

پیش‌بینی مقاومت فشاری و تحلیل اهمیت پارامترهای طرح اختلاط و ساخت در مخلوط‌های اساس تثبیت‌شده با سیمان حاوی خرده مصالح آسفالتی با استفاده از یادگیری ماشین

مقاله علمی - پژوهشی

*سید محمد منصورزاده (نویسنده مسئول)، استادیار، مرکز تحقیقات راه، مسکن و شهرسازی، تهران، ایران
*پست الکترونیکی نویسنده مسئول: m.mansoorzadeh@bhrc.ac.ir

دریافت: ۱۴۰۵/۰۲/۰۵ - پذیرش: ۱۴۰۵/۰۵/۰۵

صفحه ۱-۲۲

چکیده

در این پژوهش، با استفاده از روش‌های یادگیری ماشین، مقاومت فشاری محدود نشده مخلوط‌های اساس تثبیت‌شده با سیمان حاوی ۱۰۰٪ خرده مصالح آسفالتی (RAP) مورد پیش‌بینی و تحلیل قرار گرفت. بدین منظور، پایگاه داده‌ای حاصل از یک برنامه گسترده آزمایشگاهی شامل ۵۴۰ نمونه فشاری در سنین مختلف عمل‌آوری تهیه شد. نمونه‌ها در سه درصد مختلف سیمان (۵، ۵ و ۶ درصد) و سه درصد آب (۵/۵، ۵/۶ و ۵/۷ درصد) و با استفاده از دو روش تراکم مطابق استانداردهای ASTM D1557 و ASTM D558 ساخته شدند. همچنین، به منظور بهبود عملکرد مکانیکی مخلوط‌ها، از افزودنی پلیمری-معدنی نیکوفلاک به میزان ۱۰ درصد وزنی سیمان استفاده گردید. در ادامه، عملکرد الگوریتم‌های مختلف یادگیری ماشین شامل جنگل تصادفی، رگرسیون خطی، رگرسیون بردار پشتیبان، نزدیک‌ترین همسایه، پرسپترون چندلایه و توجه به خود در پیش‌بینی مقاومت فشاری محدود نشده مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل‌های مبتنی بر یادگیری ماشین قادرند مقاومت فشاری را با دقت قابل قبولی پیش‌بینی نمایند، به گونه‌ای که مقادیر پیش‌بینی‌شده انطباق مناسبی با داده‌های واقعی آزمایشگاهی داشتند. همچنین، با استفاده از روش‌های تحلیل اهمیت ویژگی‌ها همچون شاپ، اهمیت جابجشی و گرادیانت بوسینگ میزان تأثیر پارامترهای مختلف طرح اختلاط و ساخت بر مقاومت فشاری تعیین گردید. نتایج بیانگر آن بود که مدت زمان عمل‌آوری بیشترین تأثیر را بر مقاومت فشاری مخلوط‌ها داشته و درصد سیمان با فاصله در رتبه دوم تأثیرگذاری قرار دارد و سایر پارامترها از جمله استفاده از افزودنی، درصد رطوبت و روش تراکم به ترتیب در رتبه‌های بعدی اهمیت بودند. یادگیری ماشینی نه تنها می‌تواند پیش‌بینی UCS دقیقی ارائه دهد، بلکه می‌تواند تفسیر قابل اعتمادی از عوامل حاکم بر عملکرد مکانیکی مخلوط‌های RAP عمل‌آوری شده با سیمان نیز ارائه دهد.

واژه‌های کلیدی: تراشه آسفالت، مخلوط اساس تثبیت‌شده با سیمان حاوی ۱۰۰٪ تراشه آسفالت، مقاومت فشاری محدود نشده، افزودنی پلیمری معدنی نیکوفلاک، یادگیری ماشین

۱- مقدمه

مقرون به صرفه برای پروژه‌های اجرای روسازی جاده بسیار توصیه شده است. یکی از مواد بازیافتی، خرده مصالح آسفالتی یا تراشه آسفالت^۱ (RAP) است که از آسیاب شدن^۲، تراشیدن و یا به طور کامل برداشته شدن^۳ روسازی آسفالتی^۴ (HMA) موجود به دست می‌آید (Yuan et al., 2010). با هدف امکان استفاده از تراشه آسفالت به عنوان مصالح جایگزین و سازگار با

گرایش روزافزون به سمت استفاده از مصالح پایدار در صنعت ساختمان باعث شده است که مواد بازیافتی در کاربردهای مختلف مهندسی عمران مورد توجه قرار گیرند (Xiong et al., 2021). استفاده از مواد بازیافتی در نگهداری، تعمیر و بازسازی راه‌ها در دو دهه گذشته به طور فزاینده‌ای رایج شده است. این اقدام در راستای حفظ منابع طبیعی، کاهش ضایعات و تهیه مواد

مکانیکی مخلوط‌های تثبیت شده و از جمله مقاومت فشاری آنها تابعی از اجزای تشکیل دهنده مانند مصالح دانه‌ای، آب، سیمان (با بدون افزودنی) و همچنین پارامترهای ساخت، نظیر زمان عمل آوری و میزان تراکم هست. لذا مقاومت فشاری مخلوط‌های CTB تابع عوامل یا پارامترهای متعددی است که روابط بین این پارامترها غیرخطی هستند.

امروزه تخمین مقاومت مخلوط خاک سیمان از اهمیت خاصی برخوردار است و برای این کار می‌توان با داشتن داده‌های تجربی و الگوریتم‌های یادگیری ماشین^۱ (ML)، مقاومت این مصالح را بر اساس برخی از اجزای تشکیل دهنده آن و همچنین نوع فرآوری آن تخمین زد.

برای تخمین مقاومت مخلوط خاک سیمان می‌توان از الگوریتم‌های یادگیری ماشین استفاده نمود که این امر فوایدی را در پی دارد. الگوریتم‌های ML می‌توانند الگوها و روابطی را از مجموعه داده‌های بزرگی که انسان‌ها قادر به شناسایی آن‌ها نباشند، بیاموزند. این امر می‌تواند به پیش بینی‌های دقیق تر از مقاومت مخلوط منجر شود. این الگوریتم‌ها می‌توانند حجم زیادی از داده‌ها را به سرعت و با کارآمدی زیاد پردازش کنند که این موضوع می‌تواند در مقایسه با روش‌های سنتی در زمان صرفه‌جویی کند. همچنین می‌تواند هزینه آزمایش و تجزیه و تحلیل را کاهش دهند، زیرا می‌توانند مقاومت مخلوط را بر اساس چند پارامتر ورودی به جای نیاز به آزمایش‌های آزمایشگاهی گران قیمت تخمین بزنند. از طرفی این الگوریتم‌ها را می‌توان بر روی طیف گسترده‌ای از پارامترهای ورودی آموزش داد، که در مواردی که روش‌های سنتی ممکن است به دلیل تغییر در ترکیب مخلوط، عوامل محیطی یا سایر متغیرها مناسب نباشند، می‌تواند مفید باشد. از سویی دیگر، با جمع‌آوری داده‌های بیشتر و توسعه الگوریتم‌های جدید، دقت تخمین مقاومت مبتنی بر ML می‌تواند در طول زمان بهبود یابد.

به طور کلی، برآورد مقاومت مبتنی بر ML می‌تواند نتایج دقیق، کارآمد و مقرون به صرفه تری را در مقایسه با روش‌های سنتی ارائه دهد و آن را به ابزاری ارزشمند برای تخمین مقاومت مخلوط خاک سیمان در پروژه‌های ساختمانی تبدیل کند.

در سال‌های اخیر، کاربرد روش‌های یادگیری ماشین در مهندسی ژئوتکنیک و روسازی به‌طور قابل توجهی افزایش یافته است. شبکه‌های عصبی مصنوعی به دلیل توانایی در مدل‌سازی روابط پیچیده و غیرخطی میان متغیرهای ورودی و خروجی، به‌طور گسترده برای پیش‌بینی خواص مکانیکی مصالح مورد استفاده قرار گرفته‌اند. پژوهش‌های متعددی نشان داده‌اند که این روش‌ها در پیش‌بینی ظرفیت باربری پی‌ها، نشست خاک، پایداری شیب‌ها و همچنین خواص خاک‌های تثبیت‌شده عملکرد مناسبی دارند (Aljanabi and Salih, 2023). در چند مطالعه مختلف،

محیط زیست در روسازی جاده‌ها، لازم است که خواص مهندسی مورد نیاز بهبود داده شود. مصالح تراشه آسفالت هنگامی که به‌عنوان یک جایگزین کامل برای سنگدانه‌های طبیعی استفاده می‌شود، اغلب حداقل الزامات مصالح لایه اساس مشخص شده توسط دستورالعمل‌های بین‌المللی و محلی اداره راه‌های دولتی را برآورده نمی‌کنند.

از این رو، نیاز به نوعی بهبود داشته و تثبیت شیمیایی توسط سیمان پرتلند به‌طور گسترده‌ای در ساخت جاده‌های جدید و بازسازی جاده‌های آسیب دیده استفاده می‌شود، زیرا خواص مهندسی می‌تواند به سرعت پس از تثبیت مواد تراشه آسفالت بهبود یابد. عملکرد تراشه آسفالت تثبیت شده با سیمان، الزامات کاربرد لایه اساس و زیر اساس روسازی را برآورده می‌کند (Suddeepong et al., 2018).

بازیافت روسازی‌های انعطاف‌پذیر آسیب‌دیده اغلب به دلیل ضرورت حفظ منابع طبیعی و افزایش هزینه‌های ساخت انجام شده است (Fedrigo et al.; 2018). بازسازی و بهسازی^۲ روسازی‌های موجود، مقادیر زیادی تراشه آسفالت تولید می‌کند. تراشه آسفالت به‌عنوان مصالح آسیب دیده روسازی تعریف می‌شود که از روسازی آسفالت موجود حذف و یا دوباره اصلاح و تثبیت می‌شوند. بنابراین، RAP شامل مخلوطی از سنگدانه‌های روسازی و پوشش قیری قدیمی است. به‌طور معمول، حذف یا برداشتن روسازی موجود با تراشیدن و آسیاب نمودن سطوح فوقانی یا با برداشتن کامل روسازی انجام می‌شود. به‌طور مثال از ماشین تراش یا آسیاب^۳ آسفالت برای برداشتن ۵۰ میلی‌متر بالای سطح روسازی در یک گذر استفاده می‌شود، در حالی که برای برداشتن عمق کامل روسازی از بولدوزر^۴ در چندین قطعه استفاده می‌شود (Suddeepong et al., 2018).

در یک مطالعه تجربی، با آزمایش بر روی مصالح RAP تثبیت شده با درصد‌های مختلف سیمان و درصد‌های مختلف یک افزودنی شیمیایی، به ارزیابی فناوری احیای تمام عمق^۵ (FDR) پرداخته شد. در این مطالعه به‌منظور شناسایی اثر محتوای سیمان و افزودنی شیمیایی، خواص مهندسی مختلف مخلوط تثبیت شده مورد ارزیابی قرار گرفت و در این راستا چهار محتوای سیمان ۳،۵، ۴، ۴،۵ و ۵ درصد و پنج محتوای افزودنی شیمیایی ۰، ۳، ۳،۵، ۴ و ۴،۵ درصد وزنی سیمان در ساخت نمونه‌ها اعمال شد. براساس داده‌های آزمایش، مشخص شد که مخلوط تهیه شده با ۴/۵ درصد سیمان و ۴ درصد افزودنی شیمیایی بهترین نتیجه را از نظر پارامترهای مقاومتی و خواص دوام نمونه‌های مورد مطالعه دارا هستند (Chhabra et al., 2021).

اساس تثبیت شده با سیمان^۶ (CTB) مخلوطی از سنگدانه‌ها، سیمان و آب است که از طریق گیرش سیمان پس از تراکم آن سخت می‌شود و لایه‌ای قوی و بادوام ایجاد می‌کند. خواص

از شبکه‌های عصبی و سایر روش‌های هوشمند برای پیش‌بینی مقاومت فشاری محدود نشده^{۱۱} (UCS) و سایر ویژگی‌های خاک‌های تثبیت‌شده استفاده شده و دقت بالای این مدل‌ها گزارش شده است (Taha et al., 2018; Hanandeh et al., 2020; Tabarsa et al., 2021). از سوی دیگر، در مطالعه‌ای با بهره‌گیری از روش‌های هوش مصنوعی برای پیش‌بینی مقاومت فشاری خاک تثبیت‌شده با سیمان نشان دادند که مدل‌های یادگیری ماشین قادرند با استفاده از داده‌های آزمایشگاهی، رفتار مقاومتی مصالح را با دقت قابل قبولی برآورد نمایند (Ngo et al., 2021).

یکی از مهم‌ترین زمینه‌های کاربرد این روش‌ها، پیش‌بینی مقاومت فشاری محدود نشده مصالح تثبیت‌شده است؛ زیرا انجام آزمایش‌های آزمایشگاهی گسترده مستلزم صرف زمان، هزینه و نیروی انسانی قابل توجهی است. در این راستا، پژوهشگران مختلف از الگوریتم‌هایی نظیر شبکه عصبی مصنوعی^{۱۲} (ANN)، رگرسیون بردار پشتیبان^{۱۳} (SVR)، جنگل تصادفی^{۱۴} (RF) و روش‌های مبتنی بر تقویت نظیر گرادیانت بوسستینگ^{۱۵} (GB) برای مدل‌سازی رفتار مقاومتی انواع مصالح تثبیت‌شده، خاک‌ها و مصالح مورد استفاده در روسازی بهره گرفته‌اند (Abdullah et al., 2024; Aljanabi and Salih, 2023; Ngo et al., 2023; Tran, 2023).

مطالعات مقایسه‌ای نشان داده‌اند که الگوریتم‌های مبتنی بر درخت تصمیم و روش‌های تقویتی نظیر جنگل تصادفی و گرادیانت بوسستینگ در بسیاری از موارد عملکرد بهتری نسبت به روش‌های سنتی رگرسیونی از خود نشان می‌دهند (Ngo et al., 2023; Tran, 2023). علاوه بر این، استفاده از مدل‌های رگرسیون بردار پشتیبان و نزدیکترین همسایه^{۱۶} (KNN) نیز در پیش‌بینی خواص مکانیکی مصالح ژئوتکنیکی و روسازی نتایج امیدوارکننده‌ای به همراه داشته است (Abdullah et al., 2024; Hoque et al., 2023).

در یک مطالعه با استفاده از شبکه عصبی مصنوعی، پیش‌بینی مقاومت فشاری محدود نشده مخلوط‌های بازیافتی تثبیت‌شده با سیمان حاوی مصالح خرده آسفالتی مطالعه شده و دقت بالایی برای مدل‌های توسعه‌یافته گزارش شد. نتایج این پژوهش نشان داد که روش‌های مبتنی بر هوش مصنوعی قادرند رفتار مقاومتی مخلوط‌های تثبیت‌شده حاوی تراشه آسفالت را با دقت مناسب مدل‌سازی نمایند. با این حال، تمرکز اصلی این مطالعه بر پیش‌بینی مقاومت فشاری بوده و تحلیل و مقایسه اهمیت نسبی پارامترهای مؤثر بر مقاومت فشاری مورد بررسی قرار نگرفته است (Chhabra et al., 2024).

در سال‌های اخیر، علاوه بر توسعه مدل‌های دقیق برای پیش‌بینی خواص مهندسی، توجه پژوهشگران به تفسیرپذیری مدل‌های

یادگیری ماشین و شناسایی عوامل مؤثر بر متغیرهای هدف نیز افزایش یافته است. اگرچه الگوریتم‌هایی نظیر شبکه عصبی مصنوعی، جنگل تصادفی و روش‌های مبتنی بر تقویت قادر به دستیابی به دقت پیش‌بینی بالایی هستند، اما ماهیت جعبه سیاه این مدل‌ها، تفسیر نتایج و تعیین سهم هر متغیر در پیش‌بینی خروجی را با چالش مواجه می‌سازد. به همین دلیل، در سال‌های اخیر روش‌های تحلیل اهمیت ویژگی‌ها نظیر شاپ^{۱۷} (SHAP) و اهمیت جایگشتی^{۱۸} (PI) به‌طور گسترده مورد استفاده قرار گرفته‌اند. به‌عنوان مثال، Ngo و همکاران (۲۰۲۳) در پیش‌بینی مقاومت فشاری خاک تثبیت‌شده با ژئوپلیمر، علاوه بر مقایسه مدل‌های مختلف یادگیری ماشین، از روش SHAP برای تعیین سهم متغیرهای ورودی استفاده کردند و نشان دادند که این روش قادر است نقش نسبی هر پارامتر را به‌صورت کمی تبیین نماید (Lundberg et al., 2017; Ngo et al., 2023). همچنین، پژوهش‌های اخیر در زمینه پیش‌بینی مقاومت فشاری مصالح تثبیت‌شده و مواد ژئوتکنیکی نشان داده‌اند که ترکیب مدل‌های پیش‌بینی با روش‌های شاپ و اهمیت جایگشتی، علاوه بر افزایش قابلیت تفسیر مدل، امکان رتبه‌بندی پارامترهای مؤثر و درک بهتر رفتار مصالح را فراهم می‌آورد. با وجود این، مطالعات محدودی به بررسی و مقایسه هم‌زمان روش‌های مختلف تحلیل اهمیت ویژگی‌ها در مخلوط‌های اساس تثبیت‌شده با سیمان حاوی مصالح خرده آسفالتی پرداخته‌اند که این موضوع یکی از اهداف اصلی پژوهش حاضر محسوب می‌شود.

با وجود تحقیقات انجام‌شده در زمینه پیش‌بینی مقاومت فشاری مصالح تثبیت‌شده، مطالعات محدودی به بررسی هم‌زمان عملکرد مدل‌های مختلف یادگیری ماشین و مقایسه روش‌های تحلیل اهمیت ویژگی‌ها در مخلوط‌های اساس تثبیت‌شده با سیمان حاوی مصالح خرده آسفالتی پرداخته‌اند. از این‌رو، در پژوهش حاضر با بهره‌گیری از الگوریتم‌های MLP (پرسپترون چند لایه^{۱۹})، RF، KNN، SVR و سه رویکرد مستقل شامل SHAP، اهمیت جایگشتی و گرادیانت بوسستینگ، ضمن توسعه مدل‌های پیش‌بینی مقاومت فشاری محدود نشده (UCS)، اهمیت نسبی پارامترهای طرح اختلاط و ساخت شامل سن عمل‌آوری، درصد سیمان، وجود یا عدم وجود افزودنی، درصد آب و روش تراکم، با استفاده از روش‌های مختلف تحلیل اهمیت ویژگی‌ها مورد ارزیابی و مقایسه قرار گرفته است.

در این راستا تلاش شده تا مدل ارائه شده بر اساس مشاهده داده‌های در دسترس که حاصل از آزمایشات تجربی در آزمایشگاه می‌باشند به یک تعمیم کلی دست یابد و از این طریق بتواند میزان مقاومت مخلوط خاک سیمان برای ترکیباتی که تاکنون مشاهده نشده است را تخمین بزند. داده‌های مورد استفاده در این پژوهش از یک برنامه آزمایشگاهی گسترده استخراج

۲- مواد، برنامه آزمایشگاهی و روش تحقیق

۲-۱- مصالح مورد استفاده

مصالح تراشه آسفالت، سیمان و افزودنی شیمیایی در تحقیق حاضر با مصالح تراشه آسفالت، سیمان و افزودنی شیمیایی مورد استفاده در مطالعه دیگری (منصورزاده، ۱۴۰۲) یکسان بود. افزودنی پلیمری-معدنی نیکوفلاک^{۲۰} مورد استفاده قرار گرفت. پارامترهای دانه‌بندی مصالح تراشه آسفالت مورد مطالعه در جدول ۱ ارائه شده است. