

# مروری بر کاربرد یادگیری ماشین در مهندسی روسازی های آسفالتی

محمد مهدی دادایی<sup>۱</sup>، محمد صالح انتظاری<sup>۱</sup>، رشید تن زاده<sup>۱\*</sup>، فریدون مقدس نژاد<sup>۱</sup>

<sup>۱</sup> دانشکده مهندسی عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران

\* نویسنده مسئول: RashidTanzadeh@yahoo.com

## چکیده:

نواقص روش های طراحی و اجرای روسازی راه ها در کنار برنامه های غیربهرینه ترمیم و نگهداری آن ها، هزینه های جبران ناپذیر اقتصادی و اجتماعی را به همراه داشته است. در این راستا استفاده از دانش و فن آوری های جدید در مهندسی روسازی اجتناب ناپذیر است. هوش مصنوعی، فن آوری نوینی است که برای توسعه ماشین ها و الگوریتم هایی که همانند هوش انسان عمل می کنند استفاده می شود. هوش مصنوعی، قابلیت های منحصر به فردی در بهبود فرآیندهای طراحی، اجرا، ترمیم و نگهداری روسازی ارائه داده است که نیازمند زمان و هزینه بسیار کمتری نسبت به روش های سنتی هستند. در این تحقیق با بررسی ۱۵۰ مقاله علمی معتبر، کاربرد هوش مصنوعی در دسته یادگیری ماشین در مهندسی روسازی مورد بررسی قرار گرفته است. تحلیل پژوهش های موجود نشان داد الگوریتم های یادگیری ماشین در ۷ حوزه پژوهشی از مهندسی روسازی استفاده شده اند: بهینه سازی طراحی (۱۱٪ از مطالعات)، پیش بینی عملکرد قیر (۸٪)، پیش بینی خصوصیات مخلوط آسفالتی (۳۳٪)، تشخیص خرابی های سطح (۱۹٪)، طبقه بندی خرابی های سطح (۲٪)، پیش بینی شاخص های عملکردی رویه (۲۱٪) و بهینه سازی برنامه عملیات ترمیم و نگهداری (۶٪). همچنین با هدف شناسایی روندهای موجود در ادبیات موضوع و نیز احصاء دستاوردهای محققین، تحلیل های آماری از فراوانی پژوهش های منتشر شده در سال های مختلف، الگوریتم های استفاده شده در مدلسازی و متغیرهای وارد شده جهت پیش بینی عملکرد مخلوط یا روسازی آسفالتی ارائه گردید. این مطالعه نشان داد یادگیری ماشین ابزاری ضروری و جدایی ناپذیر جهت اجرا، بهبود و بهینه سازی فرآیندهای مختلف طراحی، ساخت، نگهداری و مدیریت روسازی است. لذا گسترش تحلیل های مبتنی بر هوش مصنوعی و ارزیابی کاربردهای آن در حوزه مهندسی روسازی ضرورت داشته و پیش نیاز شکل گرفتن فن آوری های لب دانشی از جمله دوقلوهای دیجیتال روسازی است.

## واژگان کلیدی:

روسازی آسفالتی، هوش مصنوعی، یادگیری ماشین، شبکه عصبی مصنوعی، بهینه سازی

## ۱- مقدمه و تاریخچه تحقیقات

ایده ابتدایی هوش مصنوعی<sup>۱</sup> از زمان اختراع کامپیوتر آغاز شده است. اما از اواسط دهه ۱۹۵۰ به یک دانش چند رشته‌ای تبدیل شد. جان مک‌کارتی<sup>۲</sup> پدر دانش هوش مصنوعی، در سال ۱۹۵۶ آن را "علم ساخت ماشین‌های هوشمند" معرفی کرد. ظهور تکنیک‌های محاسبات نرم به‌ویژه آشنایی با شبکه عصبی مصنوعی در میانه دهه ۱۹۸۰ سبب پیشرفت بزرگی در دانش هوش مصنوعی شد و آن را به ابزاری برای حل مسائل بشر تبدیل کرد [۱ و ۲]. هوش مصنوعی در حل مسائل مختلف، به ویژگی‌های انسانی قابل انجام توسط ماشین‌ها نیازمند است. این ویژگی‌ها شامل ادراک، یادگیری، حل مسئله و برنامه‌ریزی است [۳ و ۴]. هوش مصنوعی قادر است وظایف پیچیده و متداول انسان مانند یادگیری، طبقه‌بندی، تشخیص و تصمیم‌گیری را بدون از دست‌دادن زمانی برای کسب تجربه و بدون هیچ‌گونه خستگی انجام دهد [۵ و ۶]. رشته‌های فرعی هوش مصنوعی، پردازش زبان طبیعی<sup>۳</sup>، پردازش تصویر و استخراج داده هستند که این رشته‌ها با استفاده از الگوریتم‌های مختلفی مانند یادگیری عمیق<sup>۴</sup> در زمینه‌های مختلف از جمله مهندسی وارد شده‌اند [۷ و ۸].

از ابتدای قرن ۲۱م به‌طور ویژه‌ای از دانش هوش مصنوعی در مهندسی روسازی استفاده شده است. توسعه راه‌ها و رشد تقاضا برای ساخت روسازی‌های آسفالتی با کیفیت در کنار محدودیت‌های اقتصادی و زمانی، تلفیق روش‌های سنتی و تکنولوژی‌های جدید را اجتناب‌ناپذیر ساخته است [۸ و ۹]. روش‌های منطبق بر هوش مصنوعی، برخلاف روش‌های مرسوم قدیمی، نیازمند محاسبات گسترده برای اطلاعات ورودی نیستند. زیرا عملکرد این روش‌ها بر مبنای یادگیری داده‌ها و شناخت الگوی ورودی‌ها و خروجی‌های پدیده‌ها است [۶ و ۱۰]. هوش مصنوعی و یادگیری ماشین به خاطر موفقیت‌های اخیر خود به‌ویژه در بخش یادگیری عمیق، در حال تبدیل‌شدن به اصلی‌ترین ابزار حل مسائل پژوهشی و صنعتی هستند [۱۱]. رشد سریع جهان و افزایش حجم داده‌های جمع‌آوری شده، سبب پیشرفت علم داده و ایجاد زمینه‌های جدید برای یادگیری ماشین، به‌ویژه یادگیری عمیق شده است [۱۲]. در این

مقاله به بیان نقش هوش مصنوعی در مهندسی روسازی به تفکیک مراحل طراحی، ساخت، بهره‌برداری و نهایتاً مدیریت ترمیم‌ونگهداری آن پرداخته شده است.

هدف از ایجاد روسازی، ایجاد سطحی صاف و هموار با توان انتقال بارهای ناشی از ترافیک به خاک بستر است. روسازی علاوه بر مقاومت در برابر بارهای واردشده باید در مقابل شرایط مختلف آب و هوایی مقاوم باشد. شناخت کافی از عملکرد اجزای مخلوط آسفالتی و طراحی مناسب، ضروری است. پیش‌بینی نتایج تست‌های متداول عملکرد قیر و مخلوط آسفالتی و نیز پیش‌بینی خرابی‌های روسازی‌های آسفالتی، افزایش دقت مطالعات روسازی را به دنبال داشته است. از این رو محققین به استفاده از هوش مصنوعی در طراحی روسازی‌ها پرداخته‌اند.

اما ساخت و اجرای صحیح روسازی‌های آسفالتی نیز به اندازه طراحی آن‌ها دارای اهمیت است. تخمین میزان انرژی مصرف شده در زمان تولید مخلوط آسفالتی، دمای مصالح سنگی، مقدار تراکم روسازی و نیز هزینه‌های احداث آن از مواردی هستند که با وجود الگوریتم‌های هوش مصنوعی امکان‌پذیر شده است. پس از مرحله ساخت و اجرا، به منظور حفظ روسازی‌های آسفالتی در شرایط مطلوب خدمت‌رسانی، ارزیابی پیوسته آن‌ها ضروری است. زیرا تشخیص خرابی‌ها در مراحل اولیه، امکان ترمیم‌های پیشگیرانه را فراهم ساخته و به افزایش طول عمر قطعات روسازی و کاهش هزینه ترمیم‌ونگهداری آن‌ها منجر شده است. ارزیابی شامل نظارت بر سازه روسازی و نیز شناسایی، طبقه‌بندی و ارزیابی شدت خرابی‌ها است. در سال‌های اخیر با استفاده از هوش مصنوعی به‌ویژه شبکه‌های عصبی پیچشی<sup>۵</sup> که نوعی طبقه‌بندی‌کننده غیرخطی محسوب می‌شوند، گام مهمی در سیستم‌های نظارت بر روسازی برداشته شده است. این روش مقرون‌به‌صرفه جایگزین روش‌های سنتی ارزیابی روسازی شده است که بسیار زمان‌بر و پرهزینه بودند [۱۳-۱۶].

با توجه به این که روسازی‌ها با گذر زمان از احداثشان دچار افت شدید عملکردی می‌شوند، پایش و نظارت پیوسته بر روسازی‌ها زمینه ترمیم و نگهداری مناسب آن‌ها را فراهم ساخته است. بنابراین

<sup>۴</sup> Deep Learning (DL)

<sup>۵</sup>Convolutional Neural Network (CNN)

<sup>۱</sup> Artificial Intelligence (AI)

<sup>۲</sup> John McCarthy

<sup>۳</sup> Natural Language Processing (NLP)

سرمایه‌گذاری مستمر برای بهبود سطح خدمت یا بازسازی روسازی‌های موجود تاثیر قابل توجهی بر کیفیت راه‌ها داشته است. کمبود منابع مالی در کنار پیچیدگی‌های اجرایی روش‌های متداول ارزیابی عملکرد روسازی‌ها، فرآیند ترمیم‌ونگهداری را به امری پیچیده تبدیل کرده‌است. در این راستا، هوش مصنوعی با پیش‌بینی شاخص‌های عملکردی روسازی، بهینه‌سازی برنامه ترمیم‌ونگهداری و نیز تصمیم‌گیری به‌وسیله مدل‌های هوشمند، مدیریت شبکه گسترده روسازی را تسهیل نموده‌است [۱۷-۱۸].

مطالعات متعددی به مرور کاربرد های الگوریتم‌های هوش مصنوعی در حوزه راه‌وتراپری و مهندسی روسازی پرداخته‌اند. شعله‌ور، گل‌رو و همکاران در سال ۲۰۲۲، کاربردهای الگوریتم‌های یادگیری ماشین را در زمینه پایش و وضعیت روسازی مورد بررسی قرار دادند [۱۹]. همچنین، کونن<sup>۱</sup> و گل‌رو در سال ۲۰۱۷ در پژوهشی با موضوع مشابه، به مرور پیشینه تحقیق در زمینه شناسایی خودکار خرابی‌های روسازی پرداختند [۲۰]. این پژوهش‌ها، علیرغم ارائه تصویری کامل از پیشرفت‌های حاصل شده در بهره‌گیری از مدل‌های هوش مصنوعی در پایش سلامت راه‌ها، کاربردهای هوش مصنوعی در زمینه بهینه‌سازی طرح اختلاط آسفالت، بهینه‌سازی هزینه‌های احداث روسازی و پیش‌بینی خواص قیر و مخلوط آسفالتی را مورد بررسی قرار نداده‌اند.

برخی محققین دیگر از جمله ژو و ژنگ<sup>۲</sup> در سال ۲۰۲۲ [۲۱] و کانو اورتیز<sup>۳</sup> و همکاران در سال ۲۰۲۲ [۲۲] به مرور روش‌های توسعه مدل‌های عملکردی روسازی با استفاده از الگوریتم‌های هوش مصنوعی پرداخته‌اند. همچنین کنگ<sup>۴</sup> و همکاران در سال ۲۰۲۴ [۲۳] به بررسی کاربردهای هوش مصنوعی در توسعه مدل‌های رفتار روسازی از طریق پیش‌بینی شاخص‌های عملکردی پرداختند. این مطالعات علیرغم مرور دقیق کاربردهای هوش مصنوعی در سیستم‌های مدیریت روسازی، کاربردهای هوش مصنوعی در سایر زمینه‌های مهندسی راه را پوشش نداده‌اند. امبرز و فررا<sup>۵</sup> در سال

۲۰۲۳ [۲۴] و ینگ<sup>۶</sup> و همکاران در سال ۲۰۲۱ [۲۵] به بررسی کاربردهای شبکه‌های عصبی مصنوعی در مهندسی روسازی پرداختند که منجر به شناسایی معماری‌های رایج در مدلسازی و نیز چالش‌های موجود گردید. این پژوهش‌ها با اینکه اطلاعات دقیقی از مدلسازی با شبکه‌های عصبی را ارائه نمودند، اما بررسی سایر مدل‌های یادگیری ماشین یا یادگیری عمیق را از قلم انداخته‌اند. از مطالعات مروری دیگری که تنها بر یک مرحله از چرخه عمر روسازی تمرکز داشته‌اند می‌توان به مطالعه ونگ<sup>۷</sup> و همکاران در سال ۲۰۲۴ [۲۶] اشاره نمود که توسعه‌های اخیر در زمینه تراکم هوشمند آسفالت را مورد بررسی قرار دادند.

مطالعه حاضر انواع مدل‌های مختلف موجود در حوزه‌های یادگیری ماشین را در حیطه‌های مختلف مهندسی روسازی از جمله انتخاب مواد و ایجاد مصالح، پیش‌بینی خواص مصالح، تحلیل تاثیر مواد بر نتایج آزمایش‌ها، بهینه‌سازی عملیات نگهداری و تعمیرات و شناسایی خودکار خرابی‌ها را تحلیل نموده‌است. همچنین تلاش شده‌است تا ضمن ارائه آماره‌های توصیفی و فراوانی‌های الگوریتم‌ها، متغیرها و موضوعات انتخاب‌شده، دستاوردها و نواقص تحقیقاتی موجود نیز شناسایی شوند. بر این اساس پیشنهادهایی جهت به‌کارگیری در پژوهش‌های آینده نیز مطرح شده‌است.

ساختار ادامه این مقاله بدین شرح است: بخش دوم دربرگیرنده معرفی هوش مصنوعی و الگوریتم‌های یادگیری ماشین است. بخش سوم، خلاصه مقالات منتشرشده با محوریت استفاده از هوش مصنوعی در زمینه ساخت روسازی را ارائه نموده‌است. خلاصه پژوهش‌های منتشر شده با موضوع کاربرد های هوش مصنوعی در بررسی و نظارت روسازی و همچنین تحلیل و مقایسه آن‌ها در بخش سوم ارائه شده‌است. به‌منظور درک تفاوت رویکرد پژوهشگران ایرانی و حجم کار آن‌ها، پژوهش‌های منتشر شده به زبان فارسی به صورت مجزا در بخش چهارم ارائه و تحلیل شده‌است. در نهایت، یافته‌های پژوهش، در بخش پایانی مقاله یعنی بخش پنجم جمع‌بندی شده‌است.

<sup>۵</sup> Ambres & Ferreira

<sup>۶</sup> Yang

<sup>۷</sup> Wang

<sup>۱</sup> Coenen

<sup>۲</sup> Xu & Zhang

<sup>۳</sup> Cano-Ortiz

<sup>۴</sup> Kang

مبدل‌ها<sup>۱</sup> اشاره نمود [۳۳ و ۳۴]. در ادامه، تاریخچه و انواع این دو روش آموزش ماشین شرح داده شده‌است.

## ۲- هوش مصنوعی

هدف اصلی در دنیای مدرن امروز، انجام سریع و دقیق کارها است و روش‌های متداول و سنتی، زمان‌بر و ناکارآمد هستند. بنابراین ماشین‌ها که فاقد محدودیت‌های انسانی مانند کندی، فراموشی، سرعت کم و نامنظمی هستند می‌توانند انسان‌ها را در انجام وظایف متداول و مواجهه با چالش‌های خود یاری نمایند [۲۷]. دانش هوش مصنوعی در سال ۱۹۴۳ با اختراع رایانه‌های الکترونیکی مطرح شد. اما با کاهش سرعت پیشرفت این دانش، انتظارات محققین برآورده نشد و با کاهش سرمایه‌گذاری‌ها، هوش مصنوعی موقتاً به پایان خود رسید [۲۸]. اما مجدداً با گذشت زمان، هوش مصنوعی در دهه‌های اخیر به منظور افزایش بهره‌وری، تسریع خودکارسازی و کاهش هزینه‌ها مورد توجه قرار گرفت [۲۷]. هوش مصنوعی دانش تولید ماشین‌های هوشمند با توانایی تقلید از رفتارهای انسانی مانند تجزیه و تحلیل، طبقه‌بندی و پیش‌بینی است [۲۹]. ماشین‌ها به دلیل عدم توانایی مواجهه با موقعیت‌های جدید، همواره به سطحی از تجربه انسانی نیازمند بوده و آن را با یادگیری از مجموعه داده‌های پیشین بدست می‌آورند [۳۰].

یادگیری ماشین زیرمجموعه‌ای از هوش مصنوعی است که به‌طور خودکار ماشین یا سیستم را قادر می‌سازد تا از تجربه خود یاد بگیرد و پیشرفت کند [۳۱ و ۳۲]. اصلی‌ترین شاخه یادگیری ماشین، یادگیری عمیق است که از شبکه‌های عصبی پیچشی و لایه‌های پنهان بیشتری بهره می‌برد و امکان اجرای تحلیل‌های پیشرفته از جمله تحلیل داده‌های سری زمانی، تصاویر و پایگاه‌های داده متنی را فراهم می‌سازد. شبکه‌های عصبی پیچشی مبنای الگوریتم‌های یادگیری عمیق هستند که متشکل از چندین لایه پنهان بوده و در حوزه‌های مختلفی از جمله شناسایی اشیا، تشخیص گفتار و پردازش زبان طبیعی عملکرد موفقی داشته‌اند. از دیگر الگوریتم‌های یادگیری عمیق می‌توان به شبکه‌های عصبی بازگشتی، شبکه مولد متخاصم و

### ۲-۱- یادگیری ماشین

دهه اول قرن ۲۱ به نقطه عطفی در تاریخ یادگیری ماشین تبدیل شد. زیرا پیشرفت سریع فن‌آوری و ایجاد داده‌های گسترده در علوم مختلف، تحلیل داده‌های حاصل از آزمایش‌های جدید محققین را امکان‌پذیر ساخت [۳۵]. یادگیری ماشین بخشی از هوش مصنوعی است که به ماشین‌ها امکان یادگیری از داده‌ها را داده است. در این روش برنامه‌نویسی‌های دقیق و جزئی صورت نمی‌گیرد بلکه سیستم، توانایی فهم روابط پیچیده بین داده‌های ایجادشده را به‌دست می‌آورد و بر اساس آن می‌تواند بهترین مدل پیش‌بینی را ارائه دهد [۳۶]. در نتیجه، تکنیک‌های یادگیری ماشین به طور قابل ملاحظه‌ای در تسریع فرآیندهای تجزیه، تحلیل و تفسیر داده‌ها موثر بوده و مزایای زیادی نسبت به ابزارهای سنتی در تحقیقات ارائه می‌دهند. اگر این تکنیک‌ها قادر به یادگیری از تعداد داده‌های کمتر و تطابق با محیط‌های جدید شوند، تاثیر آن‌ها بسیار بیشتر خواهد شد [۳۶ و ۳۷].

