



Semnan University



## Research Article

## Predicting Pavement Functional Performance Using Machine Learning: A Case Study of the International Roughness Index

Masoud Yekekhani<sup>a\*</sup>, Amir Golroo<sup>b</sup>, Fereidoon Moghadas Nejad<sup>c</sup>

<sup>a</sup> MSc., Road and Transportation Engineering, Department of Civil and Environmental Engineering, Amirkabir University of Technology, Tehran, I. R. Iran.

<sup>b</sup> Associate Professor, Road and Transportation Engineering Group, Department of Civil and Environmental Engineering, Amirkabir University of Technology, Tehran, I. R. Iran.

<sup>c</sup> Professor, Road and Transportation Engineering Group, Department of Civil and Environmental Engineering, Amirkabir University of Technology, Tehran, I. R. Iran.

## PAPER INFO

**Paper history:**

Received: 2025-11-19

Revised: 2026-02-18

Accepted: 2026-02-20

**Keywords:**

Pavement management system,  
Pavement performance evaluation,  
International Roughness Index,  
Machine learning.

## ABSTRACT

Pavement networks play a vital role in national transportation infrastructure and economic growth by enabling the safe, rapid, and economical movement of goods, services, and people. The quality of these networks is heavily influenced by various types of distress; therefore, accurate prediction of such distress is essential for effective pavement management. Furthermore, machine learning models have recently demonstrated significant potential in modeling pavement performance. This study aims to employ machine learning models to predict the functional condition of pavements, specifically the International Roughness Index (IRI). The research data were extracted from the Long-Term Pavement Performance (LTPP) database managed by the U.S. Federal Highway Administration. The dataset comprises 4,453 records related to pavement structure and construction, weather, traffic, and pavement performance, encompassing 12 effective variables. Seven machine learning algorithms—Decision Tree, Random Forest, XGBoost, Gradient Boosting, K-Nearest Neighbors, Support Vector Regression, and Artificial Neural Network—were used to predict the IRI. Model performance was evaluated using Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Coefficient of Determination ( $R^2$ ). Comparative analysis revealed that the XGBoost and Random Forest algorithms outperformed the others in predicting IRI, with MAE values of 0.17 and 0.18 and  $R^2$  values of 0.73 and 0.74, respectively. The model developed in this research can serve as a precise and practical tool in pavement management systems for timely roughness prediction and optimizing maintenance programs and budget allocation.

\* Corresponding author.

E-mail address: [masoudyekekhani@aut.ac.ir](mailto:masoudyekekhani@aut.ac.ir)



مقاله پژوهشی

پیش‌بینی وضعیت عملکردی روسازی با استفاده از یادگیری ماشین: مطالعه موردی شاخص بین‌المللی ناهمواری

مسعود یکه‌خانی<sup>۱\*</sup>، امیر گل‌رو<sup>۲</sup>، فریدون مقدس‌نژاد<sup>۳</sup>

<sup>۱</sup> کارشناسی ارشد راه و ترابری، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران.

<sup>۲</sup> دانشیار، گروه راه و ترابری، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران.

<sup>۳</sup> استاد، گروه راه و ترابری، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران

چکیده

اطلاعات مقاله

شبکه‌های روسازی از طریق امکان جابجایی کالاها، خدمات و افراد به شیوه‌ای ایمن، سریع و اقتصادی نقش حیاتی در زیرساخت‌های حمل‌ونقل ملی و رشد اقتصادی کشورها دارند. کیفیت شبکه‌های روسازی به شدت تحت تأثیر انواع خرابی‌ها قرار می‌گیرد. در نتیجه، برای اطمینان از مدیریت مؤثر روسازی، پیش‌بینی دقیق این خرابی‌ها ضروری است. علاوه بر این، مدل‌های یادگیری ماشین در سال‌های اخیر پتانسیل بالایی در مدل‌سازی عملکرد روسازی نشان داده‌اند. هدف این تحقیق، بکارگیری مدل‌های یادگیری ماشین برای پیش‌بینی وضعیت عملکردی روسازی به ویژه شاخص بین‌المللی ناهمواری است. داده‌های این پژوهش از مرکز داده‌ی برنامه عملکرد بلندمدت روسازی تحت نظارت اداره فدرال بزرگراه‌های آمریکا استخراج شده‌اند. مجموعه داده شامل ۴۴۵۳ ردیف داده مربوط به سازه و ساخت روسازی، آب‌وهوا، ترافیک و عملکرد روسازی که در مجموع ۱۲ متغیر مؤثر است. از هفت الگوریتم یادگیری ماشین برای پیش‌بینی شاخص بین‌المللی ناهمواری شامل درخت تصمیم، جنگل تصادفی، ایکس‌جی‌بوست، تقویت گرادیان،  $K$ -نزدیکترین همسایه، رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی استفاده شد. عملکرد مدل‌ها با استفاده از معیارهای میانگین مطلق خطا، میانگین مربعات خطا، مجذور میانگین مربعات خطا و ضریب تعیین ارزیابی شد. تحلیل مقایسه‌ای نشان داد که الگوریتم ایکس‌جی‌بوست و جنگل تصادفی با میانگین مطلق خطا برابر با ۰/۱۷ و ۰/۱۸ همچنین ضریب تعیین به ترتیب ۰/۷۳ و ۰/۷۴ برای پیش‌بینی شاخص بین‌المللی ناهمواری عملکرد بهتری نسبت به باقی الگوریتم‌ها دارند. مدل توسعه‌یافته در این پژوهش می‌تواند به عنوان ابزاری دقیق و عملی در سیستم‌های مدیریت روسازی برای پیش‌بینی به‌موقع ناهمواری و بهینه‌سازی برنامه‌های نگهداری و تخصیص بودجه مورد استفاده قرار گیرد.

دریافت مقاله: ۱۴۰۴/۰۸/۲۸

بازنگری مقاله: ۱۴۰۴/۱۱/۲۹

پذیرش مقاله: ۱۴۰۴/۱۲/۰۱

واژه‌های کلیدی:

سیستم مدیریت روسازی، ارزیابی عملکردی روسازی، شاخص بین‌المللی ناهمواری، یادگیری ماشین.

\* پست الکترونیک نویسنده مسئول: [masoudyekekhanian@aut.ac.ir](mailto:masoudyekekhanian@aut.ac.ir)

استناد به این مقاله: یکه‌خانی، مسعود، گل‌رو، امیر و مقدس‌نژاد، فریدون. (۱۴۰۴). پیش‌بینی وضعیت عملکردی روسازی با استفاده از یادگیری ماشین: مطالعه موردی شاخص بین‌المللی ناهمواری، مهندسی زیرساخت‌های حمل و نقل، ۱۱(۴)، ۱-۲۶.

<https://doi.org/10.22075/jtie.2026.39731.1747>

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

## ۱. مقدمه

یک محدوده زمانی مشخص کمک می‌کند (آشتو، ۱۹۹۳). این سیستم زمان مناسب برای فعالیت‌های تعمیر و نگهداری را بر اساس پیش‌بینی شاخص‌های روسازی تعیین نموده و امکان توسعه برنامه‌های نگهداری پیشگیرانه و افزایش عمر روسازی را فراهم می‌آورد (وینوسا و همکاران، ۲۰۲۰).

هدف اصلی سیستم مدیریت روسازی، ارائه یک برنامه بهینه است تا راهنمایی برای متولیان راه باشد. این برنامه به آنان کمک می‌کند که بدانند چه زمان و با چه روشی به تعمیر روسازی بپردازند تا علاوه بر بهبود وضع راه، این عملیات کمترین هزینه را برای آن‌ها دربر داشته باشد (راگنولی و همکاران، ۲۰۱۸).

سیستم مدیریت روسازی از سه مرحله اصلی تشکیل شده است. مرحله اول جمع‌آوری داده، مرحله دوم تحلیل داده و مرحله سوم برنامه‌ریزی برای اقدامات نگهداری است (بنمهاهه و چنتوفی، ۲۰۲۱). در این فرآیند، با جمع‌آوری داده، شرایط حال حاضر روسازی مورد بررسی قرار می‌گیرد. در ادامه، با انتخاب یک روش مناسب برای تحلیل داده‌های جمع‌آوری شده، داده‌ها پردازش شده و در نهایت با محاسبه یکی از شاخص‌های مورد نظر، اقدامات لازم برای تهیه یک برنامه تعمیر و نگهداری بهینه انجام می‌شود (پراکا و بیلگیری، ۲۰۲۰).

## ۲-۲. الگوریتم‌های یادگیری ماشین در تحلیل

### وضعیت روسازی

یادگیری ماشین به عنوان زیرمجموعه‌ای از هوش مصنوعی، امکان یادگیری الگوهای نهفته در داده‌ها و پیش‌بینی متغیرهای مورد مطالعه را فراهم می‌کند. این روش در حوزه‌های مختلف مهندسی عمران از جمله تشخیص خرابی‌های روسازی به کار گرفته شده است (شولوار و همکاران، ۲۰۲۲). در این پژوهش، از روش رگرسیون (به دلیل پیوسته بودن متغیر هدف) و الگوریتم‌های درخت تصمیم، جنگل تصادفی، تقویت

شبکه‌های روسازی به‌عنوان زیرساخت‌های حیاتی، نقش تعیین‌کننده‌ای در رشد اقتصادی، رفاه اجتماعی و پایداری محیطی دارند. بر اساس گزارش اداره فدرال بزرگراه‌های آمریکا، ۳۱/۵ درصد از سرمایه‌گذاری‌های زیرساختی در ایالات متحده به روسازی راه اختصاص یافته است (بانیستر و برچمن، ۲۰۰۱).

شبکه‌های روسازی با تسهیل تجارت و اتصال بازارها به رشد اقتصادی کمک می‌کنند (بانیستر و برچمن، ۲۰۰۱) و از طریق ایجاد اشتغال و بهبود دسترسی به خدمات ضروری، نقش اجتماعی ایفا می‌نمایند (کی و همکاران، ۲۰۲۰؛ لیتمن، ۲۰۱۷). از جنبه محیط‌زیستی، کیفیت روسازی با کاهش مصرف سوخت و انتشار آلاینده‌ها (استریمیکینه و همکاران، ۲۰۱۳) و همچنین کاهش تصادفات (چان و همکاران، ۲۰۱۰) مرتبط است. علاوه بر این، این شبکه‌ها با ترویج حمل‌ونقل فعال، سبک زندگی سالم را تقویت می‌کنند (پوچر و دیکسترا، ۲۰۰۳).

مدل‌های یادگیری ماشین با تحلیل داده‌های بزرگ، قادر به پیش‌بینی نرخ فرسایش روسازی تحت شرایط مختلف محیطی و بارگذاری هستند که منجر به تخصیص بهینه منابع و راهبردهای نگهداری پیش‌گیرانه می‌شود (بشار و تورس‌ماچی، ۲۰۲۱). با این وجود، چالش‌هایی از جمله نیاز به روش‌های یکپارچه جمع‌آوری داده، مجموعه داده‌های بزرگ برای آموزش مدل و اعتبارسنجی در سناریوهای واقعی هنوز وجود دارد (خوستو-سیلوا و همکاران، ۲۰۲۱).

## ۲. مفهوم کلی

### ۲-۱. سیستم مدیریت روسازی

سیستم مدیریت روسازی مجموعه‌ای از ابزارها و روش‌هاست که به تصمیم‌گیرندگان در تعیین استراتژی بهینه برای برنامه‌ریزی ارزیابی و نگهداری روسازی در

پایگاه داده LTTP، عملکرد برتر جنگل تصادفی با ضریب تعیین  $0/92-0/85$  را نشان دادند.

در زمینه شبکه‌های عصبی، حسین و همکاران (۲۰۱۹) مدلی با ۷ متغیر ورودی و دو لایه پنهان توسعه دادند؛ در حالی که عبدالعزیز و همکاران (۲۰۲۰) ترکیب شبکه عصبی با رگرسیون خطی چندگانه را پیشنهاد کردند. جورجیو و همکاران (۲۰۱۸) نیز برتری شبکه عصبی نسبت به ماشین بردار پشتیبان را تأیید نمودند.

الگوریتم‌های ترکیبی نظیر ایکس‌چی بوست و گرادیان بوستینگ نیز مورد توجه قرار گرفته‌اند. دمیرچیلو و همکاران (۲۰۲۱) با استفاده از ۱۲۶۳۷ رکورد داده، دقت بالای ایکس‌چی بوست را گزارش کردند. گو و همکاران (۲۰۲۱) نیز مدل درخت تصمیم تقویتی گرادیان با ضریب تعیین  $0/9$  را توسعه دادند.

روش‌های ترکیبی همچون مدل مزاری و همکاران (۲۰۱۶) که تلفیق شبکه عصبی و برنامه‌ریزی بیان ژن بود، نتایج امیدوارکننده‌ای نشان داد. همچنین مطالعات تحلیل حساسیت توسط زیاری و همکاران (۲۰۱۶) نشان داد که بارش سالانه و ترافیک روزانه مؤثرترین متغیرها هستند.

گونگ و همکاران (۲۰۱۸) و لی و همکاران (۲۰۱۸) به ترتیب بر مزیت جنگل تصادفی در جلوگیری از بیش‌پردازش و ارائه روش محاسباتی بهبودیافته در حوزه زمان تأکید کردند. این مطالعات در مجموع نشان می‌دهند که رویکردهای یادگیری ماشین پتانسیل قابل توجهی در پیش‌بینی دقیق شاخص‌های عملکرد روسازی دارند.

با توجه به تنوع و پیچیدگی این تحقیقات، جدول ۱ برای خلاصه‌سازی تحقیقات قبلی در این حوزه تهیه شده است.

گرادیان، ایکس‌چی‌بوست، K-نزدیکترین همسایه، رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی استفاده شده است.

## ۲-۳. معیارهای ارزیابی مدل‌های یادگیری ماشین

هیچ مدل پیش‌بینی یادگیری ماشینی از نظر قابلیت‌های پیش‌بینی کاملاً دقیق نیست. این انعطاف به منظور جلوگیری از بیش‌برازش در هنگام آموزش و توسعه این مدل‌ها در نظر گرفته می‌شود. در نتیجه، ضروری است که عملکرد مدل‌های یادگیری ماشین را به صورت کمی اندازه‌گیری کرد تا بتوان به درستی ارزیابی کرده و در بیشتر موارد، نتایج چند مدل مختلف را با هم مقایسه کرد. برای ارزیابی عملکرد مدل‌های رگرسیون از معیارهای مختلفی استفاده می‌شود که شامل میانگین خطای مطلق (MAE) به عنوان میانگین مجموع خطاها بدون در نظر گرفتن علامت، میانگین مربعات خطا (MSE) که با مربع کردن خطاها بر تأثیر خطاهای بزرگتر تأکید می‌کند، مجذور میانگین مربعات خطا (RMSE) که با گرفتن جذر MSE حساسیت به داده‌های پرت را کاهش می‌دهد، و ضریب تعیین ( $R^2$ ) که درصد تغییرات متغیر وابسته را که توسط مدل توضیح داده می‌شود نشان می‌دهد، می‌باشند.

## ۳. مرور ادبیات

مطالعات متعددی با استفاده از الگوریتم‌های یادگیری ماشین برای پیش‌بینی شاخص بین‌المللی ناهمواری (IRI) انجام شده است. مطاعی و همکاران (۲۰۲۱) با توسعه مدل درخت تصمیم ابری، دقت  $81/29\%$  برای بزرگراه‌ها و  $80/66\%$  برای راه‌های اصلی گزارش کردند. قدرت‌آبادی و همکاران (۲۰۲۵) با تحلیل ۲۷۰۸ نمونه از

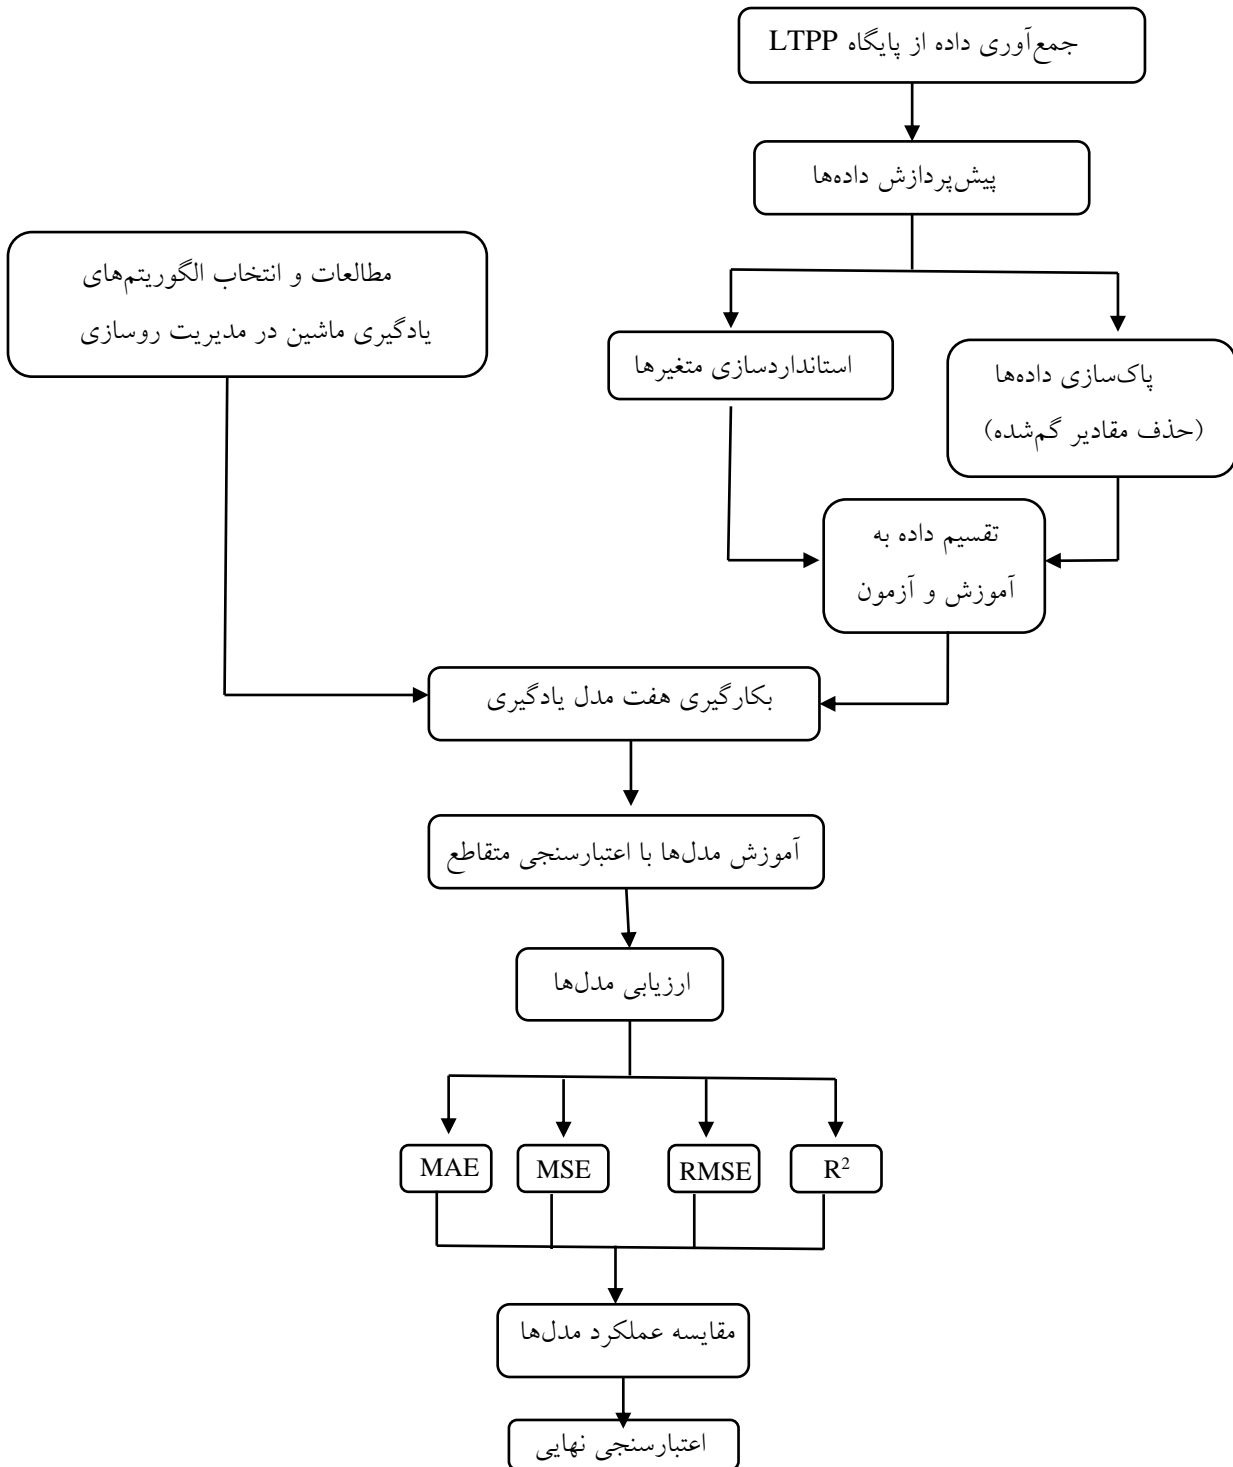
جدول ۱. مقایسه الگوریتم‌های یادگیری ماشین برای ارزیابی وضعیت روسازی

نویسندگان	شاخص روسازی	مدل‌های استفاده شده	متغیرهای مورد بررسی	تعداد نقاط داده	ارزیابی
سیاس پور و همکاران (۲۰۲۱)	شاخص بین‌المللی ناهمواری	بهینه‌سازی تکاملی و تفاضلی	شاخص بین‌المللی ناهمواری، متوسط سالانه ترافیک روزانه کامیون، ضخامت لایه آسفالتی، نرخ بارندگی سالانه، ضخامت لایه اساس، تعداد روزهای ایجاد ذوب و یخ در سال، درصد رطوبت نسبی متوسط سالانه و دمای متوسط سالانه هوا	۳۳۳	ضریب تعیین: ۰/۹۷ مجذور میانگین مربعات خطا: ۰/۲
مطاعی و همکاران (۲۰۲۱)	شاخص بین‌المللی ناهمواری	درخت تصمیم	۹ متغیر ورودی	-	دقت برابر با ۸۰/۳۵
قدرت‌آبادی و همکاران (۲۰۲۵)	شاخص بین‌المللی ناهمواری	جنگل تصادفی ماشین بردار پشتیبان	میزان تعمیرات، سن روسازی، ترافیک بارندگی، دما، رطوبت، شاخص یخبندان، ضخامت لایه‌های آسفالت، اساس و زیراساس.	۲۷۰۸	ضریب تعیین به ترتیب: ۰/۸ - ۰/۹۶ ۰/۶ - ۰/۹۲
حسین و همکاران (۲۰۱۹)	شاخص بین‌المللی ناهمواری	شبکه عصبی مصنوعی	دمای سالانه، شاخص یخبندان، رطوبت، بارندگی، ترافیک روزانه سالانه	۲۰۰	مجذور میانگین مربعات خطا: ۰/۰۲۷
کالوپ و همکاران (۲۰۲۳)	شاخص بین‌المللی ناهمواری	رگرسیون فرایند گاوسی، چندجمله‌ای وزن‌دار محلی مدل پی‌اس‌او - انفیس، مدل پی‌اس‌او - شبکه عصبی مصنوعی	سن روسازی، شاخص بین‌المللی ناهمواری اولیه، ترک‌های پوست‌سوسماری، طولی، عرضی، انحراف معیار شیارشدگی، شاخص پلاستیسیته زیراساس	۹۲۵	ضریب تعیین به ترتیب: ۰/۹۳، ۰/۹، ۰/۶۵، ۰/۵۲
دمیرچیلو و همکاران (۲۰۲۱)	شاخص بین‌المللی ناهمواری	ایکس‌جی‌بوست، جنگل تصادفی، رگرسیون بردار پشتیبان	۱۰ متغیر ورودی	۱۲۶۳۷	ضریب تعیین به ترتیب: ۰/۷، ۰/۶۶، ۰/۴۴ میانگین مطلق خطا به ترتیب: ۰/۲، ۰/۲۲، ۰/۲۸
رونهوا و همکاران (۲۰۲۱)	شاخص بین‌المللی ناهمواری و شاخص عمق شیارشدگی	گرادپان تقویتی، شبکه عصبی مصنوعی	متغیرهای مختلف از پایگاه داده برنامه عملکرد بلندمدت روسازی‌ها	۱۶۰۰	ضریب تعیین به ترتیب: ۰/۸، ۰/۸۳

#### ۴. هدف و محدوده مطالعه

این پژوهش در پی پاسخ به این پرسش اساسی است که کدامیک از الگوریتم‌های یادگیری ماشین، با در نظر گرفتن معیارهای دقت و قابلیت تعمیم‌پذیری، بهترین عملکرد را برای پیش‌بینی شاخص IRI در یک مجموعه داده واقعی و بزرگ دارا می‌باشد.

هدف اصلی این پژوهش، توسعه یک مدل پیش‌بینی دقیق و قابل اعتماد برای شاخص بین‌المللی ناهمواری با به‌کارگیری جامع‌ترین مجموعه از الگوریتم‌های یادگیری ماشین و استفاده از یک پایگاه داده گسترده و معتبر است.



شکل ۱. روش تحقیق

و در مرحله آخر ارزیابی و اعتبارسنجی مدل‌ها با بررسی خطا و ضریب تعیین مدل‌ها به منظور انتخاب بهترین مدل انجام شد. روش تحقیق در شکل ۱ نشان داده شده است

#### ۱-۵. جمع‌آوری داده‌ها

یکی از مهم‌ترین جنبه‌های هر مدل یادگیری ماشین، کیفیت مجموعه داده‌های مورد استفاده برای آموزش و آزمون مدل است. در این پژوهش، پایگاه مرکز داده‌ی برنامه عملکرد بلندمدت روسازی تحت نظارت اداره فدرال بزرگراه‌های آمریکا به عنوان منبع اصلی داده‌ها انتخاب شد، زیرا شامل داده‌های جامعی در مورد عوامل مختلف مؤثر بر عملکرد روسازی است.

برای اطمینان از قابلیت تعمیم‌پذیری مدل‌های توسعه یافته، داده‌های این پژوهش از ۲۵ ایالت مختلف آمریکا و چند استان کانادا با شرایط آب‌وهوایی کاملاً متفاوت جمع‌آوری شده‌اند. این مجموعه داده شامل مناطق گرم و خشک (آریزونا، کالیفرنیا، نوادا)، مناطق سرد و برفی (مینه‌سوتا، مین، داکوتای شمالی)، مناطق معتدل و مرطوب (کارولینای شمالی، مریلند، نیوجرسی) و مناطق کوهستانی (کلرادو، وایومینگ، یوتا) می‌باشد.

بازه زمانی جمع‌آوری داده‌های مورد استفاده در این پژوهش، سال‌های ۱۹۸۹ تا ۲۰۱۷ را در بر می‌گیرد که منطبق بر بازه زمانی موجود در پایگاه داده LTPP برای قطعات انتخابی می‌باشد. این بازه ۲۸ ساله، امکان پوشش طیف وسیعی از شرایط محیطی و ترافیکی را فراهم آورده است.

برای تفکیک داده‌ها به بخش‌های آموزش و آزمون، ۸۰ درصد از داده‌ها (۳۵۶۲ ردیف) برای آموزش مدل‌ها و ۲۰ درصد باقی‌مانده (۸۹۱ ردیف) برای آزمون مدل‌ها اختصاص یافت. نکته حائز اهمیت آنکه داده‌های آزمون شامل نمونه‌هایی از کل بازه زمانی (۱۹۸۹-۲۰۱۷) می‌باشند و هیچ سال خاصی به طور کامل از فرآیند مدل‌سازی حذف نشده است. این رویکرد تصادفی، که در مطالعات مشابه نظیر دمیرچیلو و همکاران (۲۰۲۱) نیز

در راستای این هدف کلی، اهداف فرعی پژوهش شامل موارد زیر می‌گردد: انجام یک مطالعه تطبیقی سیستماتیک بین هفت الگوریتم یادگیری ماشین مختلف روی یک مجموعه داده یکسان که امکان ارزیابی عینی و مقایسه مستقیم عملکرد هر مدل را فراهم می‌سازد؛ تأکید ویژه بر قابلیت تعمیم‌پذیری مدل‌ها از طریق ارزیابی عملکرد بر اساس داده‌های آزمون و تحلیل پدیده بیش‌برازش که منجر به شناسایی مدل‌های باثبات‌تری گردیده است؛ به‌کارگیری یک مجموعه داده یکپارچه و گسترده متشکل از متغیرهای کلیدی مؤثر بر رفتار روسازی؛ و در نهایت، تحلیل اهمیت متغیرها و شناسایی پارامترهای تأثیرگذار که بینش ارزشمندی برای مهندسان در اولویت‌بندی عوامل مؤثر در مدیریت روسازی ارائه می‌کند.

نوآوری این مطالعه در تحقق همین اهداف و در قالب انجام مقایسه‌ای سیستماتیک، تأکید بر تعمیم‌پذیری، استفاده از داده‌ای یکپارچه و تحلیل اهمیت متغیرها تبیین می‌شود.

#### ۵. روش تحقیق

این پژوهش در سه مرحله اصلی طراحی شده است در مرحله اول جمع‌آوری و پیش‌پردازش داده‌های روسازی از مرکز داده‌ی برنامه عملکرد بلندمدت روسازی تحت نظارت اداره فدرال بزرگراه‌های آمریکا، شامل شاخص عملکرد روسازی، بارهای ترافیکی و شرایط محیطی انجام شد. سپس در مرحله بعد به بکارگیری هفت الگوریتم یادگیری ماشین (درخت تصمیم، جنگل تصادفی، ایکس‌جی‌بوست، تقویت گرادیان، K-نزدیکترین همسایه، رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی) برای پیش‌بینی شاخص ناهمواری بین‌المللی صورت گرفت. در این فرآیند، داده‌ها به دو بخش آموزش و آزمایش تقسیم شده‌اند تا ابتدا الگوهای موجود شناسایی و سپس دقت پیش‌بینی‌ها سنجیده شود

مورد استفاده در این پژوهش، متغیر مرتبط با شرایط زهکشی به صورت یکپارچه برای تمامی قطعات موجود نبوده است. از این رو، این متغیر در میان ۱۲ متغیر نهایی ورودی مدل‌ها لحاظ نگردیده است. پیشنهاد می‌گردد در پژوهش‌های آتی با تمرکز بر پروژه‌های خاص LTPP، تأثیر پارامترهای زهکشی بر پیش‌بینی شاخص IRI مورد بررسی دقیق‌تری قرار گیرد.

این پایگاه داده شامل اطلاعاتی در باره عوامل مختلف تأثیرگذار بر عملکرد روسازی است. یکی از اطلاعات اصلی این پایگاه داده، مقادیر مختلف شاخص بین‌المللی ناهمواری است. سایر متغیرهای مهم موجود در این پایگاه داده شامل شرایط محیطی، بارهای ترافیکی و ویژگی‌های مقطع راه است. در این پژوهش از داده‌های تمام ایالت‌های آمریکا استفاده شده است.

داده‌های خام مورد استفاده در این تحقیق از پایگاه عمومی LTPP استخراج شده و داده‌های پردازش‌شده ناشی از این پژوهش بنا به درخواست، در اختیار محققان قرار می‌گیرد.

#### ■ تعیین متغیرهای مورد استفاده در مدل

متغیرها بر اساس مطالعات پیشین و در دسترس بودن در پایگاه داده LTPP انتخاب شدند. همبستگی متغیرها با شاخص IRI و تأثیر آن‌ها بر عملکرد روسازی ملاک انتخاب بوده است.

مجموعه داده نهایی شامل ۴۴۵۳ ردیف داده که شامل ۱۱ متغیر ورودی و یک متغیر خارجی می‌باشد. همانطور که در ادبیات موضوع بحث شد، عوامل مختلفی بر عملکرد روسازی و ایجاد خرابی‌های مختلف تأثیر می‌گذارند. به منظور بررسی جامع عوامل مؤثر، ۱۲ عامل در نظر گرفته شد. جدول ۲، این عوامل را همراه با واحد اندازه‌گیری و عنوان آن در مدل خلاصه کرده است.

به کار رفته است، اطمینان می‌دهد که مدل‌ها برای پیش‌بینی در شرایط مختلف زمانی تعمیم‌پذیری مناسبی دارند. شایان ذکر است که انتخاب نسبت ۸۰ به ۲۰ در این پژوهش، با هدف ایجاد تعادل بین حجم داده‌های آموزشی کافی برای یادگیری الگوها و داده‌های آزمون کافی برای ارزیابی معتبر، صورت گرفته است.

این تنوع جغرافیایی و زمانی باعث شده است که داده‌ها شامل محدوده وسیعی از شرایط محیطی باشند و مدل‌های توسعه یافته در شرایط مختلف آب‌وهوایی و ترافیکی کارایی قابل قبولی داشته باشند. اگرچه عملکرد الگوریتم‌ها ممکن است در شرایط خاصی بهبود یابد، اما استفاده از این مجموعه داده متنوع این اطمینان را ایجاد می‌کند که مدل‌های ارائه شده از قابلیت تعمیم‌پذیری مناسبی برخوردار هستند.

اگرچه در این پژوهش از داده‌های ۲۵ ایالت مختلف آمریکا و چند استان کانادا استفاده شده است، اما به دلیل محدودیت‌های دسترسی و یکپارچگی داده‌ها، ارائه نقشه تفکیکی تک‌تک قطعات مورد مطالعه امکان‌پذیر نبوده است. با این حال، شایان ذکر است که پایگاه داده LTPP از طریق سامانه InfoPave امکان نمایش جغرافیایی قطعات آزمایشی را فراهم می‌آورد که پژوهشگران می‌توانند موقعیت مکانی هر قطعه را به صورت نقطه‌ای روی نقشه مشاهده نمایند.

در خصوص شرایط زهکشی، باید خاطر نشان ساخت که پایگاه داده LTPP اطلاعات جامعی در مورد سیستم‌های زهکشی زیرسطحی در پروژه‌های ویژه‌ای جمع‌آوری نموده است. مطالعات پیشین نشان داده‌اند که وجود زهکشی مناسب می‌تواند تأثیر معناداری بر عملکرد روسازی، به ویژه در کاهش ترک‌های عرضی و شیارشدگی داشته باشد. با این وجود، در مجموعه داده

جدول ۲. تعیین متغیرهای مورد استفاده در مدل

ردیف	گروه داده	نام متغیر	عنوان در مدل
۱	عملکرد روسازی	بین‌المللی ناهمواری	IRI
۲	سازه و ساخت روسازی	ضخامت لایه آسفالت سطح کل	REPR_THICKNESS_AC Pavemant (Surface Layer + Bider Layer)
۳		عرض خط	LANE_WIDTH
۴		عدد سازه‌ای	SN_VALUE
۵	ترافیک	تعداد کل محورهای استاندارد در خط طرح	ANNUAL_ESAL_TREND_CUMULATIVE
۶		متوسط ترافیک روزانه سالانه	REP_AADTT
۷	آب و هوا	میزان بارش سالانه	TOTAL_ANN_PRECIP
۸		میزان برف سالانه	TOTAL_SNOWFALL_YR
۹		میانگین دمای روزانه سالانه	MEAN_ANN_TEMP_AVG
۱۰		شاخص یخ‌زدگی	FREEZE_INDEX_YR
۱۱		تعداد کل روزهای انجماد و ذوب در سال	FREEZE_THAW_YR
۱۲		رطوبت نسبی متوسط سالانه	MEAN_ANN_HUM_AVG

### ۲-۵. پیش‌پردازش داده‌ها

پیش‌پردازش داده‌ها در این پژوهش شامل سه مرحله اصلی بود: ابتدا پاک‌سازی داده‌ها با بررسی و حذف مقادیر گم‌شده و پرت انجام شد. سپس نرمال‌سازی تمام متغیرهای عددی با استفاده از روش استانداردسازی به منظور تبدیل داده‌ها به توزیع نرمال با میانگین صفر و انحراف معیار یک صورت گرفت، و در نهایت مجموعه داده به صورت تصادفی به دو بخش آموزش (۸۰٪) و آزمون (۲۰٪) تقسیم شد تا از ایجاد سوگیری در فرآیند آموزش و ارزیابی مدل‌ها جلوگیری شود.

### ۳-۵. بکارگیری مدل‌های یادگیری ماشین

برای این پژوهش، مجموعه‌ای از الگوریتم‌های یادگیری ماشین برای پیش‌بینی شاخص بین‌المللی ناهمواری روسازی انتخاب شدند. این مجموعه شامل هفت مدل

یادگیری ماشین بود. هفت الگوریتم یادگیری ماشین برای مدل‌سازی هر متغیر خروجی شامل درخت تصمیم، جنگل تصادفی، ایکس‌جی‌بوست، تقویت گرادیان، K - نزدیکترین همسایه، رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی ایجاد شدند.

پیاده‌سازی مدل‌ها با استفاده از کتابخانه‌های سایکیت‌لرن و ایکس‌جی‌بوست در پایتون انجام شد. برای هر الگوریتم، هایپرپارامترها با استفاده از جستجوی شبکه‌ای و اعتبارسنجی متقابل ۵ بخشی بهینه‌سازی شدند. فرآیند بهینه‌سازی با بررسی ترکیب‌های مختلف پارامترها برای هر مدل انجام گرفت و مقادیر بهینه هایپرپارامترها بر اساس معیار ضریب تعیین انتخاب شدند.

کلیه مدل‌ها روی سخت‌افزاری با پردازنده اینتل کور i7 و حافظه ۱۶ گیگابایت آموزش داده شدند و فرآیند آموزش با استفاده از محیط گوگل کلب انجام پذیرفت.

۵-۳-۱. مبانی ریاضی الگوریتم‌های مورد استفاده

در این پژوهش، هفت الگوریتم یادگیری ماشین برای پیش‌بینی شاخص بین‌المللی ناهمواری مورد استفاده قرار گرفته است. مبانی ریاضی هر یک از این الگوریتم‌ها به شرح زیر است:

۱. رگرسیون بردار پشتیبان

این الگوریتم به دنبال یافتن تابع  $f(x)$  است که کمترین انحراف را از مقادیر هدف واقعی داشته باشد. تابع هدف رگرسیون بردار پشتیبان با در نظر گرفتن حاشیه خطای  $\epsilon$  به صورت زیر تعریف می‌شود:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (1)$$

محدودیت‌ها:

$$\begin{cases} y_i - (w \cdot \phi(x_i) + b) \leq \epsilon + \xi_i \\ (w \cdot \phi(x_i) + b) - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (2)$$

که در آن  $w$  بردار وزن،  $C$  پارامتر تنظیم،  $\xi$  متغیرهای کمکی، تابع  $\phi$  تابع هسته،  $b$  بایاس و  $\epsilon$  حاشیه خطای مجاز است (اسمولا و شولکوف، ۲۰۰۴).

۲. جنگل تصادفی:

این الگوریتم مبتنی بر ترکیب مجموعه‌ای از درخت‌های تصمیم است. پیش‌بینی نهایی برای مسائل رگرسیون به صورت میانگین‌گیری از پیش‌بینی‌های تمام درخت‌ها حاصل می‌شود:

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (3)$$

که در آن  $B$  تعداد درخت‌ها و  $T_b(x)$  پیش‌بینی درخت  $b$ ام است (بريمن، ۲۰۰۱).

۳. ایکس‌جی‌بوست:

این الگوریتم یک روش تقویت گرادیان است که به صورت افزایشی مدل‌ها را می‌آموزد. تابع هدف در هر گام به صورت زیر تعریف می‌شود:

$$\mathcal{L}^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)}) + f_t(x_i) + \Omega(f_t) \quad (4)$$

که در آن  $l$  تابع زیان،  $f_t$  تابع یادگرفته شده در گام  $t$ ام و  $\Omega$  جمله منظم‌سازی است (چن و گوسترین، ۲۰۱۶).

۴. تقویت گرادیان:

مشابه ایکس‌جی‌بوست، این الگوریتم نیز به صورت گام‌به‌گام مدل‌ها را ترکیب می‌کند:

$$F_m(x) = F_{m-1}(x) + v \cdot h_m(x) \quad (5)$$

که در آن  $F_m(x)$  مدل در گام  $m$ ام،  $v$  نرخ یادگیری و  $h_m(x)$  مدل پایه (معمولاً درخت تصمیم) در گام  $m$ ام است (فریدمن و همکاران، ۲۰۰۱).

۵. درخت تصمیم:

برای رگرسیون، درخت تصمیم فضای ویژگی را به ناحیه‌های مجزا تقسیم کرده و برای هر ناحیه یک مقدار ثابت پیش‌بینی می‌کند:

$$\hat{y} = \sum_{j=1}^J c_j \cdot I(x \in R_j) \quad (6)$$

که در آن،  $R_j$  ناحیه‌های تقسیم‌بندی شده،  $c_j$  مقدار پیش‌بینی در ناحیه  $j$ ام و  $I$  تابع نشانگر است (بريمن و همکاران، ۱۹۸۴).

۶.  $K$ -نزدیک‌ترین همسایه:

پیش‌بینی بر اساس میانگین مقادیر  $K$  همسایه نزدیکتر انجام می‌شود:

$$\hat{y} = \frac{1}{K} \sum_{i \in N_K(x)} y_i \quad (7)$$

که در آن  $N_K(x)$  مجموعه  $K$  همسایه نزدیکتر به نقطه  $x$  است (کاور و هارت، ۱۹۶۷).

۷. شبکه عصبی مصنوعی:

یک شبکه عصبی پیش‌خور با لایه‌های مخفی به صورت زیر تعریف می‌شود:

$$a^{(l)} = \sigma^{(l)}(W^{(l)} a^{(l-1)} + b^{(l)}) \quad (8)$$

که در آن  $a^{(l)}$  خروجی لایه  $l$ ام،  $W^{(l)}$  ماتریس وزن‌ها،  $b^{(l)}$  بردار بایاس و  $\sigma^{(l)}$  تابع فعال‌سازی در لایه  $l$ ام است (هایکین، ۲۰۰۹).

#### ۴-۵. ارزیابی مدل‌های یادگیری ماشین

ارزیابی عملکرد مدل‌های یادگیری ماشین توسعه‌یافته در این پژوهش با استفاده از چهار معیار استاندارد میانگین مطلق خطا، میانگین مربعات خطا، مجذور میانگین مربعات خطا و ضریب تعیین انجام شد. انتخاب این معیارها بر اساس کاربرد گسترده آنها در مطالعات مشابه حوزه مدیریت روسازی و قابلیت سنجش ابعاد مختلف خطای پیش‌بینی بوده است.

میانگین مطلق خطا دقت کلی مدل را با میانگین‌گیری از قدر مطلق اختلاف مقادیر واقعی و پیش‌بینی شده اندازه‌گیری می‌کند. میانگین مربعات خطا با تأکید بیشتر بر خطاهای بزرگتر، حساسیت مدل به داده‌های پرت را مورد سنجش قرار می‌دهد. مجذور میانگین مربعات خطا که در همان مقیاس متغیر وابسته بیان می‌شود، قابلیت تفسیر بهتری برای تحلیل عملکرد مدل فراهم می‌آورد. ضریب تعیین نیز سهم واریانس تبیین‌شده توسط مدل را نشان می‌دهد.

به منظور اطمینان از صحت ارزیابی و قابلیت تعمیم‌پذیری نتایج، از روش اعتبارسنجی متقابل ۵-۵ بخشی استفاده شد. در این روش، داده‌ها به صورت تصادفی به پنج زیرمجموعه مساوی تقسیم شده و در پنج مرحله متوالی، هر بار از چهار زیرمجموعه برای آموزش و یک زیرمجموعه برای آزمون استفاده گردید. میانگین نتایج حاصل از این پنج تکرار به عنوان معیار نهایی عملکرد هر مدل گزارش شده است. این رویکرد از سوگیری ناشی از تقسیم‌بندی خاص داده‌ها جلوگیری کرده و ارزیابی پایدار و قابل اطمینانی از عملکرد مدل‌ها ارائه می‌دهد.

#### ۵-۵. اعتبارسنجی مدل‌های یادگیری ماشین

برای ارزیابی عملکرد و اطمینان از قابلیت تعمیم‌پذیری مدل‌ها، از روش اعتبارسنجی متقاطع با پنج بخش استفاده شد. در این روش، داده‌ها به‌طور تصادفی به پنج

زیرمجموعه مساوی تقسیم شدند. فرآیند آموزش و آزمون در پنج مرحله مجزا تکرار گردید، به‌طوری که در هر تکرار، از یک بخش به‌عنوان داده‌های آزمون و ۴ بخش باقی‌مانده به‌عنوان داده‌های آموزش استفاده شد. در نهایت، میانگین معیارهای ارزیابی حاصل از این پنج مرحله به‌عنوان معیار نهایی عملکرد هر مدل گزارش شده است. این رویکرد امکان ارزیابی مستحکم‌تری از پایداری مدل را فراهم می‌کند.

مقایسه داده‌های پیش‌بینی و واقعی نشان‌دهنده دقت و کارایی مدل‌های تحلیلی است. هنگامی که نتایج پیش‌بینی شده با داده‌های واقعی مقایسه می‌شوند، اگر داده‌های پیش‌بینی به‌خوبی بر داده‌های واقعی منطبق باشند، نشان‌دهنده قابلیت اطمینان مدل است. در غیر این صورت، نیاز به بازبینی در انتخاب ویژگی‌ها، تنظیم پارامترهای مدل یا حتی تغییر الگوریتم وجود دارد. این مقایسه به‌ویژه در حوزه‌هایی مانند مهندسی روسازی، که پیش‌بینی‌های دقیق بر تصمیم‌گیری‌های هزینه‌بر تأثیر مستقیم دارند، از اهمیت بالایی برخوردار است.

#### ۶. نتایج و بحث

بخش حاضر به بررسی جامع یافته‌های پژوهش در دو قسمت اصلی می‌پردازد. ابتدا با استفاده از تحلیل همبستگی، روابط خطی بین متغیرهای مؤثر بر عملکرد مورد ارزیابی قرار گرفته است. سپس، نتایج حاصل از هفت مدل یادگیری ماشین جهت پیش‌بینی شاخص بین‌المللی ناهمواری بیان شده است. در نهایت، با تحلیل مقایسه‌ای عملکرد مدل‌ها بر اساس معیارهای ارزیابی، بهترین الگوریتم شناسایی شده و مورد اعتبارسنجی قرار گرفته است. این بخش به درک تأثیر متقابل پارامترهای روسازی و قابلیت‌های مدل‌های مختلف در پیش‌بینی دقیق کمک می‌کند.

در این پژوهش، فرآیند پیش‌پردازش داده‌ها به صورت نظام‌مند و در سه گام اساسی انجام پذیرفت. در

تحلیل توزیع فراوانی داده‌ها نشان‌دهنده الگوهای متمایز در متغیرهای مختلف است. متغیرهای میزان برف سالانه، تعداد کل محورهای استاندارد در خط طرح، شاخص یخ‌زدگی و متوسط ترافیک روزانه سالانه همگی چولگی شدیدی به سمت چپ دارند، که حاکی از تجمع بیشتر داده‌ها در مقادیر کمتر و وجود دنباله‌ای از مقادیر بیشتر در این پارامترهاست. گروه دیگری از متغیرها بین‌المللی ناهمواری، ضخامت لایه آسفالت سطح کل، عرض خط، میزان بارش سالانه، عدد سازه‌ای و تعداد کل روزهای انجماد و ذوب در سال چولگی ملایم‌تری به چپ نشان می‌دهند. در مقابل، رطوبت نسبی متوسط سالانه و میانگین دمای روزانه سالانه دارای چولگی ملایم به چپ هستند که احتمالاً نشان‌دهنده تجمع بیشتر داده‌ها در مقادیر زیاد است.

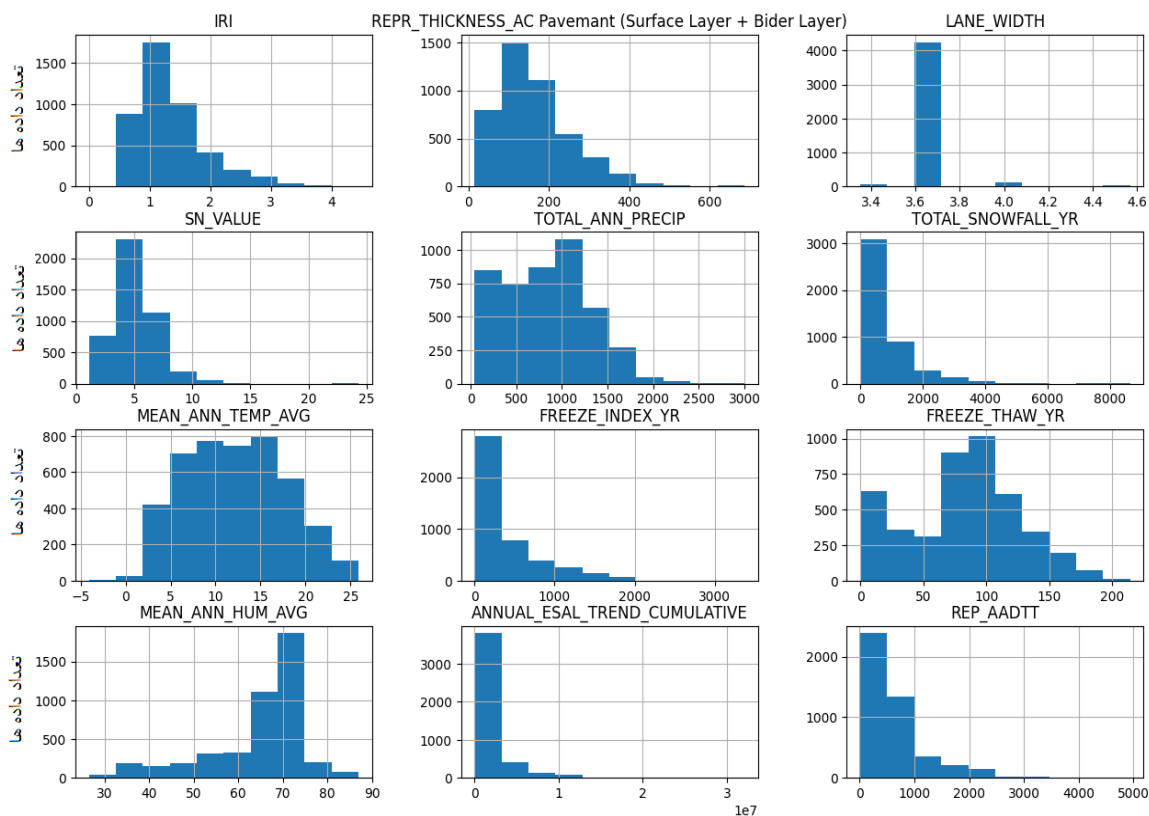
بر اساس داده‌های ارائه‌شده در جدول ۳، متغیرهای مورد بررسی در این پژوهش از پراکندگی و دامنه تغییرات قابل توجهی برخوردارند که نشان‌دهنده تنوع شرایط در داده‌های جمع‌آوری شده است. به‌طور خاص، متغیرهای تعداد کل محورهای استاندارد در خط طرح (با انحراف معیار ۲,۵۳۳,۸۳۴) و میزان برف سالانه (با انحراف معیار ۸۶۵/۲۹) دارای بیشترین انحراف معیار هستند که حاکی از ناهمگنی داده‌ها در این شاخص‌هاست. از سوی دیگر، متغیر عرض خط (با انحراف معیار ۰/۱) دارای کمترین تغییرپذیری بوده که نشان‌دهنده یکنواختی نسبی این پارامتر در نمونه‌های مطالعه شده است. مقایسه مقادیر کمینه و بیشینه در متغیرهایی مانند شاخص یخ‌زدگی (از صفر تا ۳,۳۶۹) و تعداد کل روزهای انجماد و ذوب (از صفر تا ۲۱۴) بیانگر وجود شرایط آب‌وهوایی کاملاً متفاوت در داده‌های مورد تحلیل می‌باشد. این سطح از تغییرپذیری در داده‌ها، لزوم به‌کارگیری روش‌های آماری مناسب برای شناسایی روابط معنادار بین متغیرها را توجیه می‌کند.

گام نخست، پاک‌سازی داده‌ها با بررسی دقیق مقادیر گم‌شده صورت گرفت که خوشبختانه مجموعه داده مورد استفاده از این نظر کاملاً سالم و بدون هیچ نقصانی بود. در گام دوم، به منظور بهینه‌سازی عملکرد مدل‌های یادگیری ماشین، تمامی متغیرهای عددی موجود در مجموعه داده با استفاده از روش استانداردسازی نرمال‌سازی شدند. این تبدیل آماری موجب شد توزیع داده‌ها به شکلی درآید که میانگین صفر و انحراف معیار یک داشته باشند، شرایطی که برای بسیاری از الگوریتم‌های یادگیری ماشین ایده‌آل محسوب می‌شود.

در گام پایانی، مجموعه داده به دو بخش کاملاً مجزا تقسیم شد: (۱) بخش آموزش با سهم ۸۰ درصدی و (۲) بخش آزمون با سهم ۲۰ درصدی. این تقسیم‌بندی با رعایت اصول آماری و به صورت تصادفی، اما با حفظ نسبت‌های اصلی توزیع داده‌ها انجام پذیرفت تا از ایجاد هرگونه سوگیری در فرآیند آموزش و ارزیابی مدل‌ها جلوگیری شود. کلیه این مراحل با استفاده از کتابخانه‌های معتبر علمی زبان برنامه نویسی پایتون شامل پانداس برای مدیریت داده‌ها و سایکیت-لرن برای انجام عملیات پیش‌پردازش پیاده‌سازی شدند. این رویکرد نظام‌مند نه تنها کیفیت داده‌های ورودی به مدل‌ها را تضمین کرد، بلکه پایه‌ای مستحکم برای دستیابی به نتایج قابل اعتماد و دقیق در مراحل بعدی پژوهش فراهم آورد.

مجموعه داده‌های این پژوهش شامل ۴۴۵۳ نمونه با ۱۲ ویژگی است که از مرکز داده‌ی برنامه عملکرد بلندمدت روسازی تحت نظارت اداره فدرال بزرگراه‌های آمریکا گردآوری شده‌اند. این داده‌های جامع که شامل شاخص‌های عملکردی روسازی، پارامترهای ترافیکی و شرایط محیطی می‌شوند، پایه‌ای علمی برای تحلیل‌های آماری و توسعه مدل‌های پیش‌بینی در این تحقیق فراهم کرده‌اند. برای نمایش بصری تابع توزیع هر متغیر در بین ۴۴۵۳ ردیف داده، نمودارهای شکل ۲ تهیه شده است.

پیش‌بینی وضعیت عملکردی روسازی با استفاده از یادگیری ماشین: مطالعه موردی شاخص بین‌المللی ناهمواری




شکل ۲. فراوانی متغیرهای ورودی

جدول ۳. آمارهای مجموعه داده

ردیف	نام متغیر	میانگین	انحراف معیار	کمینه	بیشینه
۱	بین‌المللی ناهمواری	۱/۳۵	۰/۵۷	۰	۴/۴۵
۲	ضخامت لایه آسفالت سطح کل	۱۶۲/۷۹	۹۳/۸۵	۱۵/۲	۶۸۵/۷
۳	عرض خط	۳/۶۷	۰/۱	۳/۳۵	۴/۵۷
۴	عدد سازه‌ای	۵/۱۱	۱/۸۹	۱/۱	۲۴/۳
۵	تعداد کل محورهای استاندارد در خط طرح	۱,۷۷۵,۶۲۴	۲,۵۳۳,۸۳۴	۰	۳۲,۰۵۲,۴۸۰
۶	متوسط ترافیک روزانه سالانه	۶۱۶	۵۴۸	۱۳	۴,۹۳۸
۷	میزان بارش سالانه	۸۳۷/۲۹	۴۵۳/۹۶	۴۲/۵	۲,۹۹۷
۸	میزان برف سالانه	۶۸۶/۷۷	۸۶۵/۲۹	۰	۸,۶۴۲
۹	میانگین دمای روزانه سالانه	۱۲/۱۴	۵/۵۲	-۴/۱	۲۵/۹
۱۰	شاخص یخ‌زدگی	۳۵۸	۴۵۲	۰	۳,۳۶۹
۱۱	تعداد کل روزهای انجماد و ذوب در سال	۸۲/۰۳	۴۴/۷	۰	۲۱۴
۱۲	رطوبت نسبی متوسط سالانه	۶۴/۷۵	۱۰/۸۶	۲۶/۵	۸۷

نیز همبستگی نسبتاً قوی مثبت (به ترتیب ۰/۷۴ و ۰/۶۸) دارند که یک الگوی وابستگی قوی بین شاخص‌های دما و یخ‌زدگی را آشکار می‌سازد. از سوی دیگر، متغیر ضخامت روسازی تقریباً با هیچیک از متغیرهای دیگر ارتباط معناداری (همبستگی نزدیک به صفر) ندارد که نشان می‌دهد این پارامتر مستقل از سایر فاکتورهای مورد مطالعه عمل می‌کند. در نهایت، همبستگی متوسط مثبت بین عدد سازه‌ای و بارش سالانه با ضریب ۰/۴۰ می‌تواند حاکی از تأثیرپذیری مشخصات سازه‌ای راه از میزان بارندگی باشد.

برای مطالعه همبستگی بین متغیرهای مختلف هر مدل، نقشه حرارتی این متغیرها تهیه شد تا هرگونه همبستگی احتمالی را نشان دهد. این موضوع در شکل ۳ قابل مشاهده است. ماتریس همبستگی نشان‌دهنده روابط معنادار بین متغیرهای مؤثر بر رفتار روسازی است. قوی‌ترین رابطه مثبت و مستقیم بین متغیرهای میانگین دمای روزانه سالانه و شاخص یخ‌زدگی با ضریب همبستگی ۰/۸۴ مشاهده می‌شود که نشان‌دهنده ارتباط بسیار نزدیک این دو پارامتر آب‌وهوایی است. همچنین، این دو متغیر با تعداد کل روزهای انجماد و ذوب در سال



شکل ۳. نقشه حرارتی ماتریس همبستگی بین متغیرها

گوگل کولب با استفاده از کتابخانه‌های سایکیت-لرن و ایکس‌جی‌بوست انجام گردید. بهینه‌سازی ابرپارامترهای هر مدل صورت پذیرفت تا بهترین ترکیب پارامترها برای هر الگوریتم تعیین شود. تمامی مراحل پیش‌پردازش، آموزش و ارزیابی مدل‌ها روی سیستمی با مشخصات پردازنده اینتل کور آی هفت و حافظه ۱۶ گیگابایت اجرا گردید. برای اطمینان از تکرارپذیری نتایج، مقدار حالت تصادفی برابر با ۴۲ در تمامی مراحل در نظر گرفته شد. این رویکرد جامع امکان مقایسه سیستماتیک قابلیت‌های پیش‌بینی مدل‌های مختلف یادگیری ماشین را در زمینه تحلیل رفتار روسازی فراهم می‌آورد.


در این قسمت، اهمیت متغیرهای ورودی روی متغیر خروجی بررسی شد. از بین ۱۲ متغیر در نظر گرفته شده، هر متغیر ورودی تأثیر متفاوتی بر نتایج هر مدل داشت. برای تحلیل سهم هر متغیر در نتایج هر مدل ترسیم شد. شکل ۴، سهم متغیرها را برای مدل نشان می‌دهد که در آن محور X نشان‌دهنده هر یک از متغیرهای استفاده شده و محور Y نشان‌دهنده سهم متغیر است. مجموع سهم متغیرها برای هر مدل برابر با یک است.

از نظر سهم متغیرها، متغیرهایی که بیشترین تأثیر را بر شاخص بین‌المللی ناهمواری در مدل داشتند، به ترتیب متوسط ترافیک روزانه سالانه، تعداد کل محورهای استاندارد در خط طرح و ضخامت لایه آسفالت سطح کل بودند.

پس از اجرای هفت مدل، نتایج مطابق جدول ۴ و شکل ۵ برای پیش‌بینی شاخص بین‌المللی ناهمواری ثبت شدند. در جدول ۴، نتایج ارزیابی مدل‌های مختلف ارائه شده است. این جدول معیارهای مختلف سنجش عملکرد مانند دقت و خطا را برای هر قسمت آزمون هر مدل به صورت مقایسه‌ای نشان می‌دهد.

اگرچه ماتریس همبستگی روابط بین متغیرها را به خوبی نشان می‌دهد، اما نکته مهم این است که وجود همبستگی بین متغیرهای پیش‌بین در مدل‌های یادگیری ماشین معمولاً مشکلی ایجاد نمی‌کند. برخلاف روش‌های سنتی مانند رگرسیون خطی که به شدت تحت تأثیر همبستگی خطی قرار می‌گیرند، الگوریتم‌های پیشرفته‌ای مانند جنگل تصادفی و گرادیان بوستینگ به طور ذاتی مقاومت بالایی در برابر همبستگی بین ویژگی‌ها دارند و می‌توانند این روابط را در فرآیند یادگیری مد نظر قرار دهند. در مورد مقادیر نسبتاً پایین همبستگی مشاهده شده بین متغیر نشست و سایر پارامترها، باید توجه داشت که ماتریس همبستگی فقط روابط خطی ساده (همبستگی درجه اول) را بررسی می‌کند. در حالی که ممکن است روابط پیچیده‌تر و غیرخطی بین این متغیرها وجود داشته باشد که توسط مدل‌های یادگیری ماشین قابل شناسایی و استفاده هستند. این الگوریتم‌ها قادرند روابط چندمتغیره و تعاملات پیچیده بین ویژگی‌ها را که در تحلیل همبستگی ساده آشکار نمی‌شوند، کشف و مدل‌سازی کنند.


در این مطالعه، هفت مدل یادگیری ماشین شامل درخت تصمیم، جنگل تصادفی، ایکس‌جی‌بوست، تقویت گرادیان، K-نزدیکترین همسایه، رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی روی داده‌های مرکز داده‌ی برنامه عملکرد بلندمدت روسازی تحت نظارت اداره فدرال بزرگراه‌های آمریکا بکارگرفته شد. تعداد ۴۴۵۳ ردیف داده با متغیرهای ورودی مشتمل بر ۱۲ پارامتر کلیدی نظیر شاخص بین‌المللی ناهمواری، مشخصات لایه‌های روسازی، بارگذاری و شرایط محیطی بودند. پس از استانداردسازی داده‌ها با استفاده از استانداردسازی، مجموعه داده به نسبت ۸۰ به ۲۰ برای آموزش و آزمون تقسیم شد. پیاده‌سازی مدل‌ها در محیط



شکل ۴. سهم متغیرها برای مدل‌های شاخص بین‌المللی ناهمواری

جدول ۴. معیارهای ارزیابی مدل‌های مختلف پیش‌بینی شاخص بین‌المللی ناهمواری

مدل	ضریب تعیین آموزش	ضریب تعیین آزمون	میانگین مطلق خطا	میانگین مربعات خطا	مجدور میانگین مربعات خطا
درخت تصمیم	۰/۹۹	۰/۴۹	۰/۲۲	۰/۱۵	۰/۳۹
جنگل تصادفی	۰/۹۵	۰/۷۴	۰/۱۸	۰/۰۸	۰/۲۹
ایکس‌جی‌بوست	۰/۹۹	۰/۷۳	۰/۱۷	۰/۰۸	۰/۲۸
تقویت گرادیان	۰/۶۲	۰/۵۲	۰/۲۷	۰/۱۴	۰/۳۷
K-نزدیکترین همسایه	۰/۸۷	۰/۵۲	۰/۲۲	۰/۱۴	۰/۳۷
رگرسیون بردار پشتیبان	۰/۰۶	۰/۰۰	۰/۳۸	۰/۳۰	۰/۵۴
شبکه عصبی مصنوعی	۰/۴۲	۰/۳۵	۰/۳۲	۰/۱۹	۰/۴۳



شکل ۵. مقایسه معیارهای خطای مدل‌های مختلف پیش‌بینی شاخص بین‌المللی ناهمواری

واریانس داده‌ها توسط مدل تبیین شده است. ضریب تعیین آموزش بیانگر میزان انطباق مدل با داده‌های آموزشی است؛ در حالی که ضریب تعیین آزمون عملکرد مدل روی داده‌های جدید را ارزیابی می‌کند.

