها در جدول ۵ آورده شده است.

میانگین مطلق خطا) در چهار سناریو می‌باشد، شامل (۱) جایگزینی با میانه بدون نویز، (۲) جایگزینی با میانگین وزنی و نویز، (۳) حذف داده‌های پرت بر اساس Z-score بیشتر از سه، و (۴) عدم حذف و مدیریت با هوبر. نتایج نشان داد که استراتژی پیشنهادی (جایگزینی با میانه/نویز و مدیریت با هوبر) بهترین عملکرد را با ضریب تعیین میانگین حدود ۰/۹۴۸ در اعتبارسنجی (در مقایسه با ۰/۹۲۷ در حالت

جدول ۵. جزئیات مدل‌های طبقه‌بندی شدت و ابرپارامترها

مدل طبقه‌بندی	لایه‌های پنهان	نرخ دراپ‌اوت ^۱	تابع فعال‌سازی	تابع ضرر	تابع بهینه‌ساز	نرخ یادگیری	تکرار	اندازه دسته	سایر پارامترها
شدت ترک خطی	[۲۵۶،۱۲۸،۶۴]	۰/۳	رلو	فوکال	آدام	۰/۰۰۱	۱۰۰	۱۶	نرمال‌سازی دسته پس از هر لایه، وزن کلاس‌ها برای کلاس‌های اقلیت دو برابر
شدت ترک پوست سوسماری	[۲۵۶،۱۲۸،۶۴]	۰/۳	رلو	فوکال	آدام	۰/۰۰۱	۱۰۰	۱۶	نرمال‌سازی دسته پس از هر لایه، وزن کلاس‌ها برای کلاس‌های اقلیت دو برابر

منظم‌سازی ال^۲ با ضریب ۰/۰۲ برای جلوگیری از بیش‌برازش اعمال شده است. جزئیات مدل‌های شبکه عصبی مصنوعی و ابرپارامترهای آنها در جدول ۶ ارائه شده است.

مدل شبکه عصبی مصنوعی برای پیش‌بینی طول ترک خطی و مساحت ترک پوست سوسماری، با تمرکز بر نمونه‌های سخت از طریق تابع ضرر فوکال، دقت پیش‌بینی کلاس‌های نادر (مانند شدت بالا) را افزایش داده است. تابع

جدول ۶. جزئیات مدل‌های شبکه عصبی مصنوعی و ابرپارامترها

مدل	لایه‌های پنهان	نرخ دراپ‌اوت	تابع فعال‌سازی	تابع ضرر	تابع بهینه‌ساز	نرخ یادگیری	تکرار	سایز دسته	سایر پارامترها
طول ترک خطی	[۲۵۶،۱۲۸،۶۴]	۰/۳	رلو	هوبر (دلتا برابر ۱)	آدام	۰/۰۰۱	۱۰۰	۱۶	نرمال‌سازی دسته، منظم‌سازی ال ^۲ برابر ۰/۱، وزن نمونه‌های غیرصفر ۱۰ برابر برای موارد پراکنده
مساحت ترک پوست سوسماری	[۲۵۶،۱۲۸،۶۴]	۰/۳	رلو	هوبر (دلتا برابر ۱)	آدام	۰/۰۰۱	۱۰۰	۱۶	نرمال‌سازی دسته، منظم‌سازی ال ^۲ برابر ۰/۱، وزن نمونه‌های غیرصفر ۱۰ برابر برای موارد پراکنده

گذشته را یاد بگیرد و توانایی پیش‌بینی رویدادهای آینده را آزمایش کرده که این رویکرد در داده‌های سری زمانی مانند عملکرد روسازی ضروری است زیرا وابستگی‌های زمانی (مانند تأثیر تجمعی بار ترافیکی و تغییرات اقلیمی بر زوال) را حفظ می‌کند و از نشت داده جلوگیری می‌نماید. این امر، تعمیم‌پذیری مدل را افزایش داده و اطمینان می‌دهد که ارزیابی بر اساس داده‌های نادیده صورت گیرد که در نتیجه منجر به معیارهای معتبرتری مانند ضریب تعیین بالا در داده‌های آزمون گردید.

همچنین در این رویکرد که بر پایه حفظ وابستگی‌های زمانی (مانند اثرات تجمعی بارهای ترافیکی و چرخه‌های محیطی بر پیشرفت خرابی‌ها) در نظر گرفته شده، از تقسیم تصادفی روی ردیف‌ها اجتناب شده است. زیرا چنین تقسیم‌بندی‌ای می‌تواند همبستگی‌های مکانی (مانند شرایط اقلیمی مشابه در قطعات مجاور) یا زمانی (مانند روند زوال در سال‌های متوالی یک قطعه) را نادیده گرفته و منجر به ارزیابی بیش از حد خوش‌بینانه شود. علاوه بر این، برای مدیریت وابستگی‌های مکانی، قطعه‌های روسازی بر اساس شناسه‌های منحصر به فرد (مانند شارپ آیدی و کد ایالت) گروه‌بندی شده تا اطمینان حاصل شود که تمام مشاهدات یک قطعه خاص در یک مجموعه (آموزش یا اعتبارسنجی) قرار گرفته و بدین ترتیب از بهره‌برداری مدل از اطلاعات همبسته مکانی جلوگیری شده است.

۵. توسعه مدل‌های پیش‌بینی خرابی

مدل‌های پیش‌بینی را برای تخمین شدت، طول و مساحت این خرابی‌ها در این بخش توسعه داده شده است. با این حال، از آن جایی که داده‌های تاریخی‌چغ‌ای و سری زمانی در اختیار نیست، از پایگاه داده LTPP برای توسعه این مدل‌ها بهره گرفته شده است. این پایگاه داده شامل اطلاعات گسترده‌ای از عوامل ساختاری، محیطی و ترافیکی

مدل شبکه عصبی مصنوعی با تابع ضرر هوبر، ترکیبی از خطای میانگین مربعات و میانگین خطای مطلق بوده که برای داده‌های پراکنده مقاوم‌تر است. آموزش با کالک‌هایی^۱ مانند توقف زودهنگام^۲ (با ضریب تحمل^۳ برابر ۱۰)، کاهش پل‌تو رگرسیون^۴ (عامل کاهش ۰/۵، ضریب تحمل برابر ۱۰ و کاهش وارم‌آپ^۵ (برابر ۲۰ تکرار) انجام شده تا نرخ یادگیری بهینه شود. داده‌ها به دو دسته آموزش و اعتبارسنجی با نسبت ۸۰/۲۰ تقسیم شده‌اند. پیش‌بینی آینده با روش تکراری انجام شده است. خروجی هر سال به عنوان ورودی سال بعد استفاده می‌شود و شاخص‌های وضعیت روسازی بر اساس پیش‌بینی‌ها محاسبه می‌گردند. همچنین ارزیابی با معیارهایی مانند صحت، دقت، فراخوانی، امتیاز اف‌وان برای مدل طبقه‌بندی و ضریب تعیین، خطای میانگین مربعات و میانگین خطای مطلق برای مدل شبکه عصبی مصنوعی صورت گرفته است. این روش‌شناسی اطمینان داده که مدل با داده‌های واقعی برنامه عملکرد بلندمدت روسازی سازگار باشد و پیش‌بینی‌های قابل اعتمادی برای مدیریت روسازی ارائه دهد.

همچنین برای صحت‌سنجی مدل‌ها، داده‌ها بر اساس ترتیب زمانی تقسیم‌بندی شده‌اند تا قابلیت پیش‌بینی مدل در شرایط واقعی آینده شبیه‌سازی شود. داده‌های پایگاه داده LTPP از سال حدود ۱۹۸۸ تا ۲۰۲۳ جمع‌آوری شده‌اند که این بازه طولانی امکان ارزیابی روند زوال روسازی در طول زمان را فراهم می‌کند. حدود ۸۰ درصد داده‌های اولیه (از سال ۱۹۸۸ تا حدود ۲۰۱۶) برای آموزش و مدل‌سازی استفاده گردیدند، در حالی که ۲۰ درصد داده‌های انتهایی (از سال ۲۰۱۷ تا ۲۰۲۳) از فرآیند مدل‌سازی حذف شده و صرفاً برای صحت‌سنجی و ارزیابی عملکرد مدل به کار گرفته شدند. این تقسیم‌بندی زمانی که بر خلاف تقسیم‌بندی تصادفی است، به مدل اجازه می‌دهد تا الگوهای


4- ReduceLROnPlateau
5- WarmUpCosineDecay

1- Callbacks
2- Early Stopping
3- Patience


برای مدل شبکه عصبی مصنوعی (برای مقاومت در برابر داده‌های پرت) استفاده شده است. این مشخصات، مدل‌ها را برای پیش‌بینی‌های در شرایط واقعی بدون نیاز به ضرایب خطی مانند مدل‌های رگرسیون سنتی مناسب ساخته است. شکل ۱ نمودار خطای آموزش و اعتبارسنجی مدل طبقه‌بندی شدت برای ترک خطی را نشان می‌دهد. این نمودار کاهش مداوم خطا را در هر دو مجموعه آموزش و اعتبارسنجی نمایش می‌دهد، جایی که خطای اعتبارسنجی پایین‌تر از آموزش باقی مانده و نشان دهنده عدم بیش‌برازش است که این امر دقت مدل در تمایز سطوح شدت ترک خطی را تأیید می‌کند. همچنین شکل ۲ نمودار خطای آموزش و اعتبارسنجی برای ترک پوست سوسماری را ارائه می‌دهد، با الگویی مشابه که خطاها به سرعت همگرا می‌شوند و خطای نهایی اعتبارسنجی حدود ۰/۰۴۲ است (بیانگر یادگیری مؤثر مدل از الگوهای شبکه‌ای این نوع خرابی).

است که روابط پیچیده بین آن‌ها و پیشرفت خرابی‌ها را مدل‌سازی می‌کند.

پیش‌بینی در دو سطح انجام شده است. سطح اول، پیش‌بینی شدت خرابی‌ها (کم، متوسط یا زیاد) برای ترک خطی و پوست سوسماری با استفاده از مدل طبقه‌بندی؛ سطح دوم، پیش‌بینی طول ترک خطی و مساحت ترک پوست سوسماری با مدل شبکه عصبی مصنوعی می‌باشد. داده‌های ورودی مدل‌ها شامل ویژگی‌هایی مانند ضخامت لایه روسازی، دمای متوسط سالانه، بارش، بار محوری تک معادل، چرخه‌های یخبندان-ذوب و میانگین روزانه ترافیک سالانه است، در حالی که خروجی‌ها شدت (برای طبقه‌بندی) و طول/مساحت (برای مدل شبکه عصبی مصنوعی) می‌باشند. مدل‌ها بر پایه شبکه‌های عصبی توسعه یافته‌اند که با لایه‌های پنهان (مانند [۲۵۶, ۱۲۸, ۶۴])، نرخ دراپ‌اوت ۰/۳، تابع فعال‌سازی رلو و تابع بهینه‌ساز آدام آموزش داده شده‌اند. همچنین از توابع ضرر فوکال برای طبقه‌بندی (به منظور مدیریت عدم تعادل کلاس‌ها) و هوبر



شکل ۱. نمودار خطای آموزش و اعتبارسنجی مدل طبقه‌بندی شدت برای ترک خطی




شکل ۲. نمودار خطای آموزش و اعتبارسنجی مدل طبقه‌بندی شدت برای ترک پوست سوسماری

شدت بوده، در حالی که ترک خطی با مقدار صحت برابر ۰/۸۳۴ همچنان قابل قبول است. خطاهای پایین اعتبارسنجی (کمتر از ۰/۰۵۱) نسبت به آموزش، عدم بیش‌برازش را نشان داده و کلیت نتایج، مدل را برای طبقه‌بندی شدت در سناریوهای واقعی مناسب می‌سازد.

نتایج مدل طبقه‌بندی شدت در جدول ۷ و شکل ۳ برای انواع خرابی‌های ترک خطی و پوست سوسماری خلاصه شده است. بررسی این جدول حاکی از عملکرد بسیار خوب مدل طبقه‌بندی شدت است. ترک پوست سوسماری با مقدار دقت برابر ۰/۹۳۲ بیانگر تمایز عالی کلاس‌های

جدول ۷. نتایج مدل طبقه‌بندی شدت خرابی


خرابی	خطای آموزش	خطای اعتبارسنجی	صحت	دقت	فراخوانی	امتیاز اف‌وان
شدت ترک خطی	۰/۰۶۷	۰/۰۵۱	۰/۸۳۴	۰/۸۴۵	۰/۸۴۳	۰/۸۴۳
شدت ترک پوست سوسماری	۰/۰۷۳	۰/۰۴۲	۰/۹۳۰	۰/۹۳۲	۰/۹۲۹	۰/۹۳۰




شکل ۳. نمودار نتایج مدل طبقه‌بندی شدت خرابی

۵ خطای آموزش و اعتبارسنجی برای مساحت ترک پوست سوسماری را نمایش می‌دهد. همان طور که در این شکل دیده می‌شود خطاها به سرعت کاهش یافته و خطای نهایی اعتبارسنجی ۰/۰۴۷ به دست آمده که بیانگر دقت بالای مدل در تخمین مساحت‌های حالت شبکه‌ای ترک‌های پوست سوسماری است.

در ادامه نتایج مدل‌های پیش‌بینی طول ترک خطی و مساحت ترک پوست سوسماری ارائه شده است. شکل ۴ نمودار خطای آموزش و اعتبارسنجی مدل شبکه عصبی مصنوعی برای طول ترک خطی را نشان می‌دهد، با کاهش مداوم خطاها که در اعتبارسنجی به ۰/۰۴۱ می‌رسد و نشان دهنده همگرایی خوب مدل بدون بیش‌برازش است. شکل




شکل ۴ نمودار خطای آموزش و اعتبارسنجی مدل شبکه عصبی مصنوعی برای طول ترک خطی




شکل ۵. نمودار خطای آموزش و اعتبارسنجی مدل شبکه عصبی مصنوعی برای مساحت ترک پوست سوسماری

از مقدار واقعی) و بیش‌برآورد (بیشتر از مقدار واقعی) مشاهده می‌شود. شکل ۷ مقادیر اندازه‌گیری شده در برابر مقادیر پیش‌بینی شده برای مساحت ترک پوست سوسماری را ارائه می‌کند. اغلب نقاط نزدیک به خط ایده‌آل تجمع یافته‌اند. انحراف رو به بالای در مقادیر حدود ۳۵۰ میلی متر مربع وجود دارد، به این دلیل که بیش‌برآورد (بیشتر از مقدار واقعی) نسبت به مقادیر اندازه‌گیری شده وجود دارد و یکی از دلایل آن این می‌باشد که مقادیر بالای مساحت در مجموعه داده کمتر بوده است و با افزایش داده‌ها می‌توان آن را بهبود بخشید.

در ادامه نتایج نمودارهای مقادیر اندازه‌گیری شده در برابر مقادیر پیش‌بینی شده برای طول ترک خطی و مساحت ترک پوست سوسماری ارائه و مورد بررسی قرار گرفته است. شکل ۶ مقادیر اندازه‌گیری شده در برابر مقادیر پیش‌بینی شده برای طول ترک خطی را به نمایش می‌گذارد. در این نمودار نقاط داده عمدتاً در نزدیکی خط ایده‌آل^۱ یا خط برابری^۲ پراکنده شده‌اند. همچنین به دلیل کم بودن تعداد ردیف داده طول ترک خطی (طول زیاد)، در مقادیر بالاتر طول ترک خطی، برخی داده‌ها پراکنده شده‌اند؛ اما کلیت توزیع نشان دهنده دقت بالای مدل در تخمین طول ترک‌های خطی می‌باشد. در برخی موارد کم‌برآورد (کمتر



شکل ۶. مقادیر اندازه‌گیری شده در برابر مقادیر پیش‌بینی شده - ترک خطی



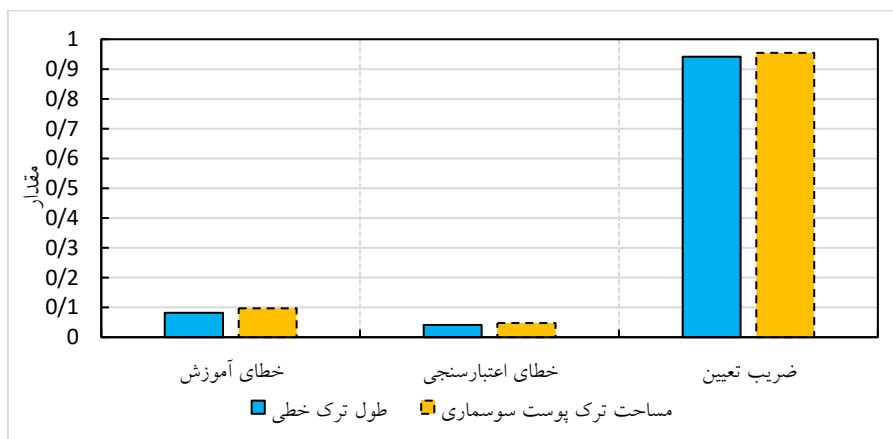
شکل ۷. مقادیر اندازه‌گیری شده در برابر مقادیر پیش‌بینی شده - ترک پوست سوسماری

ترک پوست سوسماری توسط مدل است. برای ترک خطی، مقادیر ضریب تعیین و میانگین خطای مطلق به ترتیب برابر ۰/۹۴۱ و ۲۰/۳۵۴ بیانگر پیش‌بینی‌های مناسب طول ترک خطی است.

بررسی نتایج مدل شبکه عصبی مصنوعی ارائه شده در جدول ۸ و شکل ۸ عملکرد مناسب مدل با مقدار ضریب تعیین برابر ۰/۹۵۴ برای ترک پوست سوسماری ارائه می‌دهد که نشان دهنده توضیح بیش از ۹۵ درصد واریانس

جدول ۸. نتایج مدل شبکه عصبی مصنوعی پیش‌بینی طول و مساحت خرابی‌ها

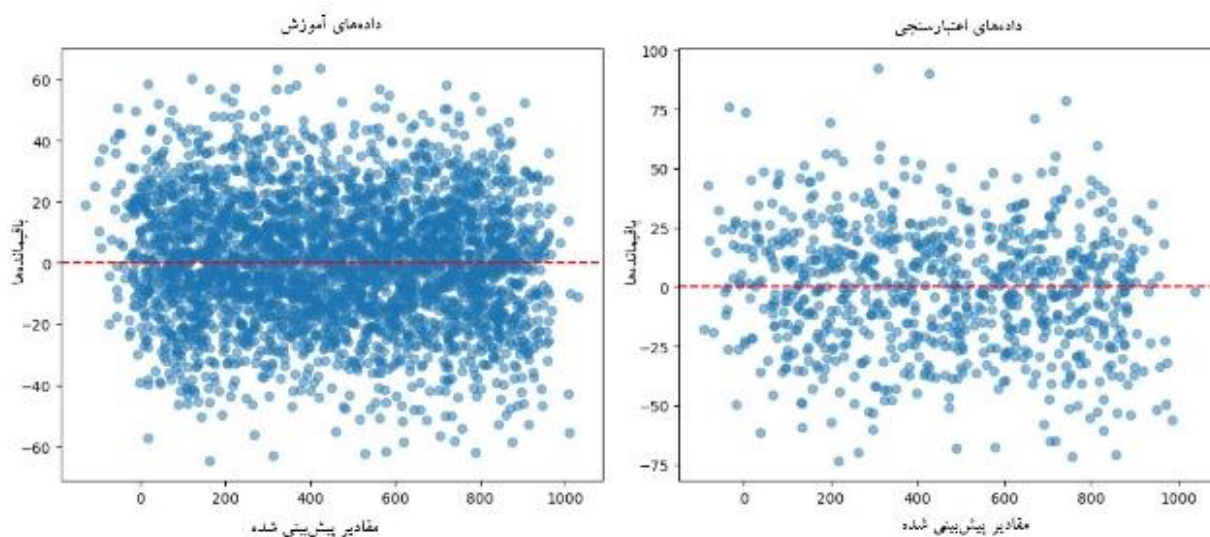
خرابی	خطای آموزش	خطای اعتبارسنجی	ضریب تعیین (آزمایش)	خطای میانگین مربعات	میانگین خطای مطلق
طول ترک خطی	۰/۰۸۲	۰/۰۴۱	۰/۹۴۱	۸۶۵/۴۷۸	۲۰/۳۵۴
مساحت ترک پوست سوسماری	۰/۰۹۷	۰/۰۴۷	۰/۹۵۴	۳۶۶/۹۱۸	۱۲/۸۶۳




شکل ۸. نمودار نتایج مدل‌های شبکه عصبی مصنوعی پیش‌بینی طول و مساحت خرابی‌ها

بر این، برای بررسی تفاوت آماری بین عملکرد آموزش و اعتبارسنجی، بازه اطمینان ۹۵ درصدی برای ضریب تعیین با روش بوت‌استرپ (با ۱۰۰۰ نمونه برداری مجدد) محاسبه گردید. برای طول ترک خطی، ضریب تعیین آموزش برابر $0/952$ با بازه اطمینان $[0/938, 0/965]$ و ضریب تعیین اعتبارسنجی برابر $0/941$ با بازه اطمینان $[0/922, 0/958]$ بوده، در حالی که برای مساحت ترک پوست سوسماری، ضریب تعیین آموزش برابر $0/963$ با بازه اطمینان $[0/975, 0/949]$ و ضریب تعیین اعتبارسنجی برابر $0/954$ با بازه اطمینان $[0/935, 0/970]$ محاسبه شده است. آزمون بوت‌استرپ برای تفاوت ضریب تعیین بین دو مجموعه (با محاسبه توزیع تفاوت‌ها) نشان داد که تفاوت‌ها آماری معنادار نیستند (مقدار پی بیشتر از $0/05$) که این امر عدم بیش‌برازش و تعمیم‌پذیری مناسب مدل‌ها را نشان می‌دهد. در شکل ۹ نمودارهای باقی‌مانده‌ها برای طول ترک خطی (آموزش و اعتبارسنجی) و شکل ۱۰ برای مساحت ترک پوست سوسماری (آموزش و اعتبارسنجی) ارائه شده که توزیع تصادفی باقی‌مانده‌ها را نشان می‌دهد.

برای ارزیابی بیشتر مدل‌های توسعه یافته در پیش‌بینی طول ترک خطی و مساحت ترک پوست سوسماری، نمودارهای باقی‌مانده‌ها در برابر مقادیر پیش‌بینی شده برای مجموعه‌های آموزش و اعتبارسنجی ترسیم شده‌اند تا الگوهای سیستماتیک در خطاها بررسی شود. باقی‌مانده‌ها به عنوان تفاوت بین مقادیر واقعی و پیش‌بینی شده محاسبه شده و شکل‌ها نشان دهنده توزیع تصادفی باقی‌مانده‌ها حول خط صفر بدون الگوی واضح افزایش یا کاهش واریانس در سطوح بالاتر مقادیر پیش‌بینی شده هستند که این امر حاکی از همگنی واریانس است. برای تأیید این مشاهده، آزمون بروش-پاگان^۱ با استفاده از مدل‌های خطی کمکی انجام شده که نتایج آن برای طول ترک خطی (آمار آزمون برابر با $1/23$ با مقدار پی^۲ برابر $0/27$) و مساحت ترک پوست سوسماری (آمار آزمون برابر $0/89$ با مقدار پی برابر $0/35$) عدم وجود ناهمسانی واریانس‌ها را در سطح معناداری $0/05$ تأیید می‌کند. به این معنا که واریانس خطاها مستقل از مقادیر پیش‌بینی شده است و مدل‌ها در سطوح کوچک یا بزرگ هدف به طور یکسان عمل می‌کنند. علاوه



شکل ۹. نمودار باقی‌مانده‌ها در برابر مقادیر پیش‌بینی شده - طول ترک خطی



شکل ۱۰. نمودار باقی مانده‌ها در برابر مقادیر پیش‌بینی شده - مساحت ترک پوست سوسماری


شود. مدل‌های شبکه عصبی مصنوعی توسعه یافته در این پژوهش، با ادغام ویژگی‌های ترافیکی و اقلیمی، این روند را با دقت مناسبی پیش‌بینی می‌کنند، زیرا لایه‌های پنهان مدل روابط غیرخطی بین متغیرها را استخراج کرده و ضریب تعیین ۰/۹۴۱ برای طول ترک خطی به دست آمده که این امر امکان برنامه‌ریزی نگهداری پیشگیرانه (مانند اعمال لایه‌های تقویت‌کننده در سال‌های میانی) را فراهم می‌کند.

همچنین شکل ۱۲ مساحت ترک پوست سوسماری را در همان بازه زمانی ۲۰۱۳ تا ۲۰۳۳ نشان می‌دهد. این نمودار نیز روندی افزایشی غیرخطی را به تصویر می‌کشد، با شروع از مقادیر پایین (نزدیک به صفر در سال‌های ۲۰۱۶-۲۰۱۳ که نشان دهنده عدم بروز خستگی ساختاری اولیه است) و افزایش تدریجی تا حدود ۲/۵ متر مربع در سال ۲۰۳۳. این الگوی غیرخطی به دلیل ساز و کارهای زوال ساختاری است، جایی که ترک‌های پوست سوسماری اغلب از لایه‌های زیرین (به دلیل بارهای سنگین و توزیع نامناسب تنش) آغاز شده و به سطح گسترش می‌یابند. عوامل مؤثر شامل حجم بالای AADTT (که باعث تغییر شکل دائمی و کاهش سختی لایه‌ها می‌شود) و شرایط اقلیمی مرطوب (که با نفوذ آب از طریق ترک‌های اولیه،


برای بررسی روند زمانی گسترش خرابی‌ها در قطعات روسازی مورد مطالعه، شکل‌های ۱۱ و ۱۲ بر اساس داده‌های تجمیعی پایگاه LTPP و خروجی‌های مدل‌های پیش‌بینی، ارائه شده‌اند. شکل ۱۱ میانگین طول ترک خطی را در بازه زمانی ۲۰۱۳ تا ۲۰۳۳ نمایش می‌دهد. این نمودار نشان دهنده روند افزایشی غیرخطی طول ترک خطی است که از مقادیر نزدیک به صفر در سال‌های اولیه (۲۰۱۳-۲۰۱۵، جایی که روسازی هنوز در مرحله عملکرد اولیه قرار دارد و تنش‌های اولیه کم است) آغاز شده و به تدریج با شتاب بیشتری افزایش می‌یابد، به طوری که تا سال ۲۰۳۳ به حدود ۲/۵ متر می‌رسد. این روند غیرخطی عمدتاً ناشی از اثرات تجمعی بارهای ترافیکی (مانند ESAL بالا که منجر به تنش‌های برشی مکرر در لایه آسفالتی می‌شود) و عوامل محیطی (مانند چرخه‌های یخبندان-ذوب که باعث انبساط و انقباض حرارتی و ایجاد ترک‌های اولیه طولی و عرضی می‌گردد) است. از منظر مهندسی روسازی، این الگو با مفهوم خستگی مواد همخوانی دارد، جایی که نرخ زوال در مراحل اولیه کند است (به دلیل مقاومت اولیه لایه‌ها) اما با عبور از آستانه بحرانی (معمولاً پس از ۵-۷ سال خدمت)، شتاب می‌گیرد و می‌تواند منجر به کاهش قابل توجه شاخص‌های عملکردی مانند شاخص وضعیت روسازی

آن‌ها پایه‌ای برای تصمیم‌گیری‌های مدیریتی، مانند اعمال عملیات بازسازی عمیق در سال‌های پیش‌بینی شده با شتاب بالا، فراهم می‌آورند. این شکل‌ها نه تنها پیشرفت خرابی‌ها را در قطعات متنوع روسازی (از راه‌های روستایی تا شهری) برجسته می‌کنند، بلکه اعتبار مدل‌ها را در پیش‌بینی بلند مدت نشان داده و به مدیران روسازی کمک می‌کنند تا منابع را بهینه تخصیص دهند.

فرآیند خوردگی را تسریع می‌کند) هستند. از دیدگاه فنی، این روند با مدل‌های مکانیکی-تجربی زوال همسو است، زیرا نرخ گسترش مساحت در مراحل میانی (پس از ۱۰ سال) به دلیل پدیده خستگی چرخه‌ای افزایش می‌یابد و می‌تواند منجر به تشکیل چاله‌ها و کاهش عمر مفید روسازی شود. مدل‌های پیش‌بینی پژوهش، با استفاده از تابع ضرر هوبر برای مقاومت در برابر داده‌های پرت، این روند را با ضریب تعیین ۰/۹۵۴ شبیه‌سازی کرده و خروجی‌های



شکل ۱۱. روند گسترش طول ترک خطی در طول زمان



شکل ۱۲. روند گسترش مساحت ترک پوست سوسماری در طول زمان


با مقادیر مثبت و بزرگ SHAP همراه هستند و مستقیماً به افزایش طول ترک پیش‌بینی شده در افق زمانی آینده منجر می‌شوند. این رفتار به روشنی بیانگر وجود پدیده‌ی حافظه خرابی و ماهیت خستگی محور^۳ ترک‌های طولی است؛ بدین معنا که مقاطعی که پیش‌تر دچار ترک‌خوردگی قابل توجه بوده‌اند، مستعد گسترش بیشتر ترک در آینده هستند. این الگو همچنین نشان دهنده یک ساز و کار اضمحلال یکنواخت است که در آن افزایش شدت خرابی فعلی، به صورت پیوسته احتمال و نرخ پیشروی خرابی را تشدید می‌کند. در مرتبه بعد، متغیرهای بارگذاری ترافیکی شامل روند تغییرات تردد کامیون‌ها (AADTT) و شاخص‌های بار محوری معادل (ESAL) قرار می‌گیرند که اثر آن‌ها عمدتاً افزایشی و هم‌راستا با مبانی مکانیکی شناخته شده است. با این حال، اهمیت این متغیرها نسبت به تاریخچه خرابی کمتر است. موضوعی که نشان می‌دهد رشد ترک‌های طولی نه صرفاً تابع بارگذاری، بلکه حاصل تعامل بین خرابی تجمع‌یافته گذشته و بارگذاری تکراری در طول زمان است. به بیان دیگر، بار ترافیکی نقش تسریع‌کننده دارد، اما بستر اصلی پیشروی ترک را وضعیت موجود روسازی تعیین می‌کند. در مقابل، متغیرهای اقلیمی در داده‌های حاضر اثر مستقلی نسبتاً ضعیف و پایدار از خود نشان می‌دهند و در نمودار SHAP به عنوان پیش‌بین‌های غالب ظاهر نمی‌شوند. این نتیجه با تفسیر مهندسی سازگار است، زیرا عوامل محیطی مانند چرخه‌های دما و تغییرات رطوبتی عمدتاً در مرحله آغاز ترک نقش پررنگ‌تری دارند تا در فرآیند گسترش و پیشروی ترک‌های موجود. در مجموع، الگوی رفتاری مدل از منظر SHAP کاملاً منطبق با اصول مکانیکی-تجربی روسازی بوده و اعتبار فیزیکی نتایج پیش‌بینی را بیان می‌کند.

در ادامه برای بررسی اهمیت نسبی متغیرهای ورودی، ارزیابی سازگاری رفتاری مدل با دانش مهندسی و اطمینان از عملکرد صحیح ساز و کار پیش‌بینی، در این پژوهش از رویکردهای هوش مصنوعی توضیح‌پذیر^۱ (XAI) استفاده شد. به طور مشخص، چارچوب روش مقادیر افزایشی شاپلی^۲ (SHAP) به عنوان یک روش مبتنی بر نظریه بازی‌ها به کار گرفته شد تا سهم کمی هر ویژگی در خروجی مدل پیش‌بینی خرابی روسازی تبیین شود. این تحلیل امکان شناسایی محرک‌های اصلی اضمحلال، تمایز میان عوامل غالب و ثانویه و بررسی اثرات اندرکنشی بین متغیرهای سازه‌ای، ترافیکی و محیطی را فراهم می‌کند. علاوه بر رتبه‌بندی اهمیت ویژگی‌ها، نتایج SHAP برای ارزیابی اعتبار فیزیکی و مهندسی مدل مورد استفاده قرار گرفت؛ به گونه‌ای که هم‌راستایی الگوهای یادگرفته شده با اصول مکانیکی-تجربی خرابی روسازی (نظیر نقش غالب سابقه خرابی، اثر تسریع‌کننده بارگذاری ترافیکی و نقش تعدیل‌کننده ضخامت سازه‌ای) بررسی شد. بدین ترتیب، XAI نه تنها به عنوان ابزاری برای تفسیر مدل، بلکه به عنوان یک ساز و کار کنترلی برای اطمینان از قابلیت اتکای نتایج پیش‌بینی و جلوگیری از یادگیری الگوهای غیرواقعی یا صرفاً آماری به کار گرفته شد.

تجزیه و تحلیل SHAP مربوط به ترک‌های طولی در شکل ۱۳ نشان می‌دهد که غالب‌ترین عامل در پیش‌بینی رشد این نوع خرابی، خود سابقه ترک‌خوردگی طولی است. به طوری که سه شاخص شدت محور طول ترک موجود (linear_length_low, linear_length_medium و linear_length_high) بیشترین سهم را در ساختار تصمیم‌گیری مدل دارند. مقادیر بالای تاریخی این ویژگی‌ها

3- Fatigue-driven

1- Explainable Artificial Intelligence (XAI)
2- SHapley Additive exPlanations




شکل ۱۳. خلاصه اهمیت ویژگی‌ها در پیش‌بینی ترک طولی

ترک پوست سوسماری حاصل برهم‌کنش بین خرابی تجمع‌یافته گذشته و بارگذاری تکراری است، نه صرفاً تابع شدت ترافیک جاری. نمونه‌هایی با ترکیبات نامطلوب متغیرها مانند سطوح بالای ترک پوست سوسماری همراه با ضخامت ترمیم کم و روند افزایشی ESAL، در تحلیل SHAP به عنوان نقاط بحرانی شناسایی می‌شوند که بیشترین پتانسیل اضمحلال سریع را دارند.

از سوی دیگر، ضخامت لایه ترمیم نقش محافظتی ایفا می‌کند و به تنهایی سهم مستقیمی در مقادیر SHAP ندارد، اما در تعامل با خرابی‌های شدید ترک پوست سوسماری به طور معناداری اثرگذار می‌شود. روکش‌های نازک در حضور ترک خوردگی شدید، مقادیر مثبت بالاتری از SHAP را نشان می‌دهند که بیانگر کاهش ظرفیت سازه‌ای و افزایش حساسیت به پیشروی خستگی تا عمق کامل روسازی است. در مجموع رفتار تفسیر شده مدل از طریق SHAP به خوبی با اصول مکانیکی-تجربی خرابی روسازی منطبق بوده و اعتبار مهندسی نتایج پیش‌بینی را تأیید می‌کند.

تحلیل SHAP مربوط به ترک پوست سوسماری در شکل ۱۴ نشان می‌دهد که سابقه خرابی پوست سوسماری در تمامی سطوح شدت (low / medium / high) قوی‌ترین محرک افزایش خرابی پیش‌بینی شده در آینده است. مقادیر بالای تاریخی این شاخص‌ها با افزایش قابل توجه مقادیر SHAP همراه بوده و بیانگر آن است که مقاطع دارای ترک پوست سوسماری موجود، به ویژه در شدت‌های متوسط و زیاد، مستعد گذار سریع به سطوح شدیدتر خرابی هستند. این رفتار با ماهیت غیرخطی و خستگی‌محور ترک پوست سوسماری همخوانی دارد؛ فرآیندی که در آن با هم‌پیوستن ریزترک‌ها، سطح خرابی به سرعت گسترش می‌یابد.

در میان سایر متغیرها، ویژگی‌های مرتبط با بارگذاری ترافیکی (نظیر روند ESAL و تردد کامیون‌ها) به عنوان عوامل تسریع‌کننده ظاهر می‌شوند که نقش آن‌ها اگر چه معنادار است، اما نسبت به سابقه خرابی سازه‌ای در مرتبه دوم اهمیت قرار می‌گیرد. این نتیجه مؤید آن است که رشد



شکل ۱۴. خلاصه SHAP اهمیت ویژگی‌ها در پیش‌بینی ترک پوست سوسماری

۶. نتیجه‌گیری

توسعه داده شده‌اند. نتایج نشان می‌دهد که اعمال راهبردهای متعادل‌سازی داده‌ها شامل SMOTE و داده‌افزایی مبتنی بر نویز گاوسی، نقش قابل توجهی در بهبود عملکرد کلاس‌های اقلیت (شدت متوسط و زیاد) داشته است؛

مدل‌های طبقه‌بندی شدت خرابی با صحت ۰/۸۳۴ برای ترک خفیف، ۰/۹۳۰ برای پوست سوسماری، دقت ۰/۸۴۵ برای ترک خفیف، ۰/۹۳۲ برای پوست سوسماری، فراخوانی ۰/۸۴۳ برای ترک خفیف، ۰/۹۲۹ برای پوست سوسماری و امتیاز افوان ۰/۸۴۳ برای ترک خفیف، ۰/۹۳۰ برای پوست سوسماری، پیش‌بینی شدت خرابی‌ها با دقت مناسبی را امکان‌پذیر ساخت؛

مدل‌های شبکه عصبی مصنوعی با ضریب تعیین ۰/۹۴۱ برای طول ترک خفیف، ۰/۹۵۴ برای مساحت پوست سوسماری، پیش‌بینی مناسب رفتار روسازی را فراهم نمود؛

برای بررسی رفتار آماری مدل‌ها، تحلیل باقی‌مانده‌ها و آزمون ناهمسانی واریانس انجام شد. نتایج آزمون بروش-پاگان نشان می‌دهد که برای هر دو مدل طول ترک خفیف و مساحت ترک پوست سوسماری، ناهمسانی واریانس در

مدل‌های پیش‌بینی زوال روسازی برای برنامه‌ریزی دقیق و اقتصادی تعمیر و نگهداری ضروری‌اند. پیش‌بینی طول ترک‌های خطی و مساحت ترک‌های پوست سوسماری کمک می‌کند شدت و روند گسترش خرابی‌ها زودتر تشخیص داده شده و مناسب‌ترین روش ترمیم انتخاب شود. این شاخص‌ها علاوه بر کاهش هزینه‌ها و جلوگیری از تشدید خرابی، در سامانه‌های هوشمند ارزیابی روسازی نیز کاربرد دارند و دقت تصمیم‌گیری را بهبود می‌دهند. در این پژوهش با استفاده از داده‌های پایگاه داده LTPP، مدل‌های پیش‌بینی برای پیش‌بینی شدت، طول ترک خطی و مساحت ترک پوست سوسماری توسعه داده شده‌اند. از مهم‌ترین نتایج پژوهش می‌توان به موارد زیر اشاره نمود:

- با توسعه مدل‌های پیش‌بینی شدت، طول و مساحت خرابی‌های روسازی بر اساس داده‌های پایگاه داده عملکرد بلند مدت روسازی، طول ترک خطی و مساحت ترک پوست سوسماری را با دقت مناسبی پیش‌بینی شده است؛
- مدل‌های طبقه‌بندی شدت خرابی برای ترک‌های خطی و ترک‌های پوست سوسماری با استفاده از مدل شبکه عصبی مصنوعی و تابع خطای فوکال

سازگار است. این نتایج امکان شناسایی زمان‌های بحرانی برای مداخله نگهداری پیشگیرانه را فراهم می‌کند؛

همچنین تحلیل نتایج SHAP بیانگر این بوده که سابقه خرابی، شاخص‌های بارگذاری ترافیکی (ESAL و AADTT) و ضخامت روسازی بیشترین سهم را در پیش‌بینی گسترش خرابی‌ها دارند. این یافته‌ها با مبانی مکانیکی-تجربی روسازی همخوانی داشته و نشان می‌دهد که مدل‌های یادگیری ماشین توسعه یافته، الگوهای معنادار فیزیکی را آموخته‌اند و صرفاً بر همبستگی‌های آماری تکیه ندارند.

سطح معناداری ۰/۰۵ مشاهده نمی‌شود. همچنین بازه‌های اطمینان ۹۵ درصدی تعیین با استفاده از روش بوت‌استرپ محاسبه گردید که همپوشانی مناسب بین مجموعه‌های آموزش و اعتبارسنجی را نشان داده و عدم بیش‌برازش مدل‌ها را تأیید می‌کند؛

پیش‌بینی روند زمانی خرابی‌ها در سال‌های آینده نشان می‌دهد که هر دو نوع خرابی دارای الگوی گسترش غیرخطی هستند. طول ترک‌های خطی و مساحت ترک‌های پوست سوسماری پس از عبور از یک آستانه زمانی مشخص، با شتاب بیشتری افزایش می‌یابند که این رفتار با مفاهیم خستگی تجمعی و زوال سازه‌ای روسازی

۷. تأییدیه اخلاقی

نویسندگان متعهد می‌شوند که مطالب این مقاله را در هیچ مجله دیگری به چاپ نرسانده‌اند.

۸. مشارکت‌های نویسندگان

محمد صدیقیان فرد: نگارش، بررسی و ویرایش، نگارش پیش‌نویس اصلی، بصری‌سازی، اعتبارسنجی، روش‌شناسی، جذب منابع مالی، تحلیل اصلی، گردآوری داده‌ها، مفهوم‌سازی. امیر گل‌رو: نگارش، بررسی و ویرایش، نظارت، جذب منابع مالی. حنا دهقان‌طزرجانی: روش‌شناسی، نگارش، بصری‌سازی.

۹. منابع مالی

این اثر تحت حمایت مادی بنیاد ملی علم ایران (INSF) بر گرفته شده از طرح شماره (۴۰۲۵۵۷۱) انجام شده است.

۱۰. تعارض منافع

نویسندگان مقاله اعلام می‌کنند که در مورد انتشار این مقاله تعارض منافع وجود ندارد.

۱۱. مراجع

- Basnet, K. S., Shrestha, J. K., & Shrestha, R. N. (2023). "Pavement performance model for road maintenance and repair planning: A review of predictive techniques". *Digit. Transport. Safety*, 4(2): 253–267.
- George, K. P., Rajagopal, A. S., & Lim, L. K. (1989). "Models for predicting pavement deterioration". *Transport. Res. Record*, No. 1215.
- Hamdi, S. P., Hadiwardoyo, A. G., Correia, P., Pereira, P., & Cortez, P. (2017). "Prediction of surface distress using neural networks". In *AIP Conference Proceedings*, American Institute of Physics Inc.
- Hu, A., Bai, Q., Chen, L., Meng, S., Li, Q., & Xu, Z. (2022). "A review on empirical methods of pavement performance modeling". *Constr. Build. Mater.*, 342: 127968.
- Justo-Silva, R., Ferreira, A., & Flintsch, G. (2021). "Review on machine learning techniques for developing pavement performance prediction models". *Sustain.*, 13(9): 5248.
- Kang, J., Tavassoti, P., Chaudhry, M. N. A. R., Baaj, H. & Ghafurian, M. (2025). "Artificial intelligence techniques for pavement performance prediction: A systematic review". Taylor and Francis Ltd.
- Kobayashi, K., Do, M., & Han, D. (2010). "Estimation of Markovian transition probabilities for pavement deterioration forecasting". *KSCE J. Civ. Eng.*, 14(3): 343–351.
- Lidicker, J., Sathaye, N., Madanat, S., & Horvath, A. (2013). "Pavement resurfacing policy for minimization of life-cycle costs and greenhouse gas emissions". *J. Infrastruct. Syst.*, 19(2): 129–137.
- Liu, M., Wang, M., & Hoogendoorn, S. (2019). "Optimal platoon trajectory planning approach at arterials". *Transport. Res. Record*, 2673(9): 214–226.
- LTPP InfoPave-Distress Maps and Images. (n.d.). Accessed August 20, 2023. <https://infopave.fhwa.dot.gov/Me dia/DistressMapsImages/>.
- Peraka, N. S. P., Biligiri, K. P., & Kalidindi, S. N. (2021). "Development of a multi-distress detection system for asphalt pavements: Transfer learning-based approach". *Transport. Res. Record*, 2675: 538–553.
- Pulugurta, H., Shao, Q., & Chou, Y. J. (2009). "Pavement condition prediction using Markov process". *J. Stat. Manag. Syst.*, 12(5): 853–871.
- Roberts, C. A., & Attoh-Okine, N. O. (1998). "A comparative analysis of two artificial neural networks using pavement performance prediction". *Comput. Civ. Infrastruct. Eng.*, 13(5): 339–348.
- Saudy, M., Breakah, T., Kaloop, M. R., & El-Badawy, S. (2023). "Regional implementation of the mechanistic empirical pavement design and analysis approach: Egyptian case study". *Case Stud. Constr. Mater.*, 18: e01863.
- Shahid, C. S., Zainal, Z. A., Yusoff, N. I. M., Mohammad, N., Zamzuri, Z. H., & Widyatmoko, I. (2025). "Stochastic-based pavement performance and deterioration models: A review of techniques and applications". *Alexandria Eng. J.*, 120: 420–437.
- Shtayat, A., Moridpour, S., Best, B., & Rumi, S. (2022). "An overview of pavement degradation prediction models". *J. Adv. Transport.*, 2022(1): 7783588.
- Tamagusko, T., Gomes Correia, M., & Ferreira, A. (2024). "Machine learning applications in road pavement management: a review, challenges and future directions". *Infrastruct.*, 9(12): 21