یادگیری ماشین عمدتاً شامل چهار بخش جمع‌آوری داده‌ها، نمایش داده‌ها، انتخاب الگوریتم مناسب و بهینه‌سازی مدل است [۳۸]. روش‌های یادگیری ماشین بر اساس نوع داده‌های ورودی غالباً به سه دسته یادگیری نظارت‌شده (مانند رگرسیون و طبقه‌بندی<sup>۲</sup>، یادگیری بدون نظارت (مانند خوشه‌بندی<sup>۳</sup> و یادگیری تقویتی<sup>۴</sup> تقسیم‌بندی می‌شوند. در حال حاضر رایج‌ترین الگوریتم‌های یادگیری ماشین، ماشین بردار پشتیبان<sup>۴</sup>، نزدیک‌ترین همسایگی<sup>۵</sup>، رگرسیون لجستیک<sup>۶</sup>، درخت تصمیم‌گیری<sup>۷</sup> و شبکه‌های عصبی مصنوعی هستند [۲۷]. در ادامه شبکه‌های عصبی مصنوعی به اختصار شرح داده می‌شوند.

### ۲-۲- شبکه‌های عصبی مصنوعی

<sup>۵</sup> K Nearest Neighbour (KNN)

<sup>۶</sup> Logistic Regression

<sup>۷</sup> Decision Tree

<sup>۱</sup> Transformers

<sup>۲</sup> Classification

<sup>۳</sup> Reinforcement Learning

<sup>۴</sup> Support Vector Machine (SVM)

شکل ۱: هوش مصنوعی و زیرمجموعه‌های آن [۴۵]

Fig. 1. AI and its subcategories [45]

### ۳- کاربردهای هوش مصنوعی در روسازی راه


در این بخش به مرور پژوهش‌های مهندسی روسازی با محوریت استفاده از الگوریتم‌های یادگیری ماشین پرداخته شده‌است. شایان ذکر است این پژوهش‌ها در چند موضوع کلی قابل طبقه‌بندی هستند:

- ۱- طراحی روسازی: بهینه‌سازی طرح براساس معیارهای مختلف
- ۲- خصوصیات مواد و عملکرد مخلوط: پیش‌بینی عملکرد قیر و پیش‌بینی خواص مخلوط،
- ۳- ارزیابی وضعیت روسازی: تشخیص وجود خرابی و طبقه‌بندی نوع آن،
- ۴- مدیریت روسازی: پیش‌بینی مقادیر شاخص‌های عملکردی رویه و برنامه‌ریزی عملیات نگهداری.

#### ۱-۳- طراحی روسازی

در یک دهه اخیر، ارائه طرح سازه‌ای روسازی به منظور افزایش دقت و بهینه‌سازی هزینه‌های طراحی با استفاده از هوش مصنوعی مورد توجه محققین بوده‌است. در این راستا، هی<sup>۴</sup> و همکاران در سال ۲۰۱۴ به پیش‌بینی هزینه ساخت یک روسازی آذراهی با استفاده از شبکه عصبی پرداختند. مطالعه در شهر هنان چین انجام شد و از ۸۸ قطعه آذراه ساخته‌شده در بین سال‌های ۱۹۹۴ تا ۲۰۰۰، ۸۱ مورد برای آموزش شبکه عصبی به‌طور تصادفی انتخاب شد. در این

پرکاربردترین زیر مجموعه روش‌های یادگیری ماشین، شبکه‌های عصبی مصنوعی<sup>۱</sup> است که برخلاف روش‌های متداول آماری می‌توانند مسائل پیچیده را با دقت بالاتر مدلسازی نمایند [۳۹]. اولین بار شبکه‌های عصبی در سال ۱۹۴۰ معرفی شدند [۴۰]. اما ویدرو و هاف<sup>۲</sup> در دانشگاه استنفورد در سال ۱۹۶۰ برای اولین بار از یک شبکه عصبی مصنوعی در حل مسائل واقعی استفاده نمودند. آشنایی با این شبکه‌ها در طول سال‌های ۱۹۷۰ تا ۱۹۸۰ زمینه استفاده بیشتر از هوش مصنوعی در مهندسی عمران را فراهم کرد [۴۱]. شبکه عصبی مصنوعی به مجموعه‌ای از یاخته‌های عصبی<sup>۳</sup> (یا نورون‌ها) می‌گویند که در یک معماری ویژه و برای حل مسئله‌ای خاص به هم متصل شده‌اند و هر کدام محاسبات ساده‌ای انجام می‌دهند. هر یاخته عصبی داده ورودی را دریافت نموده و پس از انجام محاسبات، خروجی را به یاخته‌های متصل به خود می‌دهد. شبکه‌های عصبی مصنوعی از سه بخش لایه ورودی، لایه‌های پنهان و لایه خروجی در راستای پردازش داده‌های تجربی و کشف قانون نهفته در ساختار داده‌ها تشکیل شده است [۴۲]. این شبکه‌ها در طبقه‌بندی، خوشه‌بندی، شناسایی الگو و پیش‌بینی‌ها در علوم مختلف عملکرد مناسبی نشان داده‌اند [۴۳] و [۴۴]. در شکل ۱، هوش مصنوعی و زیرمجموعه‌های آن مشخص شده است.



<sup>۳</sup> Neuron

<sup>۴</sup> He

<sup>۱</sup> Artificial Neural Network (ANN)

<sup>۲</sup> Widrow & Hoff

شبکه از فرآیند پس‌انتشار<sup>۱</sup> استفاده شد که از یک لایه پنهان محاسباتی بهره می‌برد. در این مطالعه بیش از ۹ پارامتر ورودی وجود داشت و پارامترهایی همچون توپوگرافی، اقلیم، زمین‌شناسی، تغییر ارتفاع و هزینه‌های نیروی کار و قیمت تجهیزات و مصالح در نظر گرفته شده است [۴۶].

تی‌دمیر<sup>۲</sup> در سال ۲۰۱۴ به ارزیابی مجدد معادله اصلی طراحی روسازی‌های انعطاف‌پذیر آشتو ۱۹۹۳ با روش شبکه عصبی مصنوعی پرداخت. این معادله تعداد بار تک‌محور هم‌ارز که قابلیت عبور از روسازی آسفالتی با مشخصات معین را دارد، محاسبه می‌نماید. اهمیت این مطالعه از این جهت بود که فرمول آشتو معمولاً این مقدار را بیش از حد واقعی پیش‌بینی کرده است. در این مطالعه از پایگاه داده عملکرد بلندمدت روسازی<sup>۳</sup> استفاده شده است. از کل ۲۴۴ مقطع روسازی، ۲۳۴ مقطع در مدلسازی به کار گرفته شده است که علت این کاهش، عدم وجود اطلاعات بارش برای ۱۰ مقطع روسازی بوده است. یک لایه پنهان، شش متغیر ورودی و دو متغیر خروجی مرتبط با ترافیک معادل هم‌ارز، مدل شبکه عصبی را تشکیل داده است. ضریب همبستگی بین ترافیک واقعی عبوری و ترافیک پیش‌بینی شده با مدل شبکه عصبی برابر ۹۹/۹٪ بوده که بیانگر دقت بالای این مدل است [۴۷].

با توجه به اینکه روش‌های سنتی طراحی روسازی آسفالتی امکان طراحی روسازی مقاوم در برابر خرابی‌های مختلف را نداشته است، در پژوهش‌های اخیر از مواد متنوع و روش‌های نوین برای طراحی استفاده شده است. قدیر و همکاران در سال ۲۰۲۰، مدل‌های طراحی عملکردی آسفالت مقاوم شده با ژئوسنتتیک‌ها را مورد مطالعه قرار دادند. نتایج نشان داد که افزودن یک لایه ژئوسنتتیک، بیش از ۱۵۰٪ سختی خمشی روسازی را افزایش داده است. داده‌های مدلسازی از نمونه‌های آزمایشگاهی تست‌های مارشال و تست عمق شیارشدگی حاصل شده است. نمونه‌ها در سه دانه‌بندی میانی، درشت‌دانه و ریزدانه ساخته و مورد آزمایش قرار گرفته است. در کنترل سختی خمشی تا

۱۰،۰۰۰ سیکل بارگذاری انجام شده است. دانه‌بندی میانی تقویت شده، بیشترین استحکام را در بین تمام نمونه‌ها نشان داده است. مطابق نتایج برای مجموعه داده‌های کوچک، شبکه‌های عصبی با توابع پایه شعاعی<sup>۴</sup> در راستای پیش‌بینی سختی خمشی و نیز شبکه عصبی پیش‌رونده<sup>۵</sup> در راستای پیش‌بینی عمق شیارشدگی مناسب بوده است [۴۸].

به منظور طراحی روسازی با استفاده از روش‌های مکانیکی-تجربی<sup>۶</sup> به اطلاعات طبقه‌بندی شده خودروها نیاز است. طاحائی و همکاران در سال ۲۰۲۱، به طبقه‌بندی گروه‌های مختلف کامیون از طریق داده‌های توزین در حرکت کامیون‌ها پرداختند. داده‌های این آزمایش از ایستگاه‌های توزین در حال حرکت<sup>۷</sup> کشور گرجستان حاصل شده بود. ۱۷ دسته ترافیک کامیونی تعریف شد و با کمک روش‌های نظارت شده و بدون نظارت یادگیری ماشین، داده‌ها به طبقات مختلف تقسیم بندی شدند. هدف از این تقسیم‌بندی طراحی دقیق‌تر روسازی بود. همچنین الگوریتم میانگین‌گیری<sup>۸</sup> به منظور خوشه‌بندی داده‌های ترافیکی استفاده شد [۴۹].

توحیدی و همکاران در سال ۲۰۲۲ در مطالعه‌ای به کاربرد الگوریتم‌های هوشمند جست‌وجو با هدف طراحی ضخامت روسازی راه‌ها با کمترین هزینه پرداختند. طراحی دستی روسازی فرآیندی آزمون و خطایی، زمان‌بر و خسته‌کننده است. در نتیجه، رسیدن به طرح‌های بهینه نیازمند صرف مدت زمان زیادی است. محققین دو الگوریتم ژنتیک و نیز بهینه‌سازی ازدحام ذرات<sup>۸</sup> را مورد مقایسه قرار دادند. مطابق نتایج، الگوریتم ژنتیک عملکرد بهتری داشته اما هر دو الگوریتم عملکرد مطلوبی داشتند: الگوریتم ژنتیک ۹-۲۶/۵٪ و الگوریتم بهینه‌سازی ازدحام ذرات، ۵-۲۵٪ کاهش هزینه نهایی را به دنبال داشته است. مبنای طراحی در این مطالعه روش نشریه ۲۳۴ آیین نامه طراحی روسازی ایران است. الگوریتم ژنتیک، رایج‌ترین الگوریتم مهندسی در بهینه‌سازی مسائل مهندسی است. در این مطالعه نرم‌افزاری توسعه داده شد تا دو الگوریتم بهینه‌سازی را با

<sup>۶</sup> Mechanistic-Emperical Pavement Design Guide (MEPDG)

<sup>۷</sup> Weigh-in-Motion (WIM)

<sup>۸</sup> Particle Swarm Optimization (PSO)

<sup>۱</sup> Back-propagation

<sup>۲</sup> Tigdemir

<sup>۳</sup> Long-term Pavement Performance (LTPP)

<sup>۴</sup> Radial Basis Function Networks

<sup>۵</sup> Feedforward neural network

نظر گرفتن عوامل مختلف اجرا نماید: روش طراحی آشتو ۱۹۹۳، متغیرهای موثر بر طراحی روسازی (مانند عدد سازه‌ای، انحراف معیار استاندارد، مقدار کاهش سطح خدمت روسازی)، موقعیت مکانی مناطق مختلف خوزستان، قیمت مصالح و ضخامت لایه‌های مختلف روسازی [۵۰].

## ۲-۳- پیش‌بینی عملکرد قیر

یکی از چالش‌های پیش روی مهندسين روسازی، تعیین مقدار افزودنی لازم در راستای بهبود عملکرد قیر مخلوط‌های آسفالتی است. شیانو<sup>۱</sup> و همکاران در سال ۲۰۱۱ به پیش‌بینی مقدار ویسکوزیته قیرهای اصلاح‌شده با پودر لاستیک با استفاده از روش شبکه عصبی مصنوعی پرداختند. متغیرهای ورودی این مدل، منبع تهیه قیر، سایز قطعات لاستیک، زمان اختلاط و مقدار لاستیک بود. نتایج نشان داد که طول زمان اختلاط نسبت به سایر پارامترهای ورودی، اهمیت چندانی نداشته‌است ولی حساسیت ویسکوزیته نسبت به منبع قیر و مقدار لاستیک و سایز قطعات لاستیکی زیاد بوده‌است. دو نوع قیر از ونزوئلا و یک نوع از آمریکا مورد بررسی قرار گرفته‌است. یک لایه پنهان نیز در شبکه عصبی توسعه داده‌شده، استفاده شده‌است. دقت مدل ارائه‌شده برای قیرهای لاستیکی مختلف از ۴۶٪ تا ۷۶٪ بوده‌است [۵۱].

حسینی و همکاران در سال ۲۰۲۱، با هدف تعیین مقدار بهینه اصلاح‌کننده‌ها در طرح مخلوط آسفالتی از روش‌های یادگیری ماشین بهینه‌شده استفاده کردند. در این راستا رفتار ویسکوالاستیک قیرهای اصلاح‌شده پیش‌بینی شد. پیش‌بینی تأثیر اصلاح‌کننده‌های مختلف بر قیر با توجه به پارامترهای مدول برشی قیر ( $G^*$ ) و زاویه فاز ( $\delta$ ) حاصل از تست رئومتر برشی دینامیکی<sup>۲</sup> انجام شد. اصلاح‌کننده‌های مورد بررسی عبارت است از پودر لاستیک، استایرن-بوتادین-استایرن<sup>۳</sup> و پلی فسفریک اسید. روش‌های شبکه‌های عصبی مصنوعی،

رگرسیون بردار پشتیبانی خطی<sup>۴</sup>، رگرسیون درخت تصمیم‌گیری، رگرسیون مرحله‌ای گاوسی<sup>۵</sup> و رگرسیون عملکردی بر داده‌ها توسعه داده شد. با مقایسه خروجی‌های مدل مورد مطالعه از نظر عملکرد از جمله همبستگی ضرایب، انحراف جذر میانگین مربعات<sup>۶</sup> و خطای نسبی، مشخص شد که روش رگرسیون عملکردی بیش‌ترین کارایی را در پیش‌بینی داشته‌است. لازم به ذکر است داده‌های مدلسازی حاصل آزمایش در دماهای ۲۲-، ۱۶-، ۱۰-، ۰، ۱۰، ۱۶ و ۲۲ درجه سانتی‌گراد بوده‌است [۵۲].

آریفوزمان<sup>۷</sup> و همکاران در سال ۲۰۲۱، چسبندگی قیر را مورد بررسی قرار دادند. همواره عوامل متعددی مانند دما، رطوبت و اکسیداسیون بر خواص قیرهای اصلاح‌شده تأثیرگذار است. از این جهت، شناخت تغییرات ویژگی‌های این قیرها به منظور ارائه طرح‌های با دوام ضروری است. این مدل‌سازی با استفاده از یک الگوریتم بهینه‌سازی بیز<sup>۸</sup> و نیز رگرسیون بردار پشتیبان با مجموعه داده‌های حاصل از ۴۰۵ نمونه انجام شده‌است. مقاومت چسبندگی نمونه‌ها با استفاده از میکروسکوپ نیروی اتمی اندازه‌گیری شده‌اند. ضریب برازش داده‌های حاصل از مدل ساخته‌شده نسبت به داده‌های واقعی بیش از ۹۰٪ بوده‌است [۵۳].

ریاض<sup>۹</sup> و همکاران در سال ۲۰۲۴ عملکرد دماهای بالا و متوسط قیر اصلاح‌شده با استایرن-بوتادین-استایرن، پلیمر لیگنین<sup>۱۰</sup> و خرده لاستیک بازیافتی<sup>۱۱</sup> را از طریق اجرای الگوریتم‌های یادگیری ماشین و همچنین آزمایش‌های آزمایشگاهی بهینه‌سازی نمودند. در این راستا ابتدا نمونه‌های قیر اصلاح‌شده با افزودنی‌های بیان‌شده (به میزان ۳٪، ۶٪ و ۹٪) از طریق قرارگیری در دستگاه آون دوار لایه نازک<sup>۱۲</sup> و دستگاه پیرشدگی تحت فشار<sup>۱۳</sup> به حالت پیرشده منتقل شدند. سپس

<sup>۸</sup> Bayesian method

<sup>۹</sup> Riyad

<sup>۱۰</sup> Lignin

<sup>۱۱</sup> Ground Tire Rubber (GTR)

<sup>۱۲</sup> Rolling Thin Film Oven (RTFO)

<sup>۱۳</sup> Pressure Aging Vessel (PAV)

<sup>۱</sup> Xiao

<sup>۲</sup> Dynamic Shear Rheometer (DSR)

<sup>۳</sup> Styrene-Butadiene-Styrene (SBS)

<sup>۴</sup> Support Vector Regression (SVR)

<sup>۵</sup> Gaussian Phased Regression

<sup>۶</sup> Root Mean Squared Error (RMSE)

<sup>۷</sup> Arifuzzaman

آزمایش‌های مختلفی با دستگاه‌های رئومتر برشی دینامیکی، ویسکومتر چرخشی<sup>۱</sup>، طیف‌سنج تبدیل فوریه فروسرخ<sup>۲</sup> و بمب گرماسنج<sup>۳</sup> بر حدود ۵۱ نمونه پیرشده اجرا شد تا خصوصیات پایه آن‌ها ارزیابی شوند. با اضافه شدن هر یک از ۳ ماده اصلاح‌کننده، مقاومت قیر نسبت به شیارشدگی افزایش یافت. همچنین با اضافه شدن استایرن-بوتادین-استایرن و خرده لاستیک بازیافتی با مقادیر بالا، معیار ترک خستگی سوپرپیو<sup>۴</sup> کاهش یافت که نشان از آسیب‌پذیری کمتر قیر اصلاح‌شده در برابر ترک خستگی بود. در نهایت داده‌های بدست‌آمده از آزمایش‌ها برای توسعه مدل‌های یادگیری ماشین استفاده گردید که متغیرهای پیش‌بینی‌شده عبارت بودند از گرمای سوختن<sup>۵</sup> و دمای شکست<sup>۶</sup>. متغیرهای پیش‌بینی‌کننده دمای شکست عبارت بودند از: قیر پایه، نوع و درصد افزودنی، شرایط پیرشدگی و مقدار نرمال‌شده گرمای سوختن. همچنین متغیرهای پیش‌بینی‌کننده گرمای سوختن شامل قیر پایه، نوع و درصد افزودنی، شرایط پیرشدگی، دمای شکست و همچنین مقادیر زاویه فاز و مدول برشی در دمای شکست بود. از میان مدل‌های ساخته‌شده، رگرسیون لاسو<sup>۷</sup> و رگرسیون تقویت گرادیان<sup>۸</sup> به ترتیب بهترین عملکرد را در پیش‌بینی گرمای سوختن و دمای شکست داشتند [۵۴].

### ۳-۳- پیش‌بینی خصوصیات مخلوط آسفالتی

تاپکین<sup>۹</sup> و همکاران در سال ۲۰۰۹، نتایج آزمایش خزش نمونه های اصلاح‌شده با الیاف پلی پروپیلن را با استفاده از شبکه عصبی مصنوعی پیش‌بینی نمودند. دقت مدل ارائه شده ۹۷٪ بوده است. ورودی این مدل عبارت است از نوع پلی پروپیلن، ارتفاع نمونه، وزن مخصوص نمونه، درصد فضای خالی سنگدانه، درصد فضای پرشده با قیر، درصد فضای خالی مخلوط، زمان آسودگی و تعداد ضربه. در

ساخت این مدل یک لایه پنهان استفاده شده است. درصد قیر بهینه مخلوط با آزمایش مارشال با اعمال ۵۰ ضربه برای ترافیک متوسط تعیین شده بوده است. در پایان رابطه‌ای بین کرنش تجمعی و متغیرهای ورودی، توسعه داده شده است. افزودن پلی پروپیلن به‌طور قابل ملاحظه‌ای کرنش تجمعی را کاهش داده است. به‌طور کلی با افزایش پارامترهای طول دوره آسودگی، درصد فضای خالی سنگدانه ها، تعداد ضربه‌های وارده و درصد فضای پر شده با قیر، کرنش تجمعی مخلوط نیز افزایش یافته است. همچنین، با افزایش پارامترهای وزن مخصوص و درصد فضای خالی و ارتفاع نمونه، کرنش تجمعی کاهش یافته است [۵۵].

صفارزاده و حیدری‌پناه در سال ۲۰۰۹ مطالعه‌ای بر تاثیر درصد قیر بر روی مقاومت مارشال مخلوط آسفالتی با استفاده از شبکه عصبی مصنوعی انجام دادند. پایگاه داده، متشکل از ۱۱۰ نمونه مخلوط آسفالتی بود که در آزمایشگاه استان کرمان مورد آزمایش قرار گرفت. دانه‌بندی، درصد مصالح شکسته و درصد قیر به عنوان پارامترهای ورودی، و مقاومت مارشال به عنوان خروجی مدل در نظر گرفته شده است. بر مبنای مدل توسعه‌یافته و تجربیات آزمایشگاهی، با افزایش درصد قیر، ابتدا مقاومت مارشال افزایش و پس از رسیدن به حداکثر مقدار خود، کاهش یافته است. بیشینه مقاومت مارشال متناظر با درصد بهینه قیر مخلوط بوده است. این شبکه با یک لایه پنهان توسعه داده شده است [۵۶].

غنی‌زاده و فخری در سال ۲۰۱۴ به پیش‌بینی فرکانس در راستای شبیه‌سازی آزمایش‌های خستگی مخلوط آسفالتی با استفاده از روش شبکه عصبی مصنوعی و رگرسیون مارس پرداختند. در این مطالعه، ۵۰۰۰ مقطع چهار لایه روسازی مورد بررسی تئوری الاستیک لایه‌ای قرار گرفتند. هر دو روش توان پیش‌بینی مناسبی داشته‌اند؛ اما مطابق نتایج، شبکه عصبی از رگرسیون مارس انطباق بهتری داشته است. در توسعه شبکه عصبی از یک لایه پنهان استفاده شده است. با استفاده از این مدل توسعه داده‌شده می‌توان پاسخ‌های روسازی شامل تنش

<sup>۶</sup> Failure temperature

<sup>۷</sup> Lasso Regression

<sup>۸</sup> Gradient Boosting Regression

<sup>۹</sup> Tapkin

<sup>۱</sup> Rotating Viscometer (RV)

<sup>۲</sup> Fourier Transform Infrared (FTIR) Spectroscopy

<sup>۳</sup> Bomb Calorimeter

<sup>۴</sup> Superpave (Superior Performing Asphalt Pavement)

<sup>۵</sup> Combustion Heat



و کرنش را در فواصل شعاعی مختلف از محل اعمال بار به دست آورد [۵۷].

خرابی ناشی از خستگی، یکی از خرابی‌های متداول روسازی‌های آسفالتی است و انجام آزمایش‌های گسترده بر روسازی، پرهزینه بوده است. تاپکین در سال ۲۰۱۴ مدلی در راستای تخمین عمر خستگی مخلوط‌های قیری اصلاح‌شده با خاکستر بادی بر اساس شبکه‌های عصبی مصنوعی ارائه کرد. خاکستر بادی نسبت به پلیمرها مزایای اقتصادی و محیط‌زیستی بیشتری داشته‌است. چهار نوع خاکستر بادی مختلف مورد استفاده قرار گرفت. در طرح اختلاط این مخلوط از روش مارشال استفاده شده‌است. معیار خستگی در آزمایش، شروع ترک‌های ماکرو بوده‌است. ورودی‌های مدل عبارت بوده‌است از درصد قیر، ارتفاع نمونه، وزن مخصوص، وزن مخصوص بیشینه تئوری و کل فضای خالی مخلوط. داده خروجی این آزمایش، تعداد سیکل‌های بارگذاری تا ایجاد ترک‌های ماکروی خستگی (Nf) بوده‌است. به منظور آموزش مدل از الگوریتم لونیبرگ-مارکوارت<sup>۱</sup> استفاده شده‌است. مطابق نتایج، یک لایه پنهان کافی است؛ زیرا با افزایش لایه‌های پنهان به دو و سه، دقت برازش کاهش یافته‌است [۵۸].

پارامترهای درجه نرمی و مقاومت مارشال که از آزمایش مارشال محاسبه شده‌اند به عملکرد روسازی‌های راه‌ها مرتبط هستند. خونتی<sup>۲</sup> و همکاران در هند در سال ۲۰۱۴ مدلی در راستای پیش‌بینی پارامترهای مارشال مخلوط‌های قیری اصلاح‌شده با پلی اتیلن با روش‌های هوش مصنوعی ارائه دادند. در این تحقیق، از دو الگوریتم شبکه عصبی مصنوعی و ماشین بردار پشتیبان حداقل مربعات<sup>۳</sup> که یک رگرسیون غیرخطی است استفاده شده‌است. درصد فضای خالی، درجه نرمی<sup>۴</sup> و مقاومت مارشال پیش‌بینی شدند. در مجموع ۹۰ داده ورودی آزمایشگاهی شامل درصد سنگدانه‌های درشت، ریز دانه‌ها، فیلرها، درصد پلیمر و درصد قیر بوده‌است. مطابق نتایج، هر دو الگوریتم مناسب بوده اما شبکه عصبی از ماشین بردار پشتیبان نتایج نسبتاً بهتری داشته‌است. دقت پیش‌بینی پارامترهای مقاومت مارشال،

درجه نرمی و درصد فضای خالی توسط مدل شبکه عصبی برابر با ۹۳/۹۶٪ و ۹۷٪ بوده‌است [۵۹].

غنی زاده در سال ۲۰۱۷، به پیش‌بینی پاسخ‌های (تنش-کرنش-خیز) روسازی‌های آسفالتی با استفاده از روش رگرسیون ماشین بردار پشتیبان پرداخت. در این مدل‌سازی ۱۰۰۰۰ مقطع روسازی چهار لایه شامل خاک بستر، زیراساس دانه‌ای، اساس دانه‌ای و لایه آسفالتی مورد بررسی قرار گرفته‌است. در این تحلیل از بارگذاری تحت محور استاندارد ۸/۲ تنی و تئوری الاستیک لایه‌ای استفاده شده‌است. هدف مطالعه، محاسبه بیشینه کرنش کششی زیر لایه آسفالتی و بیشینه کرنش فشاری روی لایه بستر بوده‌است [۶۰].

مجیدی فرد و همکاران در سال ۲۰۱۹، مدل‌های پیش‌بینی انرژی شکست مخلوط آسفالتی را با استفاده از روش‌های یادگیری ماشین مورد بررسی قرار دادند. در این مطالعه، دو روش ماشینی برنامه‌ریزی بیان ژنی<sup>۵</sup> و شبکه عصبی مصنوعی ترکیب‌شده با الگوریتم تبرید شبیه‌سازی‌شده<sup>۶</sup> مورد استفاده قرار گرفت. روش برنامه‌ریزی بیان ژنی که از توسعه الگوریتم ژنتیک بدست آمده، مدل‌های ریاضی را بر مبنای مفاهیم تکامل داروین ارائه داده‌است. مطابق نتایج، مدل برنامه‌ریزی بیان ژنی نتایج بهتری از مدل ترکیبی تبرید شبیه‌سازی شده و شبکه عصبی مصنوعی نشان داده‌است. ده پارامتر ورودی شامل بیشینه سائز اسمی، درصد قیر، حد پایین درجه عملکردی قیر، نوع دانه‌بندی، درصد پودر لاستیک و همچنین یک لایه پنهان در شبکه عصبی مصنوعی ساخته‌شده تعریف شده‌است تا در نهایت انرژی شکست مخلوط آسفالتی پیش‌بینی شود [۶۱].

لی<sup>۷</sup> و همکاران در سال ۲۰۲۰، به پیش‌بینی مدول دینامیکی مخلوط آسفالتی با استخوان‌بندی سنگدانه‌ای<sup>۸</sup> پرداختند. این مطالعه اولین مقایسه مدول دینامیکی بین مخلوط‌های آسفالتی گرم و استخوان‌بندی سنگدانه‌ای بوده‌است. در این مطالعه از یک الگوریتم جدید یادگیری ماشین استفاده شد. این الگوریتم، ترکیبی از دو الگوریتم شبکه عصبی مصنوعی و یک الگوریتم بهینه‌سازی مبتنی بر

<sup>۶</sup> Artificial Neural Network with Simulated Annealing (ANN/SA)

<sup>۷</sup> Le

<sup>۸</sup> Stone Mastic Asphalt (SMA)

<sup>۱</sup> Lavenberg-Marquardt Algorithm (LMA)

<sup>۲</sup> Khuntia

<sup>۳</sup> Least Square Support Vector Machine (LS-SVM)

<sup>۴</sup> Flow value

<sup>۵</sup> Gene Expression Programming (GEP)

آموزش و یادگیری<sup>۱</sup> است. مجموعه داده حاصل شده از نتایج آزمایش‌ها، شامل ۹۶ داده ورودی بوده است که هر یک میانگین ۶ نمونه مشابه بوده است. دقت مدل ترکیب شده از این دو الگوریتم برابر با ۹۸٪ و دقت مدل شبکه عصبی مصنوعی تنها با داده‌های موجود برابر با ۹۴/۸٪ بوده است که تاثیر الگوریتم جدید را به خوبی نمایش داده است. مطابق نتایج، دمای انجام آزمایش موثرترین عامل در تعیین مدول دینامیکی مخلوط آسفالتی با استخوان بندی سنگدانه‌ای است [۶۲].

غنی زاده و همکاران در سال ۲۰۲۰ به پیش بینی درجه نرمی مخلوط آسفالتی از نتایج تست مارشال با روش دایره‌وارهای رگرسیونی تطبیقی چند متغیره، معروف به رگرسیون مارس<sup>۲</sup> پرداختند. این مدل به کاهش هزینه و زمان انجام آزمایش‌ها منجر شده است. دقت مدل توسعه داده شده بیش از ۹۶ درصد بوده است. پارامترهای ورودی این مدل عبارت است از درصد ریزدانه و درشت دانه مصالح سنگی، درصد قیر، درصد فضای خالی، درصد فضای خالی مصالح سنگی، مقاومت مارشال. پارامتر خروجی مدنظر، درجه نرمی بوده است. مجموعه داده این پژوهش که حاصل نتایج میرزا حسینی در سال ۲۰۱۱ است، شامل ۱۱۸ داده بوده است. طبق نتایج ارائه شده در این پژوهش، روش رگرسیون مارس عملکرد دقیق تری از الگوریتم‌های مبتنی بر ساختار ژنتیکی<sup>۳</sup>، الگوریتم بردار پشتیبان و رگرسیون حداقل مربعات داشته است [۶۳].

مقاومت کششی مخلوط آسفالتی، یکی از مهم ترین پارامترها در راستای پیش بینی ظهور ترک‌ها در مخلوط‌های آسفالتی است [۶۴]. عابد و همکاران در سال ۲۰۲۱ مطالعه ای در راستای مدلسازی سختی مخلوط‌های آسفالتی اصلاح شده با استفاده از آزمایش رئومتر تیر خمشی<sup>۴</sup> انجام دادند. دو دانه بندی مختلف در نظر گرفته شد. همچنین از قیر با درجه نفوذ ۴۰-۵۰ میلی متر استفاده شد. از دو نوع افزودنی اصلاح کننده استایرن بوتادین استایرن و نیز از پلی وینیل کلراید<sup>۵</sup> استفاده شد. محققین با کمک نرم افزار اس پی اس اس<sup>۶</sup> از یک

شبکه عصبی مصنوعی به منظور بررسی اثرات پنج عامل دما، زمان بارگذاری، درصد استایرن-بوتادین-استایرن، درصد پلی وینیل کلراید و نیز خیز وسط دهانه تیر بر سختی مخلوط استفاده کردند. در ساختار شبکه عصبی از یک لایه پنهان استفاده شد. داده‌ها نرمال سازی شد. دقت مدل، ۸۸/۶٪ است. در این مدل، خروجی شبکه عصبی عمر خستگی بوده است [۶۵].

در روش مکانیکی تجربی که به عنوان روش جدید طراحی روسازی‌ها مطرح است، خصوصیات مخلوط آسفالتی وابسته به قیر مانند پیرشدگی در نظر گرفته شده است. در این راستا یکی از مهم ترین ورودی‌های این روش مدول دینامیکی مخلوط آسفالتی است [۶۸-۶۶]. هوانگ<sup>۷</sup> و همکاران در سال ۲۰۲۱ به کمک روش های یادگیری ماشین به پیش بینی مدول دینامیکی مخلوط آسفالتی با بهبود رابطه ی ویتزک<sup>۸</sup> پرداختند. در آماده سازی مخلوط‌ها از چهار دانه بندی با بیشینه سایز اسمی ۱۹ میلی متر و چهار دانه بندی ۱۲/۵ میلی متر، دو نوع قیر و مجموعاً ۱۶ مخلوط آسفالتی استفاده شده است. طرح اختلاط مخلوط‌ها به روش سوپریو انجام شد. مقادیر مدول برشی قیر ( $G^*$ ) و زاویه فاز ( $\delta$ ) به طور تجربی در دماهای مختلف و فرکانس‌های مختلف با استفاده از تست رئومتر دینامیکی برشی حاصل شده است. آزمایش مدول دینامیکی آسفالت انجام شد. در این مطالعه از روش های درخت رگرسیون منفرد، جنگل تصادفی<sup>۹</sup> و الگوریتم جستجوی بهبود یافته حسگر سوسک<sup>۱۰</sup> برای پیش بینی هوشمند مدول دینامیکی استفاده شده است. بر اساس نتایج، دانه بندی تاثیر چندانی بر مدول دینامیکی نداشته است، اما مدول برشی قیر، زاویه فاز و خصوصیات حجمی قیر، به ترتیب دارای بیشترین اثرگذاری بر مقدار مدول دینامیکی بوده اند [۶۹].

ارزیابی سازه‌ای روسازی‌ها همواره از دو طریق آزمایش‌های مخرب یا غیرمخرب صورت گرفته است. محاسبه مدول لایه‌های روسازی آسفالتی، به طور سنتی از طریق محاسبات معکوس خیز اندازه گیری شده رویه روسازی انجام شده است. اما روش‌های مبتنی بر شبکه

<sup>۶</sup> SPSS

<sup>۷</sup> Huang

<sup>۸</sup> Witczak

<sup>۹</sup> Random Forest (RF)

<sup>۱۰</sup> Beetle Antenna Search (BAS)

<sup>۱</sup> Teaching Learning Based Optimization (TLBO)

<sup>۲</sup> Multivariate Adaptive Regression Spline (MARS)

<sup>۳</sup> Gene Expression Programming – Multi Expression Programming (GEP-MEP)

<sup>۴</sup> Bending Beam Rheometer (BBR)

<sup>۵</sup> PolyVinyl Chloride (PVC)

یادگیری ماشین پرداختند. پیش‌بینی عمق شیارشدگی با استفاده از داده‌های آزمایش شیارشدگی هامبورگ انجام شده‌است. از الگوریتم‌های رگرسیون بردار پشتیبان، گرادیان تقویتی<sup>۵</sup>، درخت اضافی<sup>۶</sup>، جنگل تصادفی و طبقه بندی ترکیبی برای پیش‌بینی عمق شیارشدگی و مقاومت کششی غیرمستقیم استفاده شده‌است. بر اساس معیار ضریب تعیین  $R^2$ ، روش درخت اضافی بهترین مدل را ایجاد کرد [۷۲].

گسترش و توسعه ساختار ترک مخلوط‌های آسفالتی با استفاده از منحنی‌های شکست قابل درک است. آزمایش‌های تعیین رفتار شکست مخلوط‌های آسفالتی با پیچیدگی‌هایی همراه بوده، در نتیجه استفاده از روش‌های جدیدتر بررسی شده‌است. غفاری و همکاران در سال ۲۰۲۲ با استفاده از روش‌های یادگیری ماشین به پیش‌بینی منحنی‌های مقاومت شکست مخلوط‌های آسفالتی اصلاح‌نشده و اصلاح‌شده با پودر لاستیک پرداختند. نمونه‌ها با دو نوع قیر دارای درجه عملکردی مختلف، مصالح سنگی آهکی و سیلیسی با دو دانه بندی، محدوده دمایی +۵ تا -۲۰ درجه سانتی گراد برای انجام آزمایش، درصد‌های مختلف پودر لاستیک ۰، ۵، ۱۰، ۱۵ و ۲۰٪، درصد‌های مختلف قیر ۴، ۵/۴ و ۵٪ در نظر گرفته شده‌است. آزمایش تیر با ترک لبه‌ای تحت خمش سه نقطه‌ای<sup>۷</sup> در راستای استخراج داده‌ها انجام شده‌است. دقت مدل‌های ساخته‌شده با روش‌های شبکه عصبی مصنوعی و ژنتیک به ترتیب ۹۶/۵٪ و ۸۷٪ بود. داده‌های ورودی شامل محدوده عملکردی دمایی قیر، حداقل دمای عملکردی قیر، درصد قیر مخلوط، درصد پودر لاستیک، دمای انجام آزمایش، زمان بارگذاری، بیشینه سائز اسمی مصالح سنگی و نوع مصالح سنگی (آهکی یا سیلیسی) است. خروجی مدل شامل انرژی تجمعی شکست و میزان گسترش طول ترک بوده‌است. داده‌ها از ۲۵۹ آزمایش تیر با ترک لبه تحت خمش سه نقطه‌ای حاصل شده‌است. اگر چه مدل ساخته‌شده با روش شبکه عصبی از روش ژنتیک بهتر بوده، ولی هر دو دقت بالایی داشته و قابل استفاده بودند. نتایج نشان داد که درصد قیر بیشتر منجر به اتلاف بیشتر انرژی شده‌است و مقاومت بالاتری

عصبی، روش‌های دقیق‌تری برای این منظور هستند. ژنگ<sup>۱</sup> و همکاران در سال ۲۰۲۱ به محاسبه مدول روسازی با محاسبات معکوس بوسیله شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک برای یک روسازی آسفالتی پرداختند. ورودی‌های این شبکه عصبی عبارت است از: مقادیر خیز اندازه گرفته‌شده از دستگاه نشست‌سنج وزنه‌ای<sup>۲</sup>، مقدار بارگذاری، ضخامت لایه‌ها، دمای سطح روسازی و دمای هوا و شاخص حلقه پسماند (منحنی نیرو-جابجایی). همچنین پیشنهاد شده‌است که مطالعات آتی دارای متغیرهای ورودی بیشتری اعم از بار چرخ، سرعت، ساختار روسازی و مصالح باشد. یک لایه پنهان برای مدل ایجاد شده‌است. در انجام آزمایش، سه میلیون بار عبور صورت گرفته است. آزمایش در یک فضای  $۹/۵۲۵ \times ۳/۷۵$  متری انجام شده‌است. در هر یک از لایه‌های روسازی با افزایش سیکل‌های بارگذاری یا با افزایش دما، مدول کاهش یافته‌است [۷۰].

همواره مدول دینامیکی به عنوان یکی از پارامترهای مهم در طراحی روسازی بوده است. پیش‌بینی غیرمستقیم مقادیر مدول دینامیکی به جای انجام مستقیم آزمایش‌ها، مزایای اقتصادی و زمانی زیادی به همراه داشته‌است. بهنود و گلفشانی<sup>۳</sup> در سال ۲۰۲۱، به پیش‌بینی مدول دینامیکی مخلوط آسفالتی با استفاده از روش‌های یادگیری ماشین پرداختند. دو مدل با استفاده از داده‌های حاصل از ۴۰۲۲ نمونه مخلوط آسفالتی ساخته شده‌است. مدل اول شامل پارامترهای دما، فرکانس، درصد فضای خالی مصالح سنگی، درجه عملکردی قیر و مدل دوم شامل پارامترهای دما، فرکانس، درصد فضای خالی مصالح سنگی، درجه عملکردی قیر، درصد قیر مخلوط، دمای بالای درجه عملکردی قیر، حجم قیر موثر، درصد روسازی آسفالتی باز یافتی بوده است. در این پژوهش از الگوریتم بهینه‌سازی جغرافیای زیستی<sup>۴</sup> مبتنی بر توزیع طبیعی جانوران در زیست‌بوم استفاده شده‌است. هر دو مدل توسعه داده‌شده با دقت بالای ۹۷٪ با داده‌های تجربی انطباق داشته‌است [۷۱].

رحمان و همکاران در سال ۲۰۲۱، به پیش‌بینی عمق شیارشدگی و نیز مقاومت کششی غیرمستقیم مخلوط آسفالتی به وسیله روش‌های

<sup>۵</sup> Gradient Boosting

<sup>۶</sup> Extra tree

<sup>۷</sup> Single-Edge Notched Beam (SENB)

<sup>۱</sup> Zhang

<sup>۲</sup> Falling weight Deflectometer (FWD)

<sup>۳</sup> Behnood & Golafshani

<sup>۴</sup> Biogeography-Based Optimization (BBO)

در هنگام ترک خوردگی پدید آمده است. مخلوط‌های دارای ۲۰٪ پودر لاستیک حتی در دماهای پایین ۲۰- درجه سانتی‌گراد خصوصیات خوبی از خود نشان داده است [۷۳].

یکی از دلایل بروز خرابی‌های زود هنگام در رویه‌های اجرا شده، بوجود آمدن تغییرات دمایی در مخلوط آسفالتی حین حمل و انتقال به موقعیت پروژه است. ونگ<sup>۱</sup> و همکاران در سال ۲۰۲۳ به ارزیابی تغییرات دمایی مخلوط آسفالتی حمل شده توسط کامیون پرداخته و دقت روش‌های توسعه داده شده را در مقابل آزمایش‌های میدانی صحت‌سنجی نمودند. روش نوین پیشنهاد شده از دو بخش سخت‌افزار و نرم‌افزار تشکیل شده بود. سخت‌افزارها شامل دوربین‌های مادون قرمز و چند حسگر اندازه‌گیری دما با طراحی اختصاصی بودند. بخش نرم‌افزاری که مدل‌های مختلف رگرسیون، ماشین بردار پشتیبان و تقویت گرادیان شدید<sup>۲</sup> را در بر می‌گرفت، دماهای میان نقطه تماس مخلوط با محفظه کامیون و نقاط مرکزی مخلوط را پیش‌بینی می‌نمودند. نتایج نشان داد که روش توسعه داده شده در شرایط توقف کامیون، در صورتی که سرعت باد در نظر گرفته شود، عملکرد قابل قبولی داشته است. همچنین در شرایط حرکت کامیون، عوامل مختلفی از جمله سرعت رانندگی، دمای محیط، موقعیت قرارگیری حسگرها و لایه‌های عایق‌بندی باید در روابط اعمال شود [۷۴].

آن دسته از ورودی‌های مدل‌های هوش مصنوعی که مربوط به قیر بوده است در شکل ۲ نشان داده شده و فراوانی آن‌ها با یکدیگر مقایسه


شده است. بر این اساس پارامترهای درصد قیر و درجه عملکردی قیر که داده‌های آن‌ها به ترتیب در ۷ و ۳ پژوهش مورد استفاده قرار گرفته، بیشترین فراوانی را نسبت به سایر پارامترها یعنی مدول برشی قیر، حجم موثر قیر، خصوصیات حجمی قیر و درصد فضای پر شده با قیر داشته اند.

آن دسته از پارامترهای مربوط به مخلوط یا نمونه آسفالتی ساخته شده که به عنوان ورودی به مدل داده شده‌اند، از نظر فراوانی در شکل ۳ مقایسه شده‌اند. بر این اساس، درصد فضای خالی سنگدانه و درصد فضای خالی مخلوط که در ۳ مطالعه به عنوان ورودی مدل استفاده شده‌اند، بیشترین فراوانی را داشته‌اند.

در نهایت، پارامترهای مربوط به شرایط آزمایش و برخی مشخصات نمونه در شکل ۴ از نظر سهم آن‌ها در ادبیات موضوع با یکدیگر مقایسه شده‌اند. بر این اساس، دما و زمان بارگذاری بیشترین سهم را داشته‌اند.


<sup>۲</sup> Extreme Gradient Boosting (XGboost)

<sup>۱</sup> Wang




شکل ۲: سهم پارامترهای مرتبط با قیر که به مدل‌های هوش مصنوعی وارد شده‌اند.  
(مقایسه میان ۱۶ مطالعه علمی با هدف پیش‌بینی خصوصیات مخلوط آسفالتی)

Fig. 2. The share of parameters characterizing asphalt in the performed AI-assisted analyses (analyzing 16 different studies aimed at predicting asphalt mixture characteristics)



شکل ۳: مقایسه سهم پارامترهای وارد شده به مدل‌های هوش مصنوعی در ارتباط با خصوصیات نمونه یا مخلوط آسفالتی  
(مقایسه میان ۱۶ مطالعه علمی با هدف پیش‌بینی خصوصیات مخلوط آسفالتی)

Fig. 3. Comparing the share of parameters characterizing asphalt mixture or pavement sample in the performed AI-assisted analyses (analyzing 16 different studies aimed at predicting asphalt mixture characteristics)



شکل ۴: مقایسه سهم پارامترهای واردشده به مدل‌های هوش مصنوعی در ارتباط با شرایط اجرای آزمایش و نمونه آزمایش شده (مقایسه میان ۱۶ مطالعه علمی با هدف پیش‌بینی خصوصیات مخلوط آسفالتی)

Fig. 4. Comparing the share of parameters related to the experiment or sample conditions in the performed AI-assisted analyses (analyzing 16 different studies aimed at predicting asphalt mixture characteristics)

تحلیل مطالعات این بخش نشان می‌دهد که پارامترهای عمر خستگی، مدول دینامیکی و نیز پارامترهای تست مارشال در مطالعات مختلفی تحلیل شده و نتایج آن‌ها با یکدیگر قابل مقایسه است. هدف از مدل‌های ساخته‌شده در این پژوهش‌ها، جایگزین نمودن مدلسازی کامپیوتری بر آزمایش‌های زمان‌بر و هزینه‌بر بوده است. مطالعات تاپکین در سال ۲۰۱۴ [۵۸] و عابد و همکاران در سال ۲۰۲۱ [۶۵] هر دو بر پیش‌بینی عمر خستگی مخلوط آسفالتی با استفاده از شبکه عصبی متمرکز بوده است که در مطالعه اول از خاکستر بادی و در مطالعه دوم از استایرن-بوتادین-استایرن و همچنین پلی‌وینیل کلراید به عنوان افزودنی استفاده شده است. بعلاوه، در این دو مطالعه از روش‌های متفاوتی برای تخمین عمر خستگی استفاده شده است: در مطالعه اول نمونه‌ها طبق روش مارشال آماده‌سازی و سپس بر اساس آزمون کشش غیرمستقیم آزمایش شده‌اند و در مطالعه دوم، نمونه‌ها با استفاده از رئومتر تیر خمشی مورد آزمایش قرار گرفته‌اند. باتوجه به تفاوت آزمایش‌های به‌کارگرفته‌شده، ورودی‌های مدل‌های ساخته نیز متفاوت بوده است. دقت پیش‌بینی در مطالعه تاپکین در سال ۲۰۱۴ [۵۸] برابر با ۹۲/۵٪ بود که نسبت به مطالعه عابد و همکاران در سال ۲۰۲۱ [۶۵] حد ۴٪ بالاتر بوده است. پیشنهاد می‌شود در مطالعات آینده، دیگر روش‌های پیش‌بینی عمر خستگی نیز مورد مطالعه قرار گرفته و عملکرد سایر مدل‌های یادگیری ماشین در پیش‌بینی این متغیر بررسی شود. همچنین باتوجه به اینکه در ۲ مطالعه اشاره‌شده از نرم‌افزارهای متلب و اس‌پی‌اس‌اس برای مدلسازی استفاده شده است، پیشنهاد می‌شود در مطالعات آینده، مدلسازی با به‌کارگیری زبان پایتون و کتابخانه‌های مورد نیاز هر مدل ارتقاء داده شود.

مدول دینامیکی متغیر دیگری است که در مطالعات مختلف مورد بررسی قرار گرفته است. لی و همکاران در سال ۲۰۲۰ [۶۲] و هوانگ و همکاران در سال ۲۰۲۱ [۶۹] مدول دینامیکی را برای مخلوط‌های آسفالتی متفاوتی بر مبنای روش آشتو تعیین و سپس با استفاده از مدل‌های یادگیری ماشین بهینه‌سازی شده پیش‌بینی نمودند. در مطالعه اول مخلوط آسفالتی با استخوان‌بندی سنگدانه‌ای به همراه افزودنی‌هایی از جمله پلیمر، الیاف سلولزی و ساسوبیت مورد آزمایش قرار گرفته و سپس از الگوریتم شبکه عصبی مصنوعی بهینه‌شده برای مدلسازی استفاده شده است. در مطالعه دوم مخلوطی با قیر حاوی

استایرن-بوتادین-استایرن با طرح اختلاط حاصل از سوپریو در نظر گرفته شده و سپس مدل جنگل تصادفی بهینه‌شده با الگوریتم جستجوی حسگر سوسک برای مدلسازی به‌کار گرفته شده است. از تمایزات دیگر این دو مطالعه می‌توان به متغیرهای پیش‌بینی‌کننده واردشده به مدل اشاره نمود که در مطالعه اول محدود به دما و فرکانس بوده و در مطالعه دوم شامل مدول برشی قیر، زاویه فاز، خصوصیات حجمی قیر و مشخصات مصالح سنگی بوده است. جالب توجه است که شاخص انحراف جذر میانگین مربعات برای هر دو مدل برابر با ۱۸۰ مگاپاسکال بوده است. مطالعه دیگری نیز جهت پیش‌بینی مدول دینامیکی توسط بهنود و گلفشانی در سال ۲۰۲۱ [۷۱] انجام شده که در آن، متغیرهای ورودی مدل ترکیبی از دو مطالعه قبلی [۶۲] و [۶۹] به جز مقدار زاویه فاز بوده است. در این مطالعه که بر مبنای یک مجموعه داده از مشخصه‌های مخلوط آسفالتی حاوی تراشه آسفالتی انجام شده، از الگوریتم بهینه‌سازی جغرافیای زیستی برای مدلسازی بهره گرفته شده است. تعداد داده‌های استفاده‌شده در این مطالعه برابر با حدود ۴ هزار ردیف بوده که در قیاس با دو مطالعه اشاره‌شده (حاوی ۹۶ و ۱۴۰ ردیف داده) به‌طور قابل توجهی افزایش یافته است. در این مدل، شاخص انحراف جذر میانگین مربعات برای پیش‌بینی مدول به حدود ۰/۰۱ مگاپاسکال کاهش یافته است. بهبود قابل توجه خطای مدل نسبت به مطالعات قبل نشان از اهمیت به‌کارگیری داده‌های کافی برای آموزش مدل و همچنین استفاده از ورودی‌های موثر جهت پیش‌بینی است. باتوجه به تفاوت داده‌های استفاده‌شده در مطالعات، پیشنهاد می‌شود در مطالعات پیش رو مدل‌های مختلف یادگیری ماشین بر مجموعه داده‌های مشترک و متغیرهای ورودی یکسان توسعه داده شود تا امکان ارزیابی عملکرد مدل‌ها در شرایط یکسان فراهم گردد.

در نهایت، چندین مطالعه جهت پیش‌بینی پارامترهای مارشال منتشر شده است [۵۶، ۶۹، ۶۳]. باتوجه به محدودیت داده‌ها (حدود ۱۰۰ ردیف داده) و مدل‌های استفاده‌شده (شبکه عصبی مصنوعی و رگرسیون مارس) برای پیش‌بینی مقاومت مارشال، پیشنهاد می‌شود در مطالعات پیش رو از مجموعه داده‌های بزرگ‌تر و دیگر مدل‌های یادگیری ماشین برای پیش‌بینی مقاومت مارشال استفاده شود.

#### ۳-۴- تشخیص خرابی‌های سطح روسازی

ترک‌های پنهان به دلیل پتانسیل ایجاد ترک‌های انعکاسی در آینده و مشاهده‌نشدن در حین عملیات نگهداری، از معضلات ویژه در مدیریت روسازی راه محسوب می‌شود. همواره یکی از چالش‌های محققین، تشخیص این نوع از خرابی‌ها بوده‌است اما با استفاده از هوش مصنوعی این امکان بیش از پیش فراهم شده‌است. تانگ<sup>۱</sup> و همکاران در سال ۲۰۱۷، به مطالعه بر کاربرد شبکه‌های عصبی در پردازش تصاویر رادار نفوذی زیرزمینی<sup>۲</sup> پرداختند. این مطالعه در کشور چین انجام شده‌است و برای تصویربرداری از سطح روسازی‌ها از دستگاه رادار نفوذی زیرزمینی ساخت چین استفاده شده‌است. مشکل تصاویر رادار نفوذی زیرزمینی آن است که عرض ترک‌های پنهان به درستی قابل تشخیص نبوده‌است و باید برای محاسبه مقدار واقعی از روابط تجربی استفاده کرد. در این مطالعه از شبکه عصبی پیچشی که جزء شبکه‌های عصبی عمیق است، استفاده شده‌است. برای ساخت مجموعه داده تشخیص ترک، مجموعه‌ای شامل ۲,۲۰۰ تصویر از کل ۶,۸۴۲ تصویر موجود انتخاب شده و برای آموزش مدل به کار گرفته شده‌است. ساختار شبکه تشخیص ترک در این مطالعه از ۲ لایه پیچشی، ۲ لایه نمونه‌گیری فرعی، ۲ لایه ارتباطی و نهایتاً لایه خروجی تشکیل شده است [۱۵].

تشخیص خرابی توسط کاربران متخصص، زمان‌بر، گران و غیرمنطقی است. به‌منظور برداشت داده‌های تمامی شبکه راه در زمان مطلوب، نیاز به سامانه‌ای جهت تشخیص خرابی‌ها به صورت خودکار وجود دارد که افراد غیرمتخصص نیز امکان اجرای آن را داشته باشند. تانگ و همکاران در سال ۲۰۲۰، با استفاده از رادار نفوذی زیرزمینی که روشی غیرمخرب به‌شمار می‌رود، به تشخیص خرابی‌های روسازی پرداختند. در این روش، داده‌های رادار نفوذی به عنوان ورودی به دو شبکه داده شده‌است. شبکه‌ها مدل‌های یادگیری عمیق به شمار می‌روند. به منظور آموزش شبکه‌ها از پایگاه داده‌ی حاصل از ارزیابی یک چهارراه استفاده شده‌است. در انتخاب داده‌ها، فرکانس‌های ۳۰۰

۶۰۰ و ۹۰۰ مگاهرتز بررسی شدند و تعداد ۲۵۶، ۳۸۴ و ۵۱۲ نمونه از چهارراه مورد مطالعه برداشت شد. روش تشخیص خرابی‌ها بر رفتار غیرمعمول سیگنال‌های ارسالی نهفته‌است. در این مدل چندین لایه مختلف از نوع یاخته عصبی چندلایه، لایه ادغام متوسط جامع<sup>۳</sup> و تابع بیشینه هموار<sup>۴</sup> وجود داشته و تشخیص خرابی مبتنی بر خروجی لایه تابع بیشینه هموار و سه لایه رگرسیونی بوده‌است. نتایج نشان داده است دقت این روش معادل ۸۵/۱۷٪ بوده‌است [۷۵]. می و گل<sup>۵</sup> در سال ۲۰۲۰، در راستای هوشمندسازی سیستم حمل‌ونقل، مطالعه‌ای با موضوع نظارت خودکار بر ترک‌های روسازی انجام دادند. داده‌های این مطالعه شامل تصاویر برداشت‌شده از سطح راه به‌وسیله یک دوربین ورزشی تجاری گوپرو<sup>۶</sup> بود که پشت یک خودرو نصب گردیده بود. تصویربرداری در سرعت ۴۰ تا ۸۰ کیلومتر بر ساعت و با نرخ ۲۴۰ فریم بر ثانیه انجام شده‌است. در این مطالعه از یک شبکه عصبی دارای ۱۲۱ لایه واپیچش<sup>۷</sup> به عنوان مولد و نیز از یک شبکه ۵ لایه کاملاً پیچشی به عنوان تفکیک‌کننده استفاده شده‌است. مدل توسعه داده‌شده با عنوان کان‌کرک<sup>۸</sup> نام‌گذاری گردید که نتایج بهتری نسبت به روش‌های موجود داشته‌است. در این مطالعه فقط به تشخیص ترک پرداخته شده‌است و راه حلی برای تعیین ابعاد ترک‌ها توسعه داده نشده‌است [۷۶].

گائو<sup>۹</sup> و همکاران در سال ۲۰۲۰، مطالعه‌ای در راستای تشخیص خودکار خرابی‌های روسازی با استفاده از رادار نفوذی زیرزمینی با بهره‌گیری از الگوریتم یادگیری عمیق انجام دادند. الگوریتم یادگیری عمیق به کار گرفته شده در این مطالعه، یک شبکه عصبی پیچشی مبتنی بر ناحیه سریع‌تر<sup>۱۰</sup> بوده‌است. مجموعه داده این مطالعه ۳,۷۸۵ تصویر رادار نفوذی زیر زمینی با وضوح ۵۱۲ × ۵۱۲ پیکسل بوده‌است. در این مجموعه داده سه نوع معضل ترک‌های انعکاسی، جمع‌شدگی آب روی سطح زمین و نیز نشست‌های ناگهانی مورد بررسی قرار گرفت. شبکه عصبی این مطالعه دارای دو خروجی است. خروجی لایه تابع بیشینه هموار برای تشخیص و پیش‌بینی طبقه‌بندی خرابی مورد

<sup>۶</sup> GoPro

<sup>۷</sup> Deconvolution

<sup>۸</sup> ConCrack

<sup>۹</sup> Gao

<sup>۱۰</sup> Faster R-CNN

<sup>۱</sup> Tong

<sup>۲</sup> Ground Penetrating Radar (GPR)

<sup>۳</sup> Global Average Pooling (GAP)

<sup>۴</sup> Softmax

<sup>۵</sup> Mei & Gul



استفاده قرار گرفته است و خروجی لایه رگرسیونی برای مکان‌یابی محل خرابی به وسیله تصاویر رادار نفوذی مورد استفاده قرار گرفته است [۷۷].

یکی از عوامل موثر بر عملکرد و دوام روسازی‌ها نحوه توزیع سنگدانه‌ها درون روسازی است. تشخیص غیرمخرب این پارامتر ارزش بسیار بالایی در حفظ زمان و هزینه به دنبال خواهد داشت. دان<sup>۱</sup> و همکاران در سال ۲۰۲۱ به بررسی این موضوع با استفاده از یادگیری عمیق پرداختند. در این مطالعه نمونه‌های گرفته‌شده از سطح روسازی‌ها تحت آزمایش قرار گرفت. همچنین اطلاعات جانبی سطح نمونه‌ها به وسیله یک شبکه عصبی مصنوعی تجزیه و تحلیل شد. مدل‌های شناسایی‌کننده ایجادشده در این مطالعه مبتنی بر تصاویر بدست آمده از تلفن‌های همراه و کامپیوترهای شخصی بوده است. در این مطالعه ابتدا به تشخیص سنگدانه‌ها از تصاویر با استفاده از شبکه عصبی پرداخته شده است، سپس ابعاد حفرات و سنگدانه‌ها محاسبه شده و در نتیجه پارامترهایی مانند نسبت ابعاد، گردی و نیز تحلیل ضعف مخلوط بدست آمده است. برای داشتن تصویری از سطح جانبی مخلوط، تصویربرداری از زوایای مختلف صورت گرفته است. همچنین الگوریتم یونت پلاس پلاس<sup>۲</sup> از حوزه تشخیص تصاویر پزشکی به این مبحث وارد شده است [۷۸].

آریا و همکاران در سال ۲۰۲۱، با هدف تشخیص خرابی‌های راه، مطالعه‌ای بر تصاویر گرفته شده توسط تلفن‌های همراه هوشمند انجام دادند. این مطالعه با استفاده از یادگیری عمیق صورت گرفته است. در این تحقیق، اطلاعاتی پیرامون مجموعه تصاویر آردی‌دی<sup>۳</sup> ۲۰ با بیش از ۳۱,۰۰۰ نمونه خرابی از کشورهای ژاپن، هند و جمهوری چک، بیان شده است. ترک‌های خستگی (پوست‌سوسماری)، ترک‌های طولی، ترک‌های عرضی و چاله‌ها خرابی‌های مد نظر در این مجموعه بوده است. تصاویر به وسیله تلفن همراه متصل به یک خودرو و با ظرفیت ثبت تصاویر در حرکت با سرعت ۴۰ کیلومتر بر ساعت و ثبت تصویر در هر ثانیه جمع‌آوری شده‌اند [۷۹].

ژنگ<sup>۴</sup> و همکاران در سال ۲۰۲۱، با استفاده از شبکه عصبی پیچشی به تشخیص خرابی‌های روسازی در مونترال کانادا پرداختند. هدف از

این مطالعه، تشخیص خرابی‌های روسازی راه به وسیله یک روش داده‌برداری کم‌هزینه ویدئویی بوده است. در این مطالعه، خرابی‌ها به ترک‌های طولی یا خطی، ترک‌های شبکه‌ای، ترک‌های خستگی، چاله‌ها، خرابی‌های محل وصله و علامت‌گذاری روی سطح روسازی تقسیم بندی شده‌اند. مجموعه تصاویر در دسترس شامل ۲,۱۰۵ تصویر از دوربین ارزان‌قیمت نصب‌شده بر خودروی در حال حرکت بوده است. دقت تشخیص مدل ارائه شده با توجه به تصاویر برداشت‌شده از سطح روسازی‌های مونترال، ۸۳/۸٪ است [۸۰].

گوآن<sup>۵</sup> و همکاران در سال ۲۰۲۱، مطالعه‌ای در راستای تشخیص خودکار خرابی‌های سطح روسازی انجام دادند که خرابی‌ها در سطح پیکسل شناسایی می‌شدند. در این راستا از تصاویر رنگی و الگوریتم‌های یادگیری عمیق، استفاده شد. محیط دانشگاه چانگ آ برای برداشت تصاویر به دلیل جاده‌های آسفالتی و عاری از آلودگی، مناسب تشخیص داده شده است. در این مطالعه برداشت تصاویر توسط دوربین نصب‌شده روی خودرو صورت گرفته است. در این مطالعه از تکنیک‌های ساختار از حرکت<sup>۶</sup>، فن‌آوری تبدیل تصاویر دوبعدی برداشت‌شده به تصاویر دارای عمق و سه‌بعدی، استفاده گردید. به منظور سهولت محاسبات از یک شبکه ساده یونت استفاده شد. این شبکه با ۱۸۰ تکرار آموزش داده شده است. خرابی‌های تشخیص داده شده توسط این روش شامل چاله‌ها و ترک‌ها بود. عمق ترک‌ها و نیز عمق چاله‌های محاسبه شده توسط این مدل دقت بسیار خوبی نسبت به مقادیر واقعی داشته است. همچنین حجم چاله‌های تشخیص داده شده نیز محاسبه شده است [۸۱].

احسانی و همکاران در سال ۲۰۲۲ از الگوریتم‌های شبکه عصبی مصنوعی و جنگل تصادفی برای پیش‌بینی بروز اختلاف ارتفاع میان دال‌های روسازی بتنی استفاده کردند. در این پژوهش از برنامه‌نویسی عدصیح دوهدفه جهت کاهش تعداد ورودی‌های مدل شبکه عصبی استفاده گردید که منجر به کاهش ۳۲ ورودی مدل به ۱۹ ورودی شد. از مقایسه مدل‌های توسعه داده‌شده دریافت شد که عملکرد شبکه عصبی بهتر از مدل‌های جنگل تصادفی بوده است. در نهایت تحلیل حساسیت بر پارامترهای مختلف اجرا شد. مهم‌ترین

<sup>۴</sup> Zhang

<sup>۵</sup> Guan

<sup>۶</sup> Structure from Movement (SFM)

<sup>۱</sup> Dan

<sup>۲</sup> Unet++

<sup>۳</sup> RDD20

پارامترهای ورودی مدل جنگل تصادفی عبارت بودند از ضخامت اساس، ترافیک عبوری، عمر روسازی، متوسط روزهایی در سال که دمای هوا بالاتر از ۳۲ درجه سانتی‌گراد بوده و تعداد روزهایی که میزان بارش بیشتر از ۱۲/۷ میلی‌متر بوده است [۸۲].

### ۳-۵- طبقه بندی خرابی‌های سطحی

بررسی میدانی و چشمی روسازی در راستای تشخیص و دسته بندی انواع خرابی‌ها، زمان‌بر و پرهزینه است و با پیشرفت تجهیزات در علوم مختلف می‌توان این کار را به‌صورت نیمه‌خودکار یا خودکار انجام داد. لی<sup>۱</sup> و همکاران در سال ۲۰۱۹، به شناسایی و طبقه‌بندی خودکار ترک‌های روسازی بر اساس تصاویر سه‌بعدی روسازی پرداختند. پس از ساخت مدل شناسایی، با استفاده از اطلاعات ۲۰۰ روسازی، دقت و بهره‌وری مدل مورد بررسی قرار گرفت. نتایج این روش با استفاده از آزمون‌های تی و اف<sup>۲</sup> نسبت به مقادیر واقعی مقایسه شد که دقت‌های حاصل شده به ترتیب برابر با ۸۸/۳۸٪ و ۹۰/۶۸٪ بودند؛ پس بهره‌وری این روش اثبات شده است [۸۳].

### ۳-۶- پیش‌بینی مقادیر شاخص‌های عملکردی رویه

کاربرد هوش مصنوعی در ارزیابی، پیش‌بینی و برنامه‌ریزی نگهداری و تعمیرات روسازی مورد بررسی قرار گرفته است. ارزیابی وضعیت روسازی و محاسبه شاخص‌های عملکردی آن در راستای اجرای بهسازی اجتناب‌ناپذیر است. در این راستا استفاده از هوش مصنوعی و روش‌های عددی با هدف کاهش زمان و هزینه لازم مورد توجه محققین بوده است.

فخری و دزفولیان در سال ۲۰۱۹، به ارزیابی سازه روسازی بر اساس شاخص ناهمواری و خرابی سطحی با استفاده از شبکه عصبی پرداخت. در این مطالعه تلاش شد تا بین شاخص بین‌المللی ناهمواری<sup>۳</sup> و شاخص ارزیابی و رتبه‌بندی سطح<sup>۴</sup> با حوضچه خیز حاصل از آزمون نشست‌سنج وزنه‌ای ارتباط معناداری برقرار شود. پایگاه داده این مطالعه از ۳۱۸ قطعه راه از شهرهای کرمانشاه و ایلام در کشور ایران برداشت شده است [۸۴].

کایا<sup>۵</sup> و همکاران در سال ۲۰۲۰، عملکرد روسازی و پیش‌بینی عمر باقی‌مانده سیستم‌های روسازی مرکب و انعطاف‌پذیر را مورد بررسی قرار دادند. در این مطالعه روش‌های آماری و روش‌های مبتنی بر هوش مصنوعی، مقایسه شد. عملکرد روش‌های هوش مصنوعی (شبکه عصبی مصنوعی) در بهترین حالت تا دقت برازش ۹۹/۱٪ و روش‌های آماری تا دقت برازش ۹۶/۶٪ مشاهده شده است. ورودی مدل‌های آماری و شبکه عصبی ساخته شده عبارت است از ضخامت لایه آسفالتی، ترافیک، سن روسازی، شاخص ناهمواری یک و دو ساله روسازی. شاخص بین‌المللی ناهمواری به عنوان خروجی در هر سال مطلوب بوده است. شبکه عصبی ساخته شده دارای یک لایه پنهان در نظر گرفته شده است. در این مطالعه پنج شبکه عصبی برای پیش‌بینی پارامترهای شیارشدگی، ترک‌های طولی، ترک‌های عرضی و شاخص ناهمواری به دو روش ایجاد شده است [۸۵].

گانگ<sup>۶</sup> و همکاران در سال ۲۰۱۸، با استفاده از الگوریتم جنگل تصادفی به پیش‌بینی شاخص بین‌المللی ناهمواری پرداختند. متغیرهای ورودی این مدل شامل خرابی‌های اندازه‌گیری شده، ترافیک، شرایط آب‌وهوایی، شرایط نگهداری و داده‌های سازه روسازی است. مدل جنگل تصادفی به وسیله اطلاعات ۱۱،۰۰۰ نمونه برداشت شده از مجموعه داده عملکرد بلندمدت روسازی توسعه داده شده است. دقت تعیین شاخص بین‌المللی ناهمواری برابر با ۹۵٪ بوده است. نتایج نشان داد که ترک‌های عرضی، ترک‌های خستگی، ترک‌های بلوکی، شیار افتادگی، عمر روسازی و بارندگی سالانه، تاثیر زیادی بر شاخص بین‌المللی ناهمواری داشته است. همچنین ترک‌های طولی، ترک‌های لبه و چاله‌ها و صیقلی بودن مصالح تاثیر کمی بر شاخص بین‌المللی ناهمواری داشته است. مدل توسعه داده شده می‌تواند در روش طراحی مکانیکی-تجربی روسازی برای پیش بینی غیرخطی شاخص بین‌المللی ناهمواری مورد استفاده قرار گیرد [۸۶].

<sup>۴</sup> Pavement Surface Evaluation and Rating (PASER)

<sup>۵</sup> Kaya

<sup>۶</sup> Gong

<sup>۱</sup> Li

<sup>۲</sup> T and f tests

<sup>۳</sup> International Roughness Index (IRI)

صورتی فر و لواسانی در سال ۲۰۲۰، به پیش‌بینی مدل خرابی روسازی آسفالتی با استفاده از الگوریتم شبکه عصبی مصنوعی پرداختند. معیار مورد نظر شاخص بین‌المللی ناهمواری بوده‌است. آن‌ها در این مطالعه از پایگاه داده عملکرد بلندمدت روسازی استفاده کردند. اطلاعات برداشت‌شده متعلق به قطعات GPS-1 و GPS-2 بود. در این مطالعه از الگوریتم شبکه عصبی پس‌انتشار استفاده شده‌است. در شبکه عصبی توسعه داده‌شده در راستای پیش‌بینی شاخص بین‌المللی ناهمواری از یک لایه پنهان استفاده شده‌است. همچنین نتایج حاصل از شبکه عصبی مصنوعی با نتایج مدلسازی رگرسیونی مقایسه شده و مشخص گردید شبکه عصبی دقت بالاتری ارائه داده است [۸۷].

بشار و همکارش در سال ۲۰۲۱، به بررسی روش‌های یادگیری ماشین در راستای پیش‌بینی شاخص ناهمواری سطح راه پرداختند. در این تحقیق، مدل‌های ساخته‌شده به وسیله الگوریتم‌های شبکه عصبی مصنوعی، جنگل تصادفی و ماشین بردار پشتیبان مورد بررسی قرار گرفت. ۲۰ مطالعه از سال‌های ۲۰۰۱ تا ۲۰۲۰ انتخاب شده و تحلیل جزئیات روی آن‌ها انجام شده‌است. در نتیجه این مطالعه، روش جنگل تصادفی با دقت ۹۹/۵٪ به عنوان دقیق‌ترین روش شناخته شده‌است. شبکه‌های عصبی نیز با دقت ۹۳٪ برای طیف وسیعی از نمونه‌ها مناسب بوده‌است. شبکه عصبی توسعه داده‌شده در این مطالعه دارای یک لایه پنهان است. دقت مدل بردار پشتیبان در پیش‌بینی ۹۱/۶٪ است. تعداد حداقل نمونه در راستای توسعه مدل پیش‌بینی با دقت مناسب، ۵۰ برابر تعداد متغیر ورودی توصیه شده است [۸۸].

عیسی و همکاران در سال ۲۰۲۱، به پیش‌بینی شاخص وضعیت روسازی با استفاده از شبکه عصبی مصنوعی پرداختند. مدل‌سازی با داده‌های مرتبط با شاخص وضعیت روسازی برای ۳۴۸ قطعه از ۱۰ راه در شهر نابلس فلسطین انجام شده‌است. در این شبکه عصبی از یک لایه پنهان برای محاسبات استفاده شده‌است. متغیرهای ورودی

این شبکه عصبی، خرابی‌های متعددی مانند انواع ترک‌خوردگی‌ها، لکه‌گیری‌ها، تغییرات سطحی، شن‌زدگی، قیرزدگی و خرابی‌های مقطعی مانند افتادگی شانه راه هستند. نتایج نشان داد که شبکه عصبی مصنوعی توان پیش‌بینی شاخص عملکرد روسازی با دقت بیش از ۹۹٪ را دارد. همچنین مشخص شد که همبستگی کمی بین خرابی و شاخص وضعیت روسازی وجود دارد [۸۹].

قدرت‌آبادی و همکاران در سال ۲۰۲۵، به پیش‌بینی شاخص بین‌المللی ناهمواری با استفاده از مدل‌های جنگل تصادفی و همچنین ماشین بردار پشتیبان با توابع مرکزی خطی، شعاعی و چندجمله‌ای پرداختند. از نوآوری‌های این پژوهش اجرای پیش‌بینی برای مقادیر شاخص در طولانی‌مدت یا همان تغییرات شاخص در طول بازه چندساله و نیز در کوتاه‌مدت یا همان تغییر دفعی شاخص به سبب اجرای عملیات نگهداری بود. ورودی‌های مدل‌های توسعه داده‌شده جهت پیش‌بینی مقدار شاخص بین‌المللی ناهمواری شامل متغیرهای مختلفی بوده‌است، از جمله: عمر روسازی، ترافیک سنگین متوسط سالیانه روزانه، میزان بار هم‌ارز محور منفرد، مقدار اولیه شاخص، میزان بارندگی، دما، رطوبت، شاخص انجماد، ضخامت رویه، ضخامت اساس و ضخامت زیراساس. بعلاوه، ضخامت روکش‌های نازک و ضخیم و اسلاری سیل نیز در کنار ضخامت تراش رویه به‌عنوان مشخصه‌های واردشده به مدل در نظر گرفته شدند تا مقدار شاخص پس از این عملیات پیش‌بینی شود. از دیگر نوآوری‌های این پژوهش، پیس‌بینی تغییرات متغیرهای آب‌وهوایی ورودی مدل با استفاده از روش خودرگرسیون میانگین متحرک ادغام‌شده فصلی (ساریماس) بود. مدل‌های جنگل تصادفی به بالاترین دقت (۸۰٪ - ۹۶٪) دست یافتند [۹۰].

<sup>۱</sup> Seasonal AutoRegressive Integrated Moving Average (SARIMA)

چن<sup>۱</sup> و همکاران در سال ۲۰۲۵ به پیش‌بینی مقدار شاخص بین‌المللی ناهمواری بر اساس مدل شبکه عصبی فیزیک‌آگاه یا مبتنی بر فیزیک<sup>۲</sup> پرداختند. در این نوع شبکه عصبی، از مفاهیم اولیه یا قوانین فیزیک برای آموزش شبکه عصبی استفاده می‌شود. به‌منظور توسعه مدل، ۱،۲۸۷ ردیف داده از پایگاه داده عملکرد بلندمدت روسازی انتخاب گردید که شامل داده‌های ۹۹ قطعه روسازی از ۲۰ ایالت مختلف آمریکا در طی سال‌های ۱۹۹۵ الی ۲۰۰۷ بود. اطلاعات مربوط به سازه، وضعیت رویه، اقلیم، ترافیک، مصالح و پیشینه نگهداری برای توسعه دو مدل شبکه عصبی مصنوعی و شبکه عصبی فیزیک‌آگاه استفاده شد. داده‌های ۸۴ قطعه برای آموزش و صحت‌سنجی و داده‌های ۱۵ قطعه برای تست مدل‌ها انتخاب گردید. مقایسه عملکرد دو مدل نشان داد که بهره‌گیری از مدل ارتقاءیافته شبکه عصبی می‌تواند منجر به افزایش دقت پیش‌بینی به میزان ۴٪ و ۲۶/۰۸٪، به‌ترتیب در پیش‌بینی‌های ۱ و ۱۲ ساله بشود [۹۱].

یزدی و دهناد در سال ۲۰۲۵ داده‌های مرتبط با ۶ شاخص و خرابی روسازی شامل متوسط عمق بافت درشت، مساحت ترک خطی، طول ترک خطی، میزان برهنگی سنگدانه، عمق شیارشدگی و همچنین متوسط شاخص بین‌المللی ناهمواری را از مسیر مشخصی در استان قم برداشت نموده و هر شاخص یا متغیر را براساس مجموعه شاخص‌ها یا متغیرهای دیگر پیش‌بینی نمودند. روش حذف بازگشتی ویژگی‌ها<sup>۳</sup> به‌عنوان یکی از تکنیک‌های کاهش ابعاد با هدف حذف ورودی‌های اضافی مدل استفاده شد. به‌کارگیری این روش باعث کاهش پیچیدگی مدل، بهبود تعمیم‌پذیری و جلوگیری از بیش‌برازش<sup>۴</sup> می‌شود. در این راستا از طیف گسترده‌ای از مدل‌های یادگیری ماشین شامل جنگل تصادفی، تقویت گرادیان، رگرسیون

بردار پشتیبان، نزدیک‌ترین همسایگی کی، تقویت شدید گرادیان، ماشین سبک تقویت گرادیان و رگرسیون خطی استفاده شده‌است. بهترین عملکرد توسط مدل جنگل تصادفی به اجرا گذاشته شد مساحت و طول ترک را به‌ترتیب با ضرایب تعیین ۸۲/۴٪ و ۸۱٪ پیش‌بینی نمود. از نوآوری‌های این پژوهش استفاده از توضیحات افزودنی شیلی (تحلیل شپ)<sup>۵</sup> به‌عنوان یکی از تکنیک‌های هوش مصنوعی توضیح‌پذیر<sup>۶</sup> بود. به‌عنوان نمونه تحلیل شپ نشان داد که برهنگی سنگدانه بیشترین تاثیر را از مقادیر متوسط عمق بافت درشت پذیرفته‌است. همچنین نشان داده شد که موثرترین متغیرها در پیش‌بینی متوسط شاخص بین‌المللی ناهمواری، برهنگی سنگدانه‌ها و طول ترک خطی بودند [۹۲].

شهین<sup>۷</sup> و همکاران در سال ۲۰۲۵ از الگوریتم‌های جنگل تصادفی و تقویت شدید گرادیان برای پیش‌بینی شاخص وضعیت روسازی براساس متغیرهایی از جمله متغیرهای اقلیمی (مانند شاخص انجماد)، زمان (عمر روسازی)، سازه (ضخامت لایه‌ها)، مواد (شاخص پلاستیک و همچنین عبوری از الک ۲۰۰)، ترافیک و وضعیت (متوسط شاخص بین‌المللی ناهمواری و همچنین خرابی‌ها) استفاده کردند. توسعه مدل‌ها مستلزم بهینه‌سازی ابرپارامتر<sup>۸</sup>‌های آن‌ها (مانند بیشینه عمق و تعداد درختان) بود که مقادیر آن‌ها از طریق روش‌های جستجوی تصادفی<sup>۹</sup>، جستجوی شبکه‌ای<sup>۱۰</sup> و روش بیز حاصل شد. نتایج تست مدل‌ها بر داده‌های پایگاه داده عملکرد بلندمدت روسازی نشان داد که دو مدل تقویت شدید گرادیان و جنگل تصادفی به ترتیب با دقت‌های بالای ۹۲/۳٪ و ۹۱/۲٪ قادر به پیش‌بینی شاخص وضعیت هستند. از آنجایی که ماتریس هم‌بستگی ایجادشده در قالب نقشه حرارتی، نشان‌دهنده وجود هم‌بستگی میان متغیرهای

<sup>۶</sup> Explainable AI

<sup>۷</sup> Shaheen

<sup>۸</sup> Hyperparameter

<sup>۹</sup> Random Search

<sup>۱۰</sup> Grid Search

<sup>۱</sup> Chen

<sup>۲</sup> Physics-Informed or Physics-Guided Neural Network (PINN or PGNN)

<sup>۳</sup> Recursive Feature Elimination (RFE)

<sup>۴</sup> Overfitting

<sup>۵</sup> SHapely Additive exPlanations (SHAP)

مطالعات اخیر که دربرگیرنده توسعه مدل‌های پیش‌بینی شاخص‌های عملکردی روسازی بوده‌اند در جدول ۱ با یکدیگر مقایسه شده‌اند.

پیش‌بینی‌کننده بود، در این پژوهش نیز از تحلیل شپ با هدف شناسایی و حذف متغیرهای اضافی استفاده شد. برجسته‌ترین متغیرها در پیش‌بینی شاخص عبارت بودند از متوسط شاخص بین‌المللی ناهمواری و عمر روسازی [۹۳].

جدول ۱: مقایسه پژوهش‌های اخیر با موضوع پیش‌بینی شاخص‌های عملکرد روسازی با استفاده از الگوریتم‌های یادگیری ماشین


Table 1. Comparison of the latest models developed for predicting pavement performance indicators using ML algorithms

| مرجع | پایگاه و تعداد داده                      | مدل یادگیری ماشین                                                                   | شاخص |     | متغیرهای پیش‌بینی‌کننده |       |      |      |               |                 |                    | دقت مدل ( $R^2$ )     |
|------|------------------------------------------|-------------------------------------------------------------------------------------|------|-----|-------------------------|-------|------|------|---------------|-----------------|--------------------|-----------------------|
|      |                                          |                                                                                     | IRI  | PCI | ترافیک                  | اقلیم | سازه | مواد | وضعیت و خرابی | تاریخچه نگهداری | تقسیم‌بندی داده‌ها |                       |
| [۸۹] | داده‌برداری در نابلس (فلسطین) (۳۸۴ ردیف) | شبکه عصبی مصنوعی                                                                    | -    | ✓   | -                       | -     | -    | -    | ✓             | -               | ۱٪/۷۰٪ / ۱٪/۱۵٪    | ۹۹٪/۷۵                |
| [۹۰] | LTPP (۲۰۷۰۸)                             | جنگل تصادفی ماشین بردار پشتیبان                                                     | ✓    | -   | ✓                       | ✓     | ✓    | -    | ✓             | ✓               | ۲۰٪ / ۸۰٪          | ۹۶٪ / ۹۳٪             |
| [۹۱] | LTPP (۱۰۲۸۷ ردیف)                        | شبکه عصبی فیزیک‌آگاه شبکه عصبی مصنوعی                                               | ✓    | -   | ✓                       | ✓     | ✓    | ✓    | ✓             | ✓               | ۱۵٪ / ۸۵٪          | ۸۸٪/۳۹ / ۸۷٪/۸۹       |
| [۹۲] | داده‌برداری در قم (ایران) (۴۰۸۵ ردیف)    | جنگل تصادفی ماشین سبک تقویت گرادیان رگرسیون خطی نزدیک‌ترین همسایگی کی تقویت گرادیان | ✓    | -   | -                       | -     | -    | -    | ✓             | -               | ۲۰٪ / ۸۰٪          | ۶٪/۱۵ / ۱۵٪/۲ / ۱۹٪/۶ |



شده در این مطالعه با موفقیت با ۲,۵۰۰ نمونه برداشت شده از راه‌های استان جیانگسو کنترل شده است [۹۷].

در ادامه، مقالات مرور شده در دسته‌های مختلف به صورت یک‌جا با یکدیگر مقایسه شده است تا درک عمیق‌تری از ادبیات موضوع حاصل شود. به منظور ارزیابی میزان رشد استفاده از الگوریتم‌های یادگیری ماشین و شبکه عصبی در ارزیابی یا بهبود عملکرد مخلوط یا رویه آسفالتی، تعداد پژوهش‌هایی که در این زمینه در سال‌های مختلف منتشر شده‌اند، در شکل ۵ نشان داده شده است.



شکل ۵: فراوانی مقالات خارجی منتشر شده در سال‌های مختلف با هدف بهبود راه‌حل‌ها در حوزه مهندسی روسازی با استفاده از هوش مصنوعی

Fig. 5. The frequency of international articles published annually with the aim of improving pavement engineering solutions using AI

موضوعات کلی پژوهش‌هایی که بهره‌گیری از الگوریتم‌های هوش مصنوعی در مهندسی روسازی را مورد توجه قرار داده‌اند، به همراه فراوانی مطالعات تحلیل شده در آن زمینه، در شکل ۶ آورده شده است.

و ۷۰-۱۰۰ تقسیم‌بندی شده است. با هدف سهولت استفاده برای کلیه کاربران، مدل با استفاده از زبان ویژوال بیسیک<sup>۱</sup> کدگذاری شده است [۹۵].

باروا<sup>۲</sup> و زو<sup>۳</sup> در سال ۲۰۲۱، برنامه ریزی نگهداری و تعمیرات روسازی‌های فرودگاهی با استفاده از روش‌های یادگیری ماشین را مورد مطالعه قرار دادند. معیار نگهداری در نظر گرفته شده در این مطالعه شاخص وضعیت روسازی بوده است. در این مطالعه، ساخت مدل بر اساس داده‌های واقعی فرودگاه شیکاگو انجام شده است. ۱۶۳ قطعه باند پرواز و ۳۷۷ قطعه باند خزش، مرجع برداشت مجموعه داده این مطالعه است. در این مدل‌سازی از الگوریتم ماشین تقویت گرادیان<sup>۳</sup> استفاده شده است و برای باند خزش و باند پرواز مدل‌های جداگانه‌ای ایجاد شده است. پارامترهای ورودی در این مدل، عمر، نوع روسازی، ترافیک، سیکل‌های یخبندان و اقدامات ترمیمی انجام شده قبلی در نظر گرفته شده است. به منظور آموزش مدل‌ها از روش یادگیری کیو<sup>۴</sup> استفاده شده است. نتایج نشان داد که دقت پیش‌بینی مدل توسعه داده شده بیش از ۹۰٪ بوده است. روش ارائه شده در این پژوهش می‌تواند با دریافت داده‌های ورودی مورد نیاز، یعنی مقادیر شاخص وضعیت روسازی و نیز هزینه واحد عملیات بهسازی، تحلیل‌های اقتصادی را برای برنامه‌های نگهداری و تعمیرات اجرا نماید [۹۶].

هان<sup>۵</sup> و همکاران در سال ۲۰۲۱، به توسعه مدل هوشمند برنامه‌ریزی نگهداری و تعمیرات روسازی‌های آسفالتی پرداختند. دقت مدل یادگیری تقویتی توسعه داده شده برابر با ۸۲/۲٪، یعنی ۱۷/۲٪ بالاتر از مدل شبکه عصبی بوده است. شبکه عصبی مذکور دارای یک لایه پنهان بوده است. ورودی‌های شبکه عصبی توسعه داده شده، شاخص وضعیت روسازی، شاخص عمق شیارشدگی<sup>۶</sup>، شاخص کیفیت رانندگی<sup>۷</sup> و شاخص بازتاب خورشیدی سطح<sup>۸</sup> بوده است. در این مطالعه انتخاب روش نگهداری و تعمیرات متناسب با مقایسه هزینه روش‌های مختلف انجام شده است. هزینه‌ها با استفاده از الگوریتم بهینه‌سازی سیاست تقریبی<sup>۹</sup> محاسبه شده است. روش توسعه داده

<sup>۶</sup> Rutting Depth Index (RDI)

<sup>۷</sup> Ride Quality Index (RQI)

<sup>۸</sup> Solar Reflectance Index (SRI)

<sup>۹</sup> Proximal Policy Optimization (PPO)

<sup>۱</sup> Visual basics


<sup>۲</sup> Barua & Zou

<sup>۳</sup> Gradient Boosting Machine (GBM)

<sup>۴</sup> Q-learning

<sup>۵</sup> Han

استفاده از الگوریتم ها برای



شکل ۶: کاربردهای تحلیل‌شده در ادبیات موضوع بهره‌گیری از هوش مصنوعی در مهندسی روسازی و فراوانی آن‌ها

Fig. 6. Analyzed applications and the associated frequency reviewed in the AI-assisted pavement engineering literature

موضوعات کلی پژوهش‌ها که در شکل ۶ نشان داده شد، با جزئیات دقیق‌تری از هدف آن پژوهش در جدول ۲ آورده شده‌است.

جدول ۲: اهداف جزئی شناسایی‌شده ذیل موضوعات کلی در پژوهش‌های مبتنی بر یادگیری ماشین در مهندسی روسازی

Table 2. The detailed goals detected under the general topics in the ML-based analyses in pavement engineering research

| موضوع کلی     | موضوع دقیق                              | موضوع کلی           | موضوع دقیق                              |
|---------------|-----------------------------------------|---------------------|-----------------------------------------|
| طراحی سازه‌ای | پیش‌بینی هزینه ساخت روسازی              | پیش‌بینی عملکرد قیر | پیش‌بینی کرنش تجمعی                     |
|               | پیش‌بینی بار معادل هم ارز               |                     | رابطه بین درصد قیر و مقاومت مارشال      |
|               | پیش‌بینی عمر باقی مانده روسازی          |                     | پیش‌بینی فرکانس آزمایش‌های خستگی        |
|               | طبقه‌بندی ترافیک کامیون‌ها              |                     | تخمین عمر خستگی                         |
|               | بهینه‌سازی ضخامت از منظر اقتصادی روسازی |                     | پیش‌بینی نتایج تست مارشال               |
|               | پیش‌بینی ویسکوزیته قیر                  |                     | پیش‌بینی پاسخ‌های بحرانی روسازی آسفالتی |
|               | تعیین درصد بهینه افزودنی به قیر         |                     | توسعه مدل‌های انرژی شکست                |
|               | چسبندگی قیر                             |                     | پیش‌بینی عدد روانی مخلوط آسفالتی        |
|               | بهینه‌سازی طرح اختلاط آسفالت            |                     | پیش‌بینی عمر باقی مانده روسازی          |
|               |                                         |                     |                                         |



|                                    |    |                               |    |
|------------------------------------|----|-------------------------------|----|
| شبکه عصبی مصنوعی                   | ۳۱ | جنگل تصادفی                   | ۱۱ |
| ماشین بردار پشتیبان                | ۸  | انواع مدل‌های تقویت گرادیان   | ۷  |
| الگوریتم ژنتیک                     | ۷  | رگرسیون خطی                   | ۴  |
| رگرسیون مارس                       | ۲  | نزدیک‌ترین همسایگی کمی        | ۲  |
| خوشه بندی میانگین کی               | ۱  | بهینه‌سازی ازدحام ذرات        | ۱  |
| رگرسیون گاوسی                      | ۱  | بهینه‌سازی بیز الگوریتم       | ۱  |
| ماشین بردار پشتیبان حداقل مربعات   | ۱  | جستجوی بهبود یافته حسگر سوسک  | ۱  |
| الگوریتم بهینه‌سازی جغرافیای زیستی | ۱  | گرادیان افزایشی - بسته بندی   | ۱  |
| بهینه‌سازی سیاست تقریبی            | ۱  | شبکه عصبی فیزیکی آگاه         | ۱  |
| رگرسیون لاسو                       | ۱  | درخت تصمیم                    | ۱  |
| رگرسیون رنج                        | ۱  | رگرسیون کرنل رنج <sup>۱</sup> | ۱  |

برخی حوزه‌های پژوهشی که در ادبیات موضوع مورد بررسی قرار نگرفته‌اند در شکل ۷ بیان شده‌اند. تأثیرات زیست‌محیطی روسازی‌های آسفالتی در چرخه عمر از مهم‌ترین موضوعات پژوهشی روز هستند [۹۸، ۹۹]. در این زمینه، استفاده الگوریتم‌های یادگیری ماشین برای ارزیابی پدیده‌هایی مانند آلودگی و کرناسیون مورد توجه قرار نگرفته‌است. سایر موضوعاتی که در ادبیات موضوع بررسی نشده‌است و پیشنهاد می‌شود در مطالعات پیش رو تحلیل شوند عبارتند از: تحلیل یا پیش‌بینی میزان انرژی تولیدشده از روسازی، پیش‌بینی خواص آسفالت‌های رنگی، تحلیل پایگاه‌های داده متنی جهت تعیین پرمخاطره‌ترین انواع خرابی با استفاده از تکنیک‌های پردازش زبان طبیعی و شناسایی خرابی‌های تبیین‌شده، شناسایی خرابی‌های رویه با رویکرد ترکیب نمودن داده‌ها از حسگرهای مختلف یا ترکیب نمودن نتایج مدل‌های مختلف (که با عنوان هم‌جوشی در سطح داده یا تصمیم<sup>۲</sup> شناخته می‌شود) و نهایتاً به‌کارگیری الگوریتم‌های یادگیری ماشین جهت توسعه دوقلوی دیجیتال<sup>۳</sup> روسازی آسفالتی.

|                                          |                                                |                           |
|------------------------------------------|------------------------------------------------|---------------------------|
| مدلسازی خواص آسفالت‌های جاذب صوت         | پیش‌بینی مدول سختی                             | پیش‌بینی یا شناسایی خرابی |
| مدلسازی ترک‌های عرضی روکش                | پیش‌بینی مدول روسازی                           |                           |
| پیش‌بینی خستگی روسازی                    | پیش‌بینی مدول دینامیکی آسفالت و آسفالت ماستیکی |                           |
| مدلسازی شیارشدگی و پیش‌بینی عمق شیارشدگی | کمین‌سازی هزینه نگهداری و تعمیرات راه          |                           |
| شناسایی ترک‌های انعکاسی                  | برنامه‌ریزی نگهداری و تعمیرات فرودگاهی         | پیش‌بینی عملکرد روسازی    |
| پیش‌بینی شاخص بین‌المللی ناهمواری        | برنامه‌ریزی نگهداری و تعمیرات هوشمند راه       |                           |

برنامه‌ریزی نگهداری و تعمیرات

مدل‌های مختلف هوش مصنوعی بر اساس فراوانی به‌کارگیری‌شان در جدول ۳ آورده شده‌است. بر این اساس، مدل شبکه عصبی مصنوعی بیشترین تعداد دفعات استفاده در تحلیل‌ها را داشته است (۳۱ مرتبه) که این بیانگر توجه بیشتر به مدل در ادبیات موضوع است و نه عملکرد قوی‌تر. در مراتب بعدی، الگوریتم‌های جنگل تصادفی ماشین بردار پشتیبان مجموعه مدل‌های مبتنی بر تقویت گرادیان به ترتیب دارای بیشترین فراوانی در تحلیل‌ها بوده‌اند. همچنین مدل‌هایی که کمترین تعداد استفاده در ادبیات موضوع را داشته‌اند، عبارتند از خوشه‌بندی میانگین کی، بهینه‌سازی ازدحام ذرات، رگرسیون گاوسی، بهینه‌سازی بیز، ماشین بردار پشتیبان حداقل مربعات، رگرسیون لاسو، گرادیان افزایشی بسته بندی، بهینه‌سازی سیاست تقریبی، تقویت شدید گرادیان و رگرسیون (کرنل) رنج (۱ مرتبه).

جدول ۳: فراوانی استفاده از مدل‌های یادگیری ماشین در تحلیل یا پیش‌بینی عملکرد و وضعیت روسازی

Table 3. The frequency of ML-based models in prediction or analysis of pavement performance or condition

| الگوریتم | فراوانی | الگوریتم | فراوانی |
|----------|---------|----------|---------|
|----------|---------|----------|---------|

<sup>۲</sup> Digital Twin (DT)

<sup>۱</sup> Kernel Ridge Regression

<sup>۲</sup> Data-level or Decision-level Fusion



شکل ۷: برخی حوزه‌های مهندسی روسازی که از الگوریتم‌های یادگیری ماشین در بهبود آن‌ها استفاده نشده است.

Fig. 7. Research topics in pavement engineering for which ML-based models have seldom been used

#### ۴ - مطالعات منتشرشده توسط پژوهشگران ایرانی

در این بخش مطالعات منتشرشده به زبان فارسی به صورت مجزا مورد بررسی و ارزیابی قرار گرفته است تا رویکردها و دستاوردهایشان با دیگر محققین مشخص شود. مرور آثار پژوهشگران ایرانی با محور استفاده از الگوریتم‌های یادگیری ماشین، علاوه بر روسازی آسفالتی، برای دیگر سازه‌ها و مصالح از جمله بتن یا فولاد نیز انجام شده است تا تحلیل جامع‌تری ارائه شود.

با توجه به زمان‌بر بودن و هزینه‌بر بودن فرآیند تولید و کنترل کیفیت مخلوط آسفالتی، حسین‌زاده و همکاران ۱۴۰۲ به توسعه مدل‌های یادگیری ماشین جهت پیش‌بینی مقاومت مارشال پرداختند. در این راستا از نتایج آزمایش ۲۰۰۰ نمونه آسفالتی در سازمان عمران شهرداری مشهد برای توسعه مدل‌های ماشین بردار پشتیبان و جنگل تصادفی استفاده شد. متغیرهای ورودی مدل شامل دانه‌بندی مصالح، درصد شکستگی مصالح، درصد جذب قیر، وزن مخصوص قیر، وزن مخصوص حقیقی مصالح، درصد قیر مصرفی، نسبت درصد وزنی فیلر به قیر موثر و مقاومت مارشال نمونه بوده است. مقادیر ضریب تعیین بدست‌آمده برای مدل‌های ماشین بردار پشتیبان و جنگل تصادفی به ترتیب برابر با ۸۷/۵٪ و ۸۲/۷٪ بوده است [۱۰۰].

<sup>۱</sup> Analytical Heirarchical Process (AHP)

<sup>۲</sup> Linear Programming

امینی ۱۴۰۴ تاثیر هم‌افزایی استاینر-بوتادین-استایرن و نانو لوله‌های کربنی را بر رفتار رئولوژیکی قیر بررسی نموده و سپس به توسعه دو مدل یادگیری ماشین جهت پیش‌بینی شاخص شیارشدگی پرداخت. اولین مدلی که بر اساس داده‌های آزمایشگاهی ساخته شد، مدل رگرسیون چندجمله‌ای بود که متغیر وابسته آن مقاومت شیارشدگی بر حسب سوپرپیو و متغیرهای مستقل آن درصد هر یک از افزودنی‌ها و دمای آزمایش بود. در ادامه یک مدل شبکه عصبی با بهره‌گیری از الگوریتم لوببرگ-مارکوارت به عنوان بهینه‌ساز ساخته شد. به منظور دستیابی به بالاترین دقت پیش‌بینی، ۲۰ ساختار مختلف برای معماری شبکه عصبی مورد بررسی قرار گرفت که بهترین عملکرد مربوط به ساختاری با ۳ لایه مخفی و به ترتیب ۵، ۱۰ و ۱۵ یاخته عصبی در لایه‌های مخفی اول، دوم و سوم بود. هر دو مدل رگرسیون و شبکه عصبی، به ترتیب با ضرایب تعیین ۹۱/۵٪ و ۹۷/۶٪ با دقت مطلوبی برای پیش‌بینی عملکرد شیارشدگی قیر اصلاح‌شده مورد استفاده قرار گرفتند [۱۰۱].

بهبهانی و همکاران ۱۴۰۰ به بهینه‌سازی برنامه نگهداری و تعمیرات شبکه روسازی با بهره‌گیری از ابزارهای اولویت‌بندی و هوش مصنوعی پرداختند. روش پیشنهادی شامل استفاده از فرآیند سلسله‌مراتبی تحلیل<sup>۱</sup> جهت تعیین قطعات روسازی پراهمیت‌تر، برنامه‌ریزی خطی<sup>۲</sup> ریاضی جهت اعمال قیود (محدودیت بودجه، هزینه عملیات نگهداری و تعداد قطعه قابل تعمیر در سال برای متولی راه) و روش استنتاج فازی<sup>۳</sup> جهت تعیین احتمال انتخاب گزینه‌های ترمیم‌ونگهداری بوده است. مطالعه موردی بر اساس داده‌های شبکه‌ای از راه‌های شهر ماهان در استان کرمان انجام شد. عملیات نگهداری در نظر گرفته شده در تحلیل شامل پرکردن ترک، فاگ‌سیل، اسلاری سیل، چپ‌سیل، بازیافت، روکش و بازسازی بود. اولویت‌بندی قطعات روسازی و شاخه‌های موجود در شبکه نیز بر اساس ۴ معیار طبقه‌بندی عملکردی، ترافیک، دسترسی و اهمیت تجاری انجام شد. بهینه‌سازی عملیات نگهداری با استفاده از روش پیشنهادی منجر به استفاده بیشتر از گزینه‌های پیشگیرانه از جمله میکروسرفسینگ در سناریوی بودجه نامحدود و نیز انتخاب گزینه‌های مقرون‌به‌صرفه‌تر مانند فاگ‌سیل در سناریوی بودجه محدود شد [۱۰۲].

قادری و عبدالمالکی ۱۴۰۰ از روش یادگیری بدون نظارت برای شناسایی خودکار آسیب‌های سازه‌های عمرانی بهره گرفتند. الگوریتم به‌کارگرفته شده یک شبکه عصبی بدون ناظر متشکل از چند لایه ماشین بولتزمن<sup>۴</sup> بوده است. در مطالعه موردی، یک ساختمان ۳۵ طبقه فولادی طراحی گردیده و در برابر دو نوع بار طبیعی، شامل

<sup>۲</sup> Fuzzy Inference System (FIS)

<sup>۴</sup> Boltzman Machine

زلزله‌هایی با دامنه کوچک و نیز بار دینامیکی باد قرار داده‌شد. پاسخ‌های سازه سالم (سازه ۱) برای آموزش مدل پیشنهادی مورد استفاده قرار گرفت تا الگوهای معنادار موجود در پاسخ‌ها استخراج شوند. سپس یک زلزله خفیف در مدلسازی کامپیوتری به ساختمان اعمال گردید تا سازه در وضعیت نامعلوم و آسیب‌دیده قرار بگیرد. در ادامه بارهای محیطی اولیه مجدد به ساختمان وارد شد تا پاسخ‌ها ثبت شده و به‌منظور تشخیص آسیب‌دیدگی به مدل شبکه عصبی وارد شود. تفاضل خروجی‌های مدل در حالت آسیب‌دیده و حالت سالم (شاخص سلامت) نشان‌دهنده آسیب‌های وارده به ساختمان بود که حاکی از دقت مطلوب مدل در تعیین آسیب‌دیدگی (حدود ۹۵٪) بود [۱۰۳].

## ۵ - نتیجه‌گیری

هوش مصنوعی، هوشی است که با الگوگرفتن از رفتار انسانی توسط ماشین‌ها، ظهور یافته‌است. با کاربرد دسته‌های مختلف هوش مصنوعی، فرآیندهای تجزیه، تحلیل و تفسیر داده‌ها با دقت بسیار بالایی امکان‌پذیر شده‌است؛ به‌گونه‌ای که امروزه از دو زیرمجموعه هوش مصنوعی، یعنی یادگیری ماشین و یادگیری عمیق، برای خلق سامانه‌هایی استفاده می‌شود که قابلیت استخراج الگوها، تصمیم‌گیری و پیش‌بینی نتایج را بدون دخالت انسان فراهم می‌نمایند. در این تحقیق، کاربردهای هوش مصنوعی در دسته یادگیری ماشین در مهندسی روسازی آسفالتی مورد بررسی قرار گرفته‌است. در این راستا مقالات معتبر منتشرشده با محوریت به‌کارگیری الگوریتم‌های یادگیری ماشین مورد توجه بوده‌است. الگوریتم‌های یادگیری ماشین در زمینه‌های مختلف مهندسی روسازی از جمله بهینه‌سازی طراحی (۱۱٪ از مطالعات)، پیش‌بینی عملکرد قیر (۸٪)، پیش‌بینی خصوصیات مخلوط آسفالتی (۳۳٪)، تشخیص خرابی‌های سطح روسازی (۱۹٪)، طبقه‌بندی خرابی‌های سطح روسازی (۲٪)، پیش‌بینی شاخص‌های عملکردی رویه (۲۱٪) و بهینه‌سازی برنامه عملیات ترمیم‌ونگهداری (۶٪) استفاده شده‌است.

یافته‌های این پژوهش نشان می‌دهد ابزارهای سنتی مانند منحنی‌های تجربی و معادلات رگرسیونی ساده که برای ارزیابی و پیش‌بینی خصوصیات و عملکرد روسازی آسفالتی استفاده می‌شدند جای خود را به مدل‌های پیشرفته یادگیری ماشین داده‌اند که دارای قابلیت استخراج الگوهای پیچیده و غیرخطی در فرآیندهای مختلف صنعت قیر و آسفالت هستند. همچنین می‌توان گفت در آینده‌ای

نزدیک، با تجمع بیشتر داده‌های گردآوری‌شده و همچنین پیشرفت و توسعه مدل‌های هوش مصنوعی، مسائل پیچیده مرتبط با روسازی راه‌ها با سرعت و دقت بالاتری تجزیه و تحلیل خواهد شد.

با این حال استفاده از الگوریتم‌های یادگیری ماشین چالش‌هایی را نیز به همراه داشته‌است که از جمله آن‌ها می‌توان به نیاز به پایگاه‌های داده گسترده، عدم تعمیم‌پذیری و عدم ارائه معادلات و روابط ریاضی اشاره نمود. لذا پیشنهاد می‌شود در مطالعات آینده، کاربرد الگوریتم‌های هوش مصنوعی در حوزه مهندسی روسازی با رویکردهایی نوین و به‌روز انجام شود. از جمله این رویکردها، استفاده از هوش مصنوعی توضیح‌پذیر است که امکان تفهیم و ادراک تصمیم‌گیری‌های مدل‌ها را فراهم می‌سازد. تحلیل شب از جمله تکنیک‌های هوش مصنوعی توضیح‌پذیر بود که کاربرد آن در مطالعاتی که اخیراً انتشار یافته‌اند دیده‌شد. به‌خدمت‌گرفتن این تکنیک‌ها کمبودها و خلأهای مدل‌های یادگیری ماشین از جمله عدم ارائه معادلات ریاضی و عملکرد به مثابه جعبه سیاه را پوشش می‌دهد.

از دیگر رویکردهایی که در مطالعات آینده ضروری به‌نظر می‌رسد، مهندسی و بهینه‌سازی مشخصه‌های ورودی مدل‌هاست. این رویکرد باعث افزایش دقت مدل و جلوگیری از ورود مشخصه‌های اضافی به مدل می‌شود. روش حذف بازگشتی ویژگی‌ها از جمله روش‌های بهینه‌سازی ورودی‌های مدل است که کاربرد آن در پژوهش‌های اخیر در ادبیات موضوع مورد توجه قرار گرفته‌است.

همچنین پیش‌بینی و تحلیل عملکرد روسازی با رویکرد به‌کارگیری دانش و قوانین فیزیک که امروزه در حال تبدیل شدن به یک الگواره نوین جهت ارتقاء مدل‌های یادگیری ماشین است، ضرورت دارد. مطابق با مرور ادبیات، راهبردهای پیشنهادی جهت استفاده از ظرفیت‌های یادگیری فیزیکی‌محور ماشین عبارتند از: ارزیابی قوانین فیزیکی مختلف و روش‌های ادغام آن‌ها با مدل‌های یادگیری ماشین و نیز تحلیل تاثیر آن بر دقت و میزان عدم قطعیت پیش‌بینی، توسعه مدل‌های یادگیری فیزیکی‌محور ماشین با الگوریتم‌های بررسی‌نشده در این زمینه، از جمله ماشین بردار پشتیبان و جنگل تصادفی و همچنین پیش‌بینی سایر شاخص‌های عملکردی روسازی از جمله شاخص وضعیت و شیارشدگی.

[6] P. Lu, S. Chen, Y. Zheng, Artificial intelligence in civil engineering, *Mathematical Problems in Engineering*, 1 (2012) 145974.

[7] Y. Zhang, S. Balochian, P. Agarwal, V. Bhatnagar, O.J. Housheya, Artificial intelligence and its applications, *Mathematical problems in Engineering*, 1 (2014) 840491.

[8] R. Cioffi, M. Travaglioni, G. Piscitelli, A. Petrillo, F. De Felice, Artificial intelligence and machine learning applications in smart production: Progress, trends, and directions, *Sustainability*, 12(2) (2020) 492.

[9] M. Abambres, A. Ferreira, Application of ANN in Pavement Engineering: State-of-Art, (2017).

[10] B. Ghorbania, A. Arulrajaha, G. Narsiliob, S. Horpibulsuk, Experimental and ANN analysis of temperature effects on the permanent deformation properties of demolition wastes, *Transportation Geotechnics*, 24 (2020) 100365.

[11] K. Kersting, Machine learning and artificial intelligence: two fellow travelers on the quest for intelligent behavior in machines, *Frontiers in big Data*, 1 (2018) 6-10.

[12] M.I. Jordan, T.M. Mitchell, Machine learning: trends, perspectives, and prospects, *Science*, 349 (2015) 255-260.

[13] T. Xu, F. Zhu, E.K. Wong, Y. Fang, Dual many-to-one-encoder-based transfer learning for cross-dataset human action recognition, *Image and Vision Computing*, 55(2) (2016) 127-137.

[14] E.P. Ijjina, K.M. Chalavadi, Human action recognition using genetic algorithms and convolutional neural networks, *Pattern Recognition*, 59 (2016) 199-212.

[15] Z. Tong, J. Gao, H. Zhang. Recognition, location, measurement, and 3D reconstruction of concealed cracks using convolutional neural networks, *Construction and Building Materials*, 146 (2017) 775-787.

[16] Z. Du, J. Yuan, F. Xiao, C. Hettiarachchi, Application of image technology on pavement distress detection: A review, *Measurement*, 184 (2021) 109900.

[17] J. Bryce, S. Brodie, T. Parry, D.L. Presti, A systematic assessment of road pavement sustainability through a review of rating tools, *Resources, Conservation and Recycling*, 120 (2017) 108-118.

در نهایت به منظور افزایش دقت پیش‌بینی مدل‌های مورد نیاز در صنعت روسازی، پیشنهاد می‌شود الگوریتم‌های پیشرفته یادگیری عمیق برای اهدافی که در مرور ادبیات شناسایی شدند استفاده شوند. شایان ذکر است مدل‌های یادگیری عمیق با بهره‌گیری از تعداد لایه‌های بیشتر و لایه‌های کاملاً پیچشی در انجام محاسبات، دقت‌های بالاتری را نسبت به الگوریتم‌های یادگیری ماشین ارائه نموده و همچنین تحلیل انواع دیگری از داده از جمله داده‌های تصویری و سری زمانی را نیز ممکن می‌سازند.

در بخش پایانی این مقاله، پژوهش‌های منتشرشده به زبان فارسی نیز ارزیابی شدند تا رویکردها و فراوانی مطالعات محققین با مطالعات بین‌المللی مقایسه شود. باتوجه به گستره محدود مطالعات موجود، پیشنهاد می‌شود مدل‌های بیشتر و دقیق‌تری با بهره‌گیری از داده‌های آزمایشگاهی معتبر جهت پیش‌بینی خصوصیات قیر و مخلوط آسفالتی توسعه داده شود. همچنین پیشنهاد می‌شود از داده‌های برداشت‌شده از شبکه گسترده راه‌های کشور، شامل شدت و وسعت خرابی‌ها، مقادیر شاخص‌های بین‌المللی ناهمواری، وضعیت روسازی و نیز دیگر مشخصه‌های خدمت‌دهی روسازی برای توسعه مدل‌های پیش‌بینی سطح خدمت‌دهی روسازی و مدل‌های تشخیص خودکار خرابی استفاده شود.

## منابع

[1] D. Berrar, N. Sato, A. Schuster, Quo vadis, artificial intelligence?, *Advances in Artificial Intelligence*, 2010(1) (2010) 629869.

[2] L. Morgenstern, and S.A. McIlraith, John McCarthy's legacy, *Artificial Intelligence*, 175(1) (2011) 1-24.

[3] Y. Xu, X. Liu, X. Cao, C. Huang, E. Liu, S. Qian, X. Liu, Y. Wu, F. Dong, C.-W. Qiu, J. Qiu, K. Hua, W. Su, J. Wu, H. Xu, Artificial intelligence: A powerful paradigm for scientific research, *The Innovation*, 2(4) (2021).

[4] G. Tecuci, Artificial Intelligence, *WIREs Computational Statistics*, 4(2) (2012) 168-180.

[5] V. Dignum, Responsible Artificial Intelligence: Designing AI for human values, *ITU Journal: ICT Discoveries*, 1 (2017).

evolution, challenges and research agenda, *International Journal of Information Management*, 48 (2019) 63-71.

[29] S. Mouloudi, H. Rahmanpanah, S. Gohari, C. Burvill, K.M. Tse, H.M.S. Davies, What can artificial intelligence and machine learning tell us? A review of applications to equine biomechanical research, *Journal of the Mechanical Behavior of Biomedical Materials*, 123 (2021) 104728.

[30] F. Yang, X. Zhang, Z. Yu, Human-machine collaborative learning for streaming data-driven scenarios. *Sensors*, 25(21) (2025) 6505.

[31] K. Razzaq, and M. Shah, Machine learning and deep learning paradigms: From techniques to practical applications and research frontiers, *Computers*, 14(3) (2025) 93.

[32] M.H.M., Noor, A.O. Ige, A survey on state-of-the-art deep learning applications and challenges, *Engineering Applications of Artificial Intelligence*, 159 (2025) 111225.

[33] I.H. Sarker, Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions, *SN computer science*, 2(6) (2021) 1-20.

[34] M. Soori, B. Arezoo, R. Dastres, Artificial intelligence, machine learning and deep learning in advanced robotics, a review, *Cognitive Robotics*, 3 (2023) 54-70.

[35] A.L. Fradkov, Early history of machine learning, *IFAC-Papers OnLine*, 53(2) (2020) 1385-1390.

[36] H.S. Greenwald, C.K. Oertel, Future directions in machine learning, *Frontiers in Robotics and AI*, 3 (2017) 79.

[37] K. Rajan, Materials informatics, *Materials Today*, 8(10) (2005) 38-45.

[38] D. Wang, H. He, D. Liu, Adaptive critic nonlinear robust control: a survey, *IEEE transactions on cybernetics*, 47(10) (2017) 3429-3451.

[39] M. Nikzad, K. Movagharnajad, F. Talebnia, Comparative study between neural network model and mathematical models for prediction of glucose concentration during enzymatic hydrolysis, *International Journal of Computer Applications*, 56(1) (2012).

[40] M. Lazarevska, M. Knezevic, M. Cvetkovska, A. Trombeva-Gavriloska, Application of artificial neural networks in civil engineering, *Tehnički vjesnik*, 21(6) (2014) 1353-1359.

[18] X. Yang, J. Guan, L. Ding, Z. You, V.C. Lee, M.R.M. Hasan, X. Cheng, Research and applications of artificial neural network in pavement engineering: A state-of-the-art review, *Journal of Traffic and Transportation Engineering (English Edition)*, 8(6) (2021) 1000-1021.

[19] N. Sholevar, A. Golroo, S.R. Esfahani, Machine learning techniques for pavement condition evaluation. *Automation in Construction*, 136 (2021) 104190.

[20] T.B.J. Coenen, A. Golroo, A review on automated pavement distress detection methods, *Cogent Engineering*, 4(1) (2017) 1374822.

[21] Y. Xu, Z. Zhang, Review of applications of artificial intelligence algorithms in pavement management. *Journal of Transportation Engineering, Part B: Pavements*, 148(3) (2022) 03122001.

[22] S. Cano-Ortiz, P. Pascual-Muñoz, D. Castro-Fresno, Machine learning algorithms for monitoring pavement performance. *Automation in Construction*, 139 (2022) 104309.

[23] J. Kang, P. Tavassoti, M.N.A.R. Chaudhry, H. Baaj, M. Ghafurian, Artificial intelligence techniques for pavement performance prediction: a systematic review, *Road Materials and Pavement Design*, 26(3) (2025) 497-522.

[24] M. Abambres, A. Ferreira, Application of ANN in pavement engineering: State-of-Art. *Authorea Preprints*, (2017).

[25] X. Yang, J. Guan, L. Ding, Z. You, V.C. Lee, M.R.M. Hasan, X. Cheng, Research and applications of artificial neural network in pavement engineering: a state-of-the-art review, *Journal of Traffic and Transportation Engineering (English Edition)*, 8(6) (2021) 1000-1021.

[26] Y. Wang, J. Li, X. Zhang, Y. Yao, Y. Peng, Recent Development in Intelligent Compaction for Asphalt Pavement Construction: Leveraging Smart Sensors and Machine Learning, *Sensors*, 24(9) (2024) 2777.

[27] W. Sha, Y. Guo, Q. Yuan, S. Tang, X. Zhang, S. Lu, X. Guo, Y.-C. Cao, and S. Cheng. *Artificial Intelligence to Power the Future of Materials Science and Engineering*. Published by WILEY-VCH Verlag GmbH & Co. KGaA, Weinheim.

[28] Y. Duan, J.S. Edwards, Y.K. Dwivedi, Artificial intelligence for decision making in the era of Big Data–

- [52] A.S. Hosseini, P. Hajikarimi, M. Gandomi, F. Moghadas Nejad, A.H. Gandomi, Optimized machine learning approaches for the prediction of viscoelastic behavior of modified asphalt binders, *Construction and Building Materials*, 299 (2021) 124264.
- [53] M. Arifuzzaman, M.A. Gul, K. Khan and S.M.Z. Hossain, Application of Artificial Intelligence (AI) for Sustainable Highway and Road System, *Symmetry*, 13(60) 2021.
- [54] R.H. Riyad, R. Jaiswal, I.B. Muhit, J. Shen, Optimizing modified asphalt binder performance at high and intermediate temperatures using experimental and machine learning approaches, *Construction and Building Materials*, 449 (2024) 138350.
- [55] S. Tapkin, A. Cevik, Ü. Usar. Accumulated strain prediction of polypropylene modified marshall specimens in repeated creep test using artificial neural networks, *Expert Systems with Applications*, 36 (2009) 11186–11197.
- [56] M. Saffarzadeh, A. Heidaripناه. Effect of Asphalt Content on the Marshall Stability of Asphalt Concrete Using Artificial Neural Networks, *Scientia Iranica*, 16(1) (2009).
- [57] A.R. Ghanizadeh and M. Fakhri, Prediction of Frequency for Simulation of Asphalt Mix Fatigue Tests Using MARS and ANN, *The Scientific World Journal*, 1 (2014) 515467.
- [58] S. Tapkin, Estimation of Fatigue Lives of Fly Ash Modified Dense Bituminous Mixtures Based on Artificial Neural Networks, *Materials Research*, 17(2) (2014) 316-325.
- [59] S. Khuntia, A.K. Das, M. Mohanty, M. Panda, Prediction of Marshall Parameters of Modified Bituminous Mixtures Using Artificial Intelligence Techniques, *Transportation Science and Technology*, 3(3) (2014) 211-227.
- [60] A.R. Ghanizadeh, Application of Support Vector Machine Regression for Predicting Critical Responses of Flexible Pavements, *International Journal of Transportation Engineering*, 4(4) (2017) 305-315.
- [61] H. Majidifard, B. Jahangiri, W.G. Buttlar, A.H. Alavi, New machine learning-based prediction models for fracture energy of asphalt mixtures, *Measurement*, 135 (2019) 438–451.
- [62] T.-H. Le, H.-L. Nguyen, B.T. Pham, M.H. Nguyen, C.-T. Pham, N.-L. Nguyen, T.-T. Le, H.-B. Ly, Artificial
- [41] A.M. Mosa, R.A.O.K Rahmat, A. Ismail, M.R. Taha. Expert system to control construction problems in flexible pavements, *Computer-Aided Civil and Infrastructure Engineering*, 28(4) (2013) 307-323.
- [42] A. Kurian, E. Sunildutt, Artificial Neural Networks in Pavement Engineering: A Recent Review, *AIJR Proceedings*, (2021) 553-558.
- [43] V.S. Dave, K. Dutta, Neural network-based models for software effort estimation: a review, *Artificial Intelligence Review*, 42(2) (2014) 295-307.
- [44] R. Bala, D.D. Kumar, Classification using ANN: A review, *International Journal of Computational Intelligence Research*, 13(7) (2017) 1811–1820.
- [45] B.O. Antwi, B.O. Adelakun, A.O. Eziefule. Transforming financial reporting with AI: Enhancing accuracy and timeliness, *International Journal of Advanced Economics*, 6(6) (2024) 205-223.
- [46] J. He, Z. Qi, W. Hang, C. Zhao, M. King, Predicting freeway pavement construction cost using a back-propagation neural network: A case study in Henan, China, *The Baltic Journal of Road and Bridge Engineering*, 9(1) (2014) 66-76.
- [47] M. Tiğdemir, Re-evaluation of the AASHTO-flexible pavement design equation with neural network modeling, *PloS one*, 9(11) (2014) e113226.
- [48] A. Qadir, U. Gazder, K.U.N Choudhary, Artificial neural network models for performance design of asphalt pavements reinforced with geosynthetics, *Transportation Research Record*, 2674(8) (2020) 319-326.
- [49] N. Tahaei, J.J. Yang, M.G. Chorzepa, S.S. Kim, S.A. Durham. Machine learning of Truck Traffic Classification groups from Weigh-in-Motion data, *Machine Learning with Applications*, 6 (2021) 100178.
- [50] M. Tohidi, N. Khayat, A. Telvari, The use of intelligent search algorithms in the cost optimization of road pavement thickness design, *Ain Shams Engineering Journal*, 13 (2022) 101596.
- [51] F. Xiao, B.J. Putman, S.N. Amirkhanian, Viscosity prediction of CRM binders using artificial neural network approach, *International Journal of Pavement Engineering*, 12(5) (2011) 485–495.

- [72] S. Rahman, A. Bhasin, A. Smit. Exploring the use of machine learning to predict metrics related to asphalt mixture performance, *Construction and Building Materials*, 295 (2021) 123585.
- [73] S. Ghafari, M. Ehsani, F. Moghadas Nejad, Prediction of low-temperature fracture resistance curves of unmodified and crumb rubber modified hot mix asphalt mixtures using a machine learning approach, *Construction and Building Materials*, 314 (2022) 125332.
- [74] X. Wang, P. Pan, J. Li, Real-time measurement on dynamic temperature variation of asphalt pavement using machine learning, *Measurement*, 207 112413.
- [75] Z. Tong, D. Yuan, J. Gao, Y. Wei, H. Dou, Pavement-distress detection using ground-penetrating radar and network in networks, *Construction and Building Materials*, 233 (2020) 117352.
- [76] Q. Mei, M. Gül. A cost-effective solution for pavement crack inspection using cameras and deep neural networks, *Construction and Building Materials*, 256 (2020) 119397.
- [77] J. Gao, D. Yuan, Z. Tong, J. Yang, D. Yu, Autonomous pavement distress detection using ground penetrating radar and region-based deep learning, *Measurement* 164 (2020) 108077.
- [78] H.-C., Dan, G.-W. Bai, Z.-H. Zhu, Application of deep learning-based image recognition technology to asphalt-aggregate mixtures: Methodology, *Construction and Building Materials*, 297 (2021) 123770.
- [79] D. Arya, H. Maeda, S.K. Ghosh, D. Toshniwal, Y. Sekimoto, An annotated image dataset for automatic road damage detection using deep learning, *Data in Brief*, 36 (2021) 107133.
- [80] C. Zhang, E. Nateghinia, L.F. Miranda-Moreno, L. Sun, Pavement distress detection using convolutional neural network (CNN): A case study in Montreal, Canada, *International Journal of Transportation Science and Technology*, 11(2) (2022) 298-309.
- [81] J. Guan, X. Yang, L. Ding, X. Cheng, V.C.S. Lee, C. Jin, Automated pixel-level pavement distress detection based on stereo vision and deep learning, *Automation in Construction*, 129 (2021) 103788.
- [82] M. Ehsani, F. Moghadas Nejad, P. Hajikarimi, Developing an optimized faulting prediction model in Intelligence-Based Model for the Prediction of Dynamic Modulus of Stone Mastic Asphalt, *Applied Sciences*, 10(15) (2020) 5242.
- [63] A.R. Ghanizadeh, F.S. Jahanshahi, V. Khalifeh, F. Jalali, Predicting Flow Number of Asphalt Mixtures Based on the Marshall Mix design Parameters Using Multivariate Adaptive Regression Spline (MARS), *International Journal of Transportation Engineering*, 7(4) (2020) 433-448.
- [64] N.T. Tran, O. Takahashi, Evaluating the rutting resistance of wearing course mixtures with different fine aggregate sources using the indirect tensile strength test, *Journal of Testing and Evaluation*, 48(4) (2020) 2865-2879.
- [65] M.A. Abed, Z.N.M. Taki, A.H. Abed, Artificial neural network modeling of the modified hot mix asphalt stiffness using Bending Beam Rheometer. *Materials Today: Proceedings*, 42 (2021) 2584–258.
- [66] L.T. Glover, J. Mallela, Guidelines for Implementing NCHRP 1-37A ME Design Procedures in Ohio: Volume 4—MEPDG Models Validation & Recalibration, No. FHWA/OH-2009/9D, Ohio Department of Transportation, 2009.
- [67] Q. Li, D.X. Xiao, K.C. Wang, K.D. Hall, Y. Qiu, Mechanistic-empirical pavement design guide (mepdg): A bird's-eye view, *Journal of Modern Transportation*, 19(2) (2011) 114-133.
- [68] J. Huang, G.S. Kumar, Y. Sun, Evaluation of workability and mechanical properties of asphalt binder and mixture modified with waste toner, *Construction and Building Materials*, 276 (2021) 122230.
- [69] J. Huang, G.S. Kumar, J. Ren, J. Zhang, Y. Sun, Accurately predicting dynamic modulus of asphalt mixtures in low temperature regions using hybrid artificial intelligence model, *Construction and Building Materials*, 297 (2021) 123655.
- [70] X. Zhang, F. Otto, M. Oeser, Pavement moduli back-calculation using artificial neural network and genetic algorithms, *Construction and Building Materials*, 287 (2021) 123026.
- [71] A. Behnood, E.M. Golafshani, Predicting the dynamic modulus of asphalt mixture using machine learning techniques: An application of multi biogeography-based programming, *Construction and Building Materials*, 266 (2021) 120983.

Data, Case Studies in Construction Materials, (2025) e05291.

[93] M. Shaheen, R.A. Elsayed, H. Ghazoly, W.A. Bekheet, Explainable and economical AI-based approach for PCI assessment, *International Journal of Pavement Engineering*, 26(1) (2025) 2531195.

[94] Y. Wu, B. Sicard, S.A. Gadsden, Physics-informed machine learning: A comprehensive review on applications in anomaly detection and condition monitoring, *Expert Systems with Applications*, 255 (2024) 124678.

[95] A.A. Elhadidy, E.E. Elbeltagi, M.A. Ammar, Optimum analysis of pavement maintenance using multi-objective genetic algorithms, *HBRC Journal*, 11(1) (2015) 107–113.

[96] L. Barua, B. Zou, Planning maintenance and rehabilitation activities for airport pavements: A combined supervised machine learning and reinforcement learning approach, *International Journal of Transportation Science and Technology*, 11(2) (2022) 423-435.

[97] C. Han, T. Ma, S. Chen, Asphalt pavement maintenance plans intelligent decision model based on reinforcement learning algorithm, *Construction and Building Materials*, 299 (2021) 124278.

[98] M.S. Entezari, R. Tanzadeh, F. Moghadas Nejad, Economic, Environmental, and Social Assessment of Concrete Pavement Life Cycle: A Literature Review, *Sharif Journal of Civil Engineering*, 41(1) (2025) 110-129.

[99] M.M. Dadaei, P. Hajikarimi, F. Moghadas Nejad, Sustainable prospective proposals for utilizing modifiers in bitumen industry to address global warming, *Scientific Reports*, 15(1) (2025) 17042.

[100] H. Hosseinzadeh, A. Hasani, S. Arman, A.S. Hejazi, Predicting Marshall Asphalt Stability Using Supervised Machine Learning Algorithms, support vector machine and random forest, *Journal of Transportation Research*, 20(3) (2023) 249-262 (in Persian).

[101] A. Amini, Presenting Predictive Models of Rheological Characteristics of Modified Bitumens Containing SBS and Carbon Nanotubes Using Nonlinear Regression and Neural Network, *Journal of Transportation Research*, 22(3) (2025) 373-384 (in Persian).

[102] H. Behbahani, N. Nadimi, M. Khaleghi, Introducing a New Method for the Pavements' Maintenance and

Jointed Plain Concrete Pavement using artificial neural networks and random forest methods, *International journal of pavement engineering*, 24(2) (2023) 2057975.

[83] B. Li, K.C.P. Wang, A. Zhang, Y. Fei, Automatic Segmentation and Enhancement of Pavement Cracks Based on 3D Pavement Images. *Journal of Advanced Transportation*, 1 (2019) 1813763.

[84] M. Fakhri, R.S. Dezfoulian, Pavement structural evaluation based on roughness and surface distress survey using neural network model, *Construction and Building Materials*, 204 (2019) 768–780.

[85] O. Kaya, H. Ceylan, S. Kim, D. Waid, and B.P. Moore, Statistics and Artificial Intelligence-Based Pavement Performance and Remaining Service Life Prediction Models for Flexible and Composite Pavement Systems, *Transportation Research Record*, 2674(10) (2020) 448-460.

[86] H. Gong, Y. Sun, X. Shu, B. Huang, Use of random forests regression for predicting IRI of asphalt pavements, *Construction and Building Materials*, 189 (2018) 890–897.

[87] N. Solatifar, S.M. Lavasani, Development of An Artificial Neural Network Model for Asphalt Pavement Deterioration Using LTPP Data, *Journal of Rehabilitation in Civil Engineering*, 8(1) (2020) 121-132.

[88] M.Z. Bashar, C. Torres-Machi, Performance of Machine Learning Algorithms in Predicting the Pavement International Roughness Index, *Transportation Research Record*, 2675(5) (2021) 226-237.

[89] A. Issa, H. Samaneh, M. Ghanim, Predicting pavement condition index using artificial neural networks approach, *Ain Shams Engineering Journal*, 13(1) (2022) 101490.

[90] M. Ghodratabadi, A. Golroo, M.S. Entezari, Machine learning for predicting pavement roughness and optimising maintenance, *Road Materials and Pavement Design*, (2025) 1-20.

[91] K. Chen, M.E. Torbaghan, N. Thom, A. Faramarzi, Physics-guided neural network for predicting international roughness index on flexible pavements considering accuracy, uncertainty and stability, *Engineering Applications of Artificial Intelligence*, 142 (2025) 109922.

[92] A. Yazdi, M.H. Dehnad, A Case Study on Predicting Asphalt Pavement Distress Using Advanced Machine Learning Techniques and Road Surface Inspection



Rehabilitation Planning, Amirkabir Journal of Civil Engineering, 53(7) (2021) 2801-2820 (in Persian).

[103] P. Ghaderi, A. Abdolmaaleki, A novel unsupervised deep neural network-based method for damage detection in civil structures, Modarres Civil Engineering Journal, 22(1) (2022) 143-159 (in Persian).