پس از اجرای هفت مدل، اعتبارسنجی مدل‌ها مطابق شکل‌های زیر ثبت شد. شکل ۶، ضریب تعیین آموزش و آزمون مدل‌های مختلف را نشان می‌دهد. ضریب تعیین معیاری کلیدی برای سنجش کیفیت مدل رگرسیون است که نشان می‌دهد چه نسبتی از




شکل ۶. مقایسه ضریب تعیین آموزش و آزمون مدل‌های مختلف پیش‌بینی شاخص بین‌المللی ناهمواری

۰/۷۴ و ۰/۷۳ بهترین کارایی را از خود نشان داده‌اند. مدل ایکس‌جی‌بوست با مقدار ضریب تعیین آموزش به ترتیب

بر پایه شکل ۶، مدل‌های جنگل تصادفی و ایکس‌جی‌بوست با مقدار ضریب تعیین آموزش به ترتیب

در شکل ۷، با نرمال‌سازی تمام معیارهای آزمون مدل به مقیاس صفر تا یک و معکوس کردن مقادیر خطاها، یک استاندارد یکسان برای مقایسه عملکرد تمام مدل‌ها ایجاد شده است. به این ترتیب، بیشترین مقدار (۱) در همه‌ی معیارها نشان‌دهنده‌ی بهترین عملکرد است. برای ضریب تعیین که ذاتاً بین صفر تا ۱ است، ۱ به معنای بالاترین ضریب تعیین است و برای معیارهای خطا که مقادیر مثبت دارند، با تبدیل معکوس، ۱ نشان‌دهنده‌ی کمترین خطا (بهترین حالت) و صفر نشان‌دهنده‌ی بیشترین خطا (بدترین حالت) می‌شود. این رویکرد بصری، مقایسه‌ی جامع مدل‌ها را آسان می‌کند، زیرا تمام معیارها در یک مقیاس مشابه و مطلوبیت‌محور (۱=بهینه) نمایش داده می‌شوند.

ضریب تعیین آموزش آن ۰/۹۹ است، همخوانی بسیار خوبی با داده‌های آموزشی دارند. با این‌حال، جنگل تصادفی با اختلاف کمتر بین ضریب تعیین آموزش (۰/۹۵) و ضریب تعیین آزمون (۰/۷۴) در مقایسه با ایکس‌جی‌بوست (با ضریب تعیین آموزش برابر با ۰/۹۹ و ضریب تعیین آزمون ۰/۷۳) قابلیت تعمیم‌پذیری بهتری دارد. درخت تصمیم با وجود ضریب تعیین آموزش کامل (۰/۹۹)، به دلیل اختلاف زیاد با ضریب تعیین آزمون ۰/۴۹ نشان‌دهنده بیش‌برازش واضح است. مدل ماشین بردار ضعیف‌ترین نتایج را ارائه داد. این تحلیل نشان می‌دهد که جنگل تصادفی و ایکس‌جی‌بوست به عنوان پایدارترین و قابل اعتمادترین مدل‌ها برای این مسئله شناخته می‌شوند.




شکل ۷. نمودار مقدار معیارهای ارزیابی مدل‌های مختلف پیش‌بینی شاخص بین‌المللی ناهمواری

مطلق خطا برابر با ۰/۱۸ و ۰/۱۷ و ضریب تعیین برابر با ۰/۷۴ و ۰/۷۳ برای داده‌های آزمون بهترین عملکرد را داشتند. همچنین، K\_ نزدیک‌ترین همسایه، درخت تصمیم، گرادیان تقویتی، شبکه عصبی مصنوعی و

توجه به نتایج جدول ۴ و شکل‌های ۶ و ۷ در مدل پیش‌بینی شاخص بین‌المللی ناهمواری، الگوریتم جنگل تصادفی و ایکس‌جی‌بوست به ترتیب با ضریب تعیین برابر با ۰/۹۵ و ۰/۹۹ برای داده‌های آموزشی و میانگین

مقادیر پیش‌بینی شده توسط مدل روی محور عمودی برای همه مدل‌ها رسم شده و بهترین خط ممکن بر هر یک از آنها برازش شده است. اگر مدل عملکرد ایده‌آلی داشته باشد، خط برازش شده دقیقاً مطابق خط  $y = x$  (نیمساز ربع اول) بوده، زیرا در این حالت پیش‌بینی‌ها با مقادیر واقعی کاملاً برابر هستند.

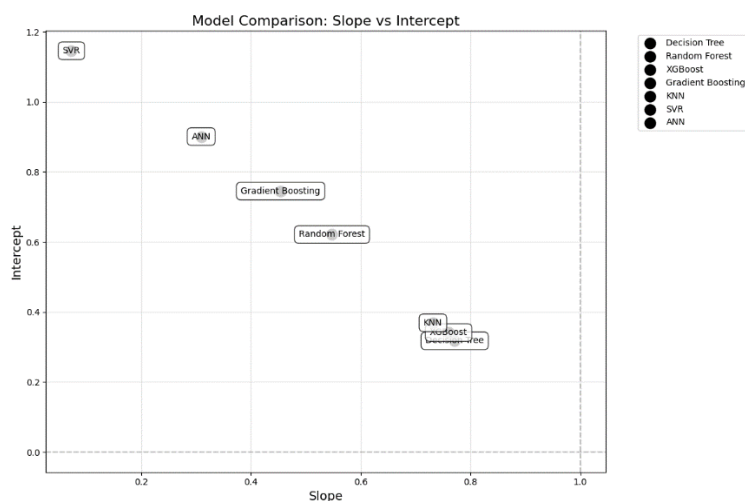
رگرسیون بردار پشتیبان در رتبه‌های بعدی قرار گرفتند. شکل ۸، مقادیر پیش‌بینی شده در مقابل مقادیر واقعی برای مدل‌ها را نشان می‌دهد که یک ابزار ساده اما قدرتمند برای ارزیابی عملکرد مدل‌های رگرسیون در یادگیری ماشین است. در نمودار شکل ۸، مقادیر واقعی روی محور افقی و



شکل ۸. اعتبارسنجی مدل‌های مختلف پیش‌بینی شاخص بین‌المللی ناهمواری

عرض از مبدأ و شیب خط‌های برازش شده بر داده‌های هر یک از مدل‌ها هر چه به ترتیب به صفر و ۱ نزدیکتر باشد در واقع به خط  $y = x$  نزدیکتر بوده و مدل مربوطه معتبرتر است.

شکل ۹، نمودار عرض از مبدأ - شیب مربوط به خط‌های برازش شده بر داده‌های هر یک از مدل‌ها را نشان می‌دهد که ابزاری مفید برای تحلیل حساسیت و پایداری مدل‌های رگرسیون است. در این نمودار، مقادیر



شکل ۹. تحلیل شیب و عرض از مبدأ در اعتبارسنجی مدل‌های مختلف پیش‌بینی شاخص بین‌المللی ناهمواری

معیار میانگین خطای مطلق، مدل‌های حاضر عملکرد مطلوب‌تری نسبت به کارهای گذشته از خود نشان داده‌اند. با این حال، باید توجه داشت که به دلیل تفاوت‌های اساسی در مجموعه داده‌های مورد استفاده (از جمله شرایط محیطی، مشخصات روسازی و بازه زمانی مطالعه) و همچنین تفاوت در متغیرهای ورودی و روش‌های جمع‌آوری داده‌ها، انجام مقایسه مستقیم یا اعتبارسنجی مطلق با نتایج مطالعات قبلی نمی‌تواند ارزیابی دقیق و منصفانه‌ای ارائه دهد. این تفاوت‌های ساختاری موجب می‌شوند که هر پژوهش در این حوزه تا حد زیادی منحصر به فرد بوده و قابلیت مقایسه پذیری مطلق را نداشته باشد.

شکل‌های ۸ و ۹ نشان می‌دهند که مدل‌های درخت تصمیم، ایکس‌جی‌بوست، K\_نزدیک‌ترین همسایه و جنگل تصادفی در پیش‌بینی مقادیر داده‌های آزمون عملکرد مطلوبی دارند، به طوری که ایکس‌جی‌بوست و درخت تصمیم با شیب حدود ۰/۸ و عرض از مبدأ ۰/۳۵ معتبرترین مدل شناخته می‌شوند. هرچند با افزایش مقادیر  $\gamma$  انحراف اندکی مشاهده می‌شود.

براساس جدول ۵، اعتبارسنجی مدل در مقایسه با مطالعات پیشین در این حوزه، مدل‌های ارائه شده در این پژوهش از نظر ضریب تعیین در محدوده قابل قبولی قرار دارند و با برخی از تحقیقات قبلی برابری می‌کنند، اگرچه در مقایسه با برخی مطالعات دیگر مانند قدرت‌آبادی و همکاران (۲۰۲۵) مقدار کمتری را نشان می‌دهند. از منظر

جدول ۵. مقایسه عملکرد مدل‌های پیشنهادی با مطالعات پیشین

نویسندگان	شاخص روسازی	متغیرها	مدل	ضریب تعیین	میانگین مطلق خطا
قدرت‌آبادی و همکاران (۲۰۲۵)	بین‌المللی ناهمواری	میزان تعمیرات، سن روسازی، ترافیک بارندگی، دما، رطوبت، شاخص یخبندان، ضخامت لایه‌های آسفالت، اساس و زیراساس.	جنگل تصادفی	۰/۸- ۰/۹۶	-
			ماشین بردار پشتیبان	۰/۶- ۰/۹۲	-
کالوپ و همکاران (۲۰۲۳)	بین‌المللی ناهمواری	سن روسازی، شاخص بین‌المللی ناهمواری اولیه، ترک‌های پوست‌سوسماری، طولی، عرضی، انحراف معیار شیارشدگی، شاخص پلاستیسیته زیراساس	رگرسیون فرایند گاوسی	۰/۹۳	
			چندجمله‌ای وزن‌دار محلی مدل پی‌اس‌او - انفیس	۰/۹	
			مدل پی‌اس‌او - شبکه عصبی مصنوعی	۰/۵۲	
دمیرچیلو و همکاران (۲۰۲۱)	بین‌المللی ناهمواری	۱۰ متغیر ورودی	ایکس‌جی‌بوست	۰/۷	۰/۲
			جنگل تصادفی	۰/۶۶	۰/۲۲
			رگرسیون بردار پشتیبان	۰/۴۴	۰/۲۸
رونهوا و همکاران (۲۰۲۱)	بین‌المللی ناهمواری	-	گرادیان تقویتی	۰/۸۳	
			شبکه عصبی مصنوعی	۰/۸	

قرار گرفت. همچنین تحلیل عملکرد و سازگاری این الگوریتم‌های یادگیری ماشین ارائه شد.

در مرحله دوم، داده‌های این پژوهش از مرکز داده‌ی برنامه عملکرد بلندمدت روسازی تحت نظارت اداره فدرال بزرگراه‌های آمریکا استخراج شده‌اند.

مجموعه داده شامل ۴۴۵۳ ردیف داده مربوط به سازه و ساخت روسازی، آب‌وهوا، ترافیک و عملکرد روسازی (در مجموع ۱۲ متغیر) بودند. این بررسی به منظور بومی‌سازی مدل‌های پیش‌بینی تولید شده برای شرایط کشور انجام شد.

نوآوری اصلی این پژوهش، ارائه یک مطالعه سیستماتیک و تطبیقی برای ارزیابی عملکرد هفت الگوریتم یادگیری ماشین در پیش‌بینی شاخص بین‌المللی ناهمواری بر پایه یک مجموعه داده یکسان و گسترده بود. این بررسی جامع نشان داد که اگرچه مدل‌های مختلفی قابلیت پیش‌بینی این شاخص را دارند، اما انتخاب مدل بهینه نیازمند سنجش توأمان معیارهای مختلف است.

در فرآیند تحلیل، اولین گام بررسی وجود هم‌خطی بین متغیرهای موجود، فراوانی و آمارهای مجموعه داده در مدل‌ها بود. به صورت کلی در این تحقیق نتایج زیر حاصل شد:

۱. در مدل شاخص بین‌المللی ناهمواری، الگوریتم‌های جنگل تصادفی و ایکس‌جی‌بوست به ترتیب با ضریب تعیین ۰/۹۵ و ۰/۹۹ برای داده‌های آموزشی، میانگین مطلق خطای ۰/۱۸ و ۰/۱۷ و ضریب تعیین ۰/۷۴ و ۰/۷۳ برای داده‌های آزمون بهترین عملکرد را داشتند.

۲. نشان داده شد که مدل جنگل تصادفی و ایکس‌جی‌بوست عملکرد بهتری نسبت به سایر مدل‌ها داشتند. به طور خاص، مدل‌هایی که از جنگل تصادفی و ایکس‌جی‌بوست استفاده می‌کردند، کمترین میانگین مطلق خطا و بالاترین ضریب تعیین را در مدل‌سازی شاخص بین‌المللی ناهمواری نشان دادند.

انتخاب شاخص بین‌المللی ناهمواری (IRI) به عنوان متغیر خروجی در این پژوهش مبتنی بر ملاحظات متعددی بوده است. نخست آنکه IRI به عنوان یک شاخص استاندارد جهانی در حوزه مدیریت روسازی شناخته می‌شود که امکان مقایسه‌پذیری نتایج با مطالعات بین‌المللی را فراهم می‌نماید. دوم آنکه این شاخص با معیارهای مهمی همچون ایمنی، راحتی مسافران و مصرف سوخت وسایل نقلیه ارتباط مستقیم دارد و به عنوان یکی از شاخص‌های کلیدی در سیستم‌های مدیریت روسازی مورد استفاده قرار می‌گیرد. سوم، دسترسی به داده‌های تاریخی غنی و پیوسته این شاخص در پایگاه داده LTPP، امکان توسعه مدل‌های پیش‌بینی پایدار را مهیا ساخته است. با این وجود، نویسندگان به این محدودیت آگاه هستند که IRI تنها یکی از ابعاد عملکرد روسازی را پوشش می‌دهد و برای ارزیابی جامع، استفاده توأمان با سایر شاخص‌های عملکردی توصیه می‌شود.

## ۷. نتیجه‌گیری

در این مطالعه سعی شد پژوهشی جامع در زمینه بکارگیری مدل‌های پیش‌بینی دقیق و قابل اعتماد برای ارزیابی وضعیت روسازی ارائه شود. به طور خاص، این بررسی بر مطالعه الگوریتم‌ها و روش‌هایی متمرکز است که پتانسیل تولید مدل‌های پیش‌بینی با دقت بالا را نشان داده‌اند. تمرکز اصلی بر الگوریتم‌های یادگیری ماشینی است که برای پیش‌بینی شاخص بین‌المللی ناهمواری روسازی بکار گرفته شده‌اند.

برای مطالعه عمیق اطلاعات مرتبط با موضوع، ابتدا کاربردهای الگوریتم‌های یادگیری ماشین در زمینه پیش وضعیت روسازی بررسی شد. سپس تحول الگوریتم‌های مورد استفاده در حوزه زیرساخت‌ها به الگوریتم‌های خاص یادگیری ماشین که به طور ویژه برای پیش و پیش‌بینی شرایط روسازی استفاده می‌شوند، مورد بررسی

تعمیم‌پذیری است. نتایج نشان داد که مدل‌های پیشنهادی می‌تواند به عنوان پایه‌ای علمی برای توسعه سیستم‌های برنامه‌ریزی عملیات تعمیر و نگهداری مبتنی بر شاخص‌های عملکردی مورد استفاده قرار گیرند. با توجه به اهمیت سیستم‌های مدیریت روسازی در تأمین ایمنی کاربران و حفظ کیفیت سواری، مدل‌های ارائه‌شده از کاربردپذیری بالایی برخوردار هستند. در این راستا، از دستاوردهای این پژوهش می‌توان به موارد زیر اشاره کرد:

- ارائه چارچوبی نظام‌مند برای مدل‌سازی پارامترهای خرابی روسازی که می‌تواند در تدوین استراتژی‌های مدیریت و نگهداری مؤثر مورد استفاده قرار گیرد.
- تشکیل و آماده‌سازی مجموعه‌داده‌ای معتبر از پارامترهای روسازی که می‌تواند مبنای تحقیقات آینده قرار گیرد.
- معرفی و ارزیابی سیستماتیک الگوریتم‌های یادگیری ماشین با رویکردی نوآورانه در انتخاب مدل بهینه بر اساس معیارهای چندبعدی
- معرفی و ارزیابی الگوریتم‌های جنگل تصادفی و ایکس‌جی‌بوست به عنوان ابزارهای کارآمد در مدیریت روسازی
- بکارگیری مدل‌های پیش‌بینی شاخص‌های عملکردی متناسب با شرایط آزادراه‌های کشور یافته‌های این تحقیق دارای کاربردهای عملی مستقیمی در صنعت حمل‌ونقل و مدیریت زیرساخت است. مدل توسعه‌یافته می‌تواند توسط سازمان‌های راهداری و نهادهای مسئول نگهداری راه، به‌عنوان یک ابزار تصمیم‌یار قدرتمند به کار گرفته شود. از جمله این کاربردها می‌توان به موارد زیر اشاره نمود:
- بهینه‌سازی برنامه‌ریزی و بودجه‌بندی نگهداری با شناسایی به‌موقع قطعات بحرانی آزادراه‌ها بر اساس پیش‌بینی دقیق شاخص IRI امکان تخصیص هدفمند

۳. در مدل‌سازی شاخص بین‌المللی ناهمواری، مدل‌های K\_ نزدیک‌ترین همسایه، درخت تصمیم، گرادیان تقویتی، شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان در رتبه‌های بعدی قرار گرفتند.

۴. در بخش اعتبارسنجی مدل، با در نظر گرفتن معیارهای چندبعدی عملکرد شامل دقت (ضریب تعیین)، خطا (میانگین خطای مطلق) و قابلیت تعمیم‌پذیری، مدل ایکس‌جی‌بوست به عنوان مدل بهینه انتخاب شد. اگرچه مدل جنگل تصادفی دارای ضریب تعیین آزمون اندکی بالاتر (۰/۷۴ در مقابل ۰/۷۳) بود، اما مدل ایکس‌جی‌بوست با دارا بودن کمترین میزان خطا (میانگین خطای مطلق ۰/۱۷ در مقابل ۰/۱۸) و همچنین برخورداری از اختلاف کمتر بین مقادیر ضریب تعیین داده‌های آموزش و آزمون (۰/۲۶ واحد در مقابل ۰/۲۱ واحد)، از تعادل بهتری بین دقت و قابلیت اطمینان برخوردار بود. این ارجحیت به‌ویژه در تحلیل‌های بصری مبتنی بر نمودارهای اعتبارسنجی (شکل‌های ۸ و ۹) نیز تأیید می‌شود. در شکل ۸، نمودار پراکندگی و خط برازش مدل ایکس‌جی‌بوست، انطباق بیشتری با خط ایده‌آل  $y=x$  از خود نشان می‌دهد. همچنین در شکل ۹، مقادیر شیب (نزدیک به ۰/۸) و عرض از مبدأ (حدود ۰/۳۵) مربوط به این مدل، در مقایسه با سایر مدل‌ها، به ترتیب به مقادیر ایده‌آل ۱ و صفر نزدیک‌تر بوده که این موضوع صحت و پایداری بالاتر آن را در پیش‌بینی شاخص IRI نوید می‌دهد. این مجموعه شواهد کمی و کیفی، حاکی از پتانسیل کمتر مدل ایکس‌جی‌بوست برای بیش‌برازش و در نتیجه، قابلیت تعمیم‌پذیری بهتر آن در مواجهه با داده‌های جدید است.

در این پژوهش، چارچوبی برای مدل‌سازی شاخص بین‌المللی ناهمواری در روسازی راه‌ها ارائه شد. مهم‌ترین دستاورد نوآورانه این پژوهش، توسعه یک چارچوب سیستماتیک برای انتخاب بهینه‌ترین مدل پیش‌بینی با در نظرگیری همزمان معیارهای دقت، پایداری و قابلیت

همگی در پروژه‌های راه‌سازی ایران قابل اندازه‌گیری یا برآورد می‌باشند. سازمان راهداری و حمل‌ونقل جاده‌ای ایران داده‌های ترافیکی و اقلیمی را در بسیاری از محورهای مواصلاتی اصلی جمع‌آوری می‌کند. همچنین مشخصات سازه‌ای روسازی (ضخامت لایه‌ها، عدد سازه‌ای) در اسناد فنی پروژه‌ها موجود است.

۳. تحلیل اهمیت متغیرها برای ایران: نتایج تحلیل اهمیت متغیرها در شکل ۴ نشان داد که متوسط ترافیک روزانه سالانه، تعداد کل محورهای استاندارد و ضخامت لایه آسفالت بیشترین تأثیر را بر شاخص IRI دارند. این یافته با شرایط راه‌های ایران که غالباً با مشکل ترافیک سنگین کامیونی و ضخامت‌های طراحی متغیر مواجه هستند، همخوانی دارد. بنابراین، اولویت‌بندی این متغیرها در جمع‌آوری داده‌های بومی می‌تواند به بهینه‌سازی فرآیند مدل‌سازی کمک کند (عسکری و همکاران، ۲۰۲۲).

۴. چالش‌ها و محدودیت‌ها: با وجود پتانسیل‌های مذکور، بومی‌سازی مدل‌ها با چالش‌هایی نیز مواجه است. نخست آنکه پایگاه داده LTPP عمدتاً شامل روسازی‌های با کیفیت ساخت بالاتر و نظارت دقیق‌تر است؛ در حالی که کیفیت اجرا در پروژه‌های ایران ممکن است نوسان بیشتری داشته باشد. دوم آنکه داده‌های ترافیکی در ایران با دقت کمتری ثبت می‌شوند و ممکن است نیاز به برآوردهای غیرمستقیم داشته باشند. همچنین داده‌های اقلیمی با قدرت تفکیک مکانی مناسب در همه نقاط کشور در دسترس نیست (وفائی و ستاری، ۲۰۲۳).

۵. پیشنهادها: عملی برای پیاده‌سازی: بر اساس یافته‌های این پژوهش، مراحل زیر برای توسعه مدل پیش‌بینی IRI در ایران پیشنهاد می‌گردد:

فاز اول (آماده‌سازی): انتخاب حداقل ۵ فقره راه با تنوع اقلیمی و ترافیکی مناسب (مناطق گرم و خشک مرکزی، سرد کوهستانی، معتدل خزری) و جمع‌آوری داده‌های پایه شامل مشخصات لایه‌ها، آمار ترافیک و

منابع مالی را فراهم کرده و منجر به افزایش عمر مفید روسازی می‌شود

• ارتقای ایمنی و پشتیبانی از تصمیم‌گیری‌های کلان با کمک به کاهش ناهمواری‌های خطرناک موجب افزایش ایمنی کاربران شده و با تحلیل تأثیر عوامل کلیدی مانند ترافیک و شرایط آب‌وهوایی از تصمیم‌گیری‌های استراتژیک در مدیریت شبکه راه پشتیبانی می‌نماید

• ادغام در سیستم‌های هوشمند پایش از طریق قابلیت یکپارچه‌سازی با سامانه‌های پایش بلادرنگ امکان ارزیابی لحظه‌ای وضعیت روسازی و ارائه هشدارهای به موقع را فراهم می‌آورد.

۷-۱. قابلیت تعمیم‌پذیری مدل‌ها به راه‌های ایران یکی از پرسش‌های اساسی در پژوهش‌های مبتنی بر داده‌های بین‌المللی، امکان تعمیم‌پذیری نتایج به شرایط بومی هر کشور است. در این راستا، مدل‌های توسعه‌یافته در این پژوهش قابلیت بومی‌سازی برای پیش‌بینی شاخص IRI در راه‌های ایران را دارند. این مهم از چند جنبه قابل بررسی است:

۱. شباهت اقلیمی: ایران دارای تنوع اقلیمی گسترده‌ای شامل مناطق گرم و خشک (مشابه آریزونا و نوادا)، مناطق سرد و کوهستانی (مشابه کلرادو و وایومینگ) و مناطق معتدل و مرطوب (مشابه کارولینای شمالی) می‌باشد. از آنجا که داده‌های آموزش مدل‌ها شامل طیف وسیعی از شرایط اقلیمی بوده است، مدل‌های توسعه‌یافته پتانسیل بالایی برای عملکرد در اقلیم‌های مختلف ایران دارند. مطالعات پیشین در ایران نظیر عسکری و همکاران (۲۰۲۲) نشان داده‌اند که مدل‌های آموزش دیده با داده‌های LTPP می‌توانند با انجام واسنجی محلی، در پیش‌بینی خرابی‌های روسازی در ایران عملکرد قابل قبولی ارائه دهند.

۲. تطبیق متغیرهای ورودی: همان‌طور که در جدول ۲ نشان داده شد، متغیرهای مورد استفاده در این پژوهش شامل پارامترهای سازه‌ای، ترافیکی و اقلیمی هستند که

داده‌های اقلیمی.

همراهی کلیه همکاران پژوهشی که بازخوردهای سازنده‌ای در راستای بهبود کیفیت این مطالعه ارائه نموده‌اند، تشکر می‌گردد.

## ۹. تأییدیه اخلاقی

نویسندگان تأیید می‌کنند که این مقاله حاصل پژوهش اصیل آن‌ها بوده و قبلاً در هیچ مجله یا کنفرانس دیگری منتشر نشده و همچنین برای بررسی همزمان به مجله دیگری ارسال نشده است.

## ۱۰. مشارکت‌های نویسندگان

مسعود یکه‌خانی: ایده‌پردازی و مفهوم‌سازی، پیاده‌سازی نرم‌افزار و کدنویسی، اعتبارسنجی، تحلیل داده‌ها، جمع‌آوری و آماده‌سازی داده‌ها، نگارش پیش‌نویس اصلی مقاله

دکتر امیر گل‌رو: طراحی روش‌شناسی و الگوریتم‌ها، اعتبارسنجی، بازبینی و ویراستاری مقاله، نظارت و راهنمایی کلی پژوهش  
دکتر فریدون مقدس‌نژاد: مدیریت پروژه و هماهنگی، نظارت و راهنمایی کلی پژوهش

## ۱۱. منابع مالی

این پژوهش هیچ بودجه مشخصی از سازمان‌های تأمین‌کننده داخلی یا خارجی دریافت نکرده است.

## ۱۲. تعارض منافع

نویسندگان تأیید می‌کنند که هیچ گونه تعارض منافع مرتبط با انتشار این مقاله ندارند.

فاز دوم (اندازه‌گیری IRI): اندازه‌گیری شاخص IRI

در مقاطع زمانی مختلف (حداقل سه دوره زمانی) با استفاده از دستگاه‌های پروفایل‌متر یا روش‌های کم‌هزینه‌تر نظیر استفاده از تصاویر ماهواره‌ای و داده‌های پهپاد.

فاز سوم (واسنجی): استفاده از مدل پیشنهادی ایکس‌جی‌بوست به عنوان مدل پایه و واسنجی آن با استفاده از ۷۰٪ داده‌های جمع‌آوری‌شده.

فاز چهارم (اعتبارسنجی): ارزیابی عملکرد مدل واسنجی‌شده روی ۳۰٪ باقی‌مانده داده‌ها و مقایسه نتایج با پژوهش‌های مشابه داخلی نظیر قدرت‌آبادی و همکاران (۲۰۲۵) و عسکری و همکاران (۲۰۲۲).

در مجموع، با توجه به عملکرد برتر مدل ایکس‌جی‌بوست در این پژوهش و قابلیت تعمیم‌پذیری بالای آن، می‌توان انتظار داشت که این مدل با واسنجی مناسب، به عنوان ابزاری کارآمد در سیستم مدیریت روسازی کشور مورد استفاده قرار گیرد. این رویکرد با چشم‌انداز حکمروایی هوشمند در زیرساخت‌های حمل‌ونقل ایران نیز همسو بوده و می‌تواند گامی در جهت تصمیم‌سازی مبتنی بر داده باشد.

## ۸. تقدیر و قدردانی

نویسندگان مراتب سپاس و قدردانی خود را از تمامی پژوهشگران و متخصصانی که در پیشبرد این پژوهش یاری‌رسان بوده‌اند، ابراز می‌دارند. همچنین از همکاری و

## ۱۳. مراجع

- Abdelaziz, N., El-Hakim, R. T., El-Badawy, S. M., & Afify, H. A. 2020. "International roughness index prediction model for flexible pavements". *Int. J. Pavement Eng.*, 21(1): 88-99. <https://doi.org/10.1080/10298436.2018.1441414>
- American Association of State Highway and Transportation Officials. 1993. "Guide for design of pavement structures".
- Askari, A., Hajikarimi, P., Ehsani, M., & Moghadas Nejad, F. 2022. "Prediction of rutting deterioration in flexible pavements using artificial neural network and genetic algorithm". *Amirkabir J. Civ. Eng.*, 54(9): 3581-3602. <https://doi.org/10.22060/ceej.2022.20965.7581>

- Banister, D., & Berechman, Y. 2001. "Transport investment and the promotion of economic growth". *J. Transport Geog.*, 9(3): 209–218. [https://doi.org/10.1016/S09666923\(01\)00013-8](https://doi.org/10.1016/S09666923(01)00013-8)
- Bashar, M. Z., & Torres-Machi, C. 2021. "Performance of machine learning algorithms in predicting the pavement international roughness index". *Transport. Res. Record*, 2675(9): 1151–1163. <https://doi.org/10.1177/0361198120986171>
- Benmhahe, B., & Chentoufi, J. A. 2021. "Automated pavement distress detection, classification and measurement: A review". *Int. J. Adv. Comput. Sci. Appl.*, 12(8): 708–718. <https://doi.org/10.14569/IJACSA.2021.0120882>
- Breiman, L. 2001. "Random forests". *Machine Learn.*, 45(1): 5–32. <https://doi.org/10.1023/A:1010933404324>
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. 1984. "Classification and Regression Trees". Wadsworth and Brooks. <https://doi.org/10.1201/9781315139470>
- Chan, C. Y., Huang, B., Yan, X., & Richards, S. H. 2010. "Investigating effects of asphalt pavement conditions on traffic accidents in Tennessee based on the pavement management system (PMS)". *J. Adv. Transport.*, 44(3): 150–161. <https://doi.org/10.1002/atr.129>
- Chen, T., & Guestrin, C. 2016. "XGBoost: A scalable tree boosting system". In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). ACM. <https://doi.org/10.1145/2939672.2939785>
- Cover, T., & Hart, P. 1967. "Nearest neighbor pattern classification". *IEEE Trans. Inform. Theory*, 13(1): 21–27. <https://doi.org/10.1109/TIT.1967.1053964>
- Damirchilo, F., Hosseini, A., Mellat Parast, M., & Fini, E. H. 2021. "Machine learning approach to predict international roughness index using long-term pavement performance data". *J. Transport. Eng., Part B: Pavements*, 147(4): 04021059. <https://doi.org/10.1061/JPEODX.0000312>
- Friedman, J. H. 2001. "Greedy function approximation: A gradient boosting machine". *Ann. Statistics*, 29(5): 1189–1232. <https://doi.org/10.1214/aos/1013203451>
- Georgiou, P., Plati, C., & Loizos, A. 2018. "Soft computing models to predict pavement roughness: A comparative study". *Adv. Civ. Eng.*, 2018: 5939806. <https://doi.org/10.1155/2018/5939806>
- Ghodratabadi, M., Golroo, A., & Entezari, M. S. 2025. "Machine learning for predicting pavement roughness and optimising maintenance". *Road Mater. Pavement Design*. <https://doi.org/10.1080/14680629.2025.2454376>
- Gong, H., Sun, Y., Shu, X., & Huang, B. 2018. "Use of random forests regression for predicting IRI of asphalt pavements". *Constr. Build. Mater.*, 189: 890–897. <https://doi.org/10.1016/j.conbuildmat.2018.09.017>
- Guo, R., Fu, D., & Sollazzo, G. 2021. "An ensemble learning model for asphalt pavement performance prediction based on gradient boosting decision tree". *Int. J. Pavement Eng.*, 23(11): 3907–3920. <https://doi.org/10.1080/10298436.2021.1910825>
- Haykin, S. 2009. "Neural networks and learning machines". 3rd ed., Pearson Education.
- Hossain, M. I., Gopiseti, L. S. P., & Miah, M. S. 2019. "International roughness index prediction of flexible pavements using neural networks". *J. Transport. Eng., Part B: Pavements*, 145(1): 04018058. <https://doi.org/10.1061/JPEODX.0000088>
- Justo-Silva, R., Ferreira, A., & Flintsch, G. 2021. "Review on machine learning techniques for developing pavement performance prediction models". *Sustain.*, 13(9): 5248. <https://doi.org/10.3390/su13095248>
- Kaloo, M. R., El-Badawy, S. M., Hu, J. W., & Abd El-Hakim, R. T. 2023. "International roughness index prediction for flexible pavements using novel machine learning techniques". *Eng. Appl. Artif. Intell.*, 122: 106007. <https://doi.org/10.1016/j.engappai.2023.106007>
- Ke, X., Chen, H., Hong, Y., & Hsiao, C. 2020. "Do China's high-speed-rail projects promote local economy?—New evidence from a panel data approach". *China Econ. Rev.*, 44: 203–226. <https://doi.org/10.1016/j.chieco.2017.02.008>
- Li, J., Zhang, Z., & Wang, W. 2018. "International Roughness Index and a new solution for its calculation". In *International Conference on Transportation and Development* (pp. 67–76). American Society of Civil Engineers.
- Litman, T. 2017. "Evaluating public transit benefits and costs". Victoria Transport Policy Institute.
- Mataei, B., Moghadas Nejad, F., & Zakeri, H. 2021. "Pavement maintenance and rehabilitation optimization based on cloud decision tree". *Int. J. Pavement Res. Technol.*, 14(6): 740–750. <https://doi.org/10.1007/s42947-020-0306-7>
- Mazari, M., & Rodriguez, D. D. 2016. "Prediction of pavement roughness using a hybrid gene expression programming-neural network technique". *J. Traffic Transport. Eng. (English Edition)*: 3(5): 448–455. <https://doi.org/10.1016/j.jtte.2016.09.001>

- Peraka, N. S. P., & Biligiri, K. P. 2020. "Pavement asset management systems and technologies: A review". *Automat. Constr.*, 119: 103336. [http s://doi.org/10.1016/j.autcon.2020.103336](http://doi.org/10.1016/j.autcon.2020.103336)
- Pucher, J., & Dijkstra, L. 2003. "Promoting safe walking and cycling to improve public health: Lessons from the Netherlands and Germany". *Amer. J. Public Health*, 93(9): 1509–1516. <https://doi.org/10.2105/AJPH.93.9.1509>
- Ragnoli, A., De Blasiis, M. R., & Di Benedetto, A. 2018. "Pavement distress detection methods: A review". *Infrastruct.*, 3(4): 58. <https://doi.org/10.3390/infrastructures3040058>
- Sepaspour, R., Ehsani, M., Naseri, H., & Moghadas Nejad, F. 2021. "Presenting a new estimation technique to model International Roughness Index and treatment improvement". *Transport. Infrastruct. Eng.*, 7(28): 53–73. <https://doi.org/10.22075/jtie.2021.21865.1492>  
[In Persian]
- Sholevar, N., Golroo, A., & Esfahani, S. R. 2022. "Machine learning techniques for pavement condition evaluation". *Automat. Constr.*, 136: 104190. <https://doi.org/10.1016/j.autcon.2022.104190>
- Smola, A. J., & Schölkopf, B. 2004. "A tutorial on support vector regression". *Statistics Computing*, 14(3): 199–222. <https://doi.org/10.1023/B:STCO.0000035301.49549.88>
- Streimikiene, D., Baležentis, T., & Baležentienė, L. 2013. "Comparative assessment of road transport technologies". *Renewable Sustainable Energy Reviews*, 20: 611–618. <https://doi.org/10.1016/j.rser.2012.12.021>
- Vafaei, A., & Sattari, M. T. 2023. "Evaluation and prediction of seasonal precipitation in different climates of Iran using a hybrid deep learning model (Case study: Rasht and Yazd)". *Amirkabir J. Civ. Eng.*, 55(8): 1475–1492. <https://doi.org/10.22108/gep.2025.145951.1735>
- Vinuesa, R., Azizpour, H., Leite, I., Balaam, M., Dignum, V., Domisch, S., Felländer, A., Langhans, S. D., Tegmark, M., & Nerini, F. F. 2020. "The role of artificial intelligence in achieving the Sustainable Development Goals". *Nature Commun.*, 11(1): 233. <https://doi.org/10.1038/s41467-019-14108-w>
- Ziari, H., Sobhani, J., Ayoubinejad, J., & Hartmann, T. 2016. "Prediction of IRI in short and long terms for flexible pavements: ANN and GMDH methods". *Inter. J. Pavement Eng.*, 17(9): 776–788. <https://doi.org/10.1080/10298436.2015.1019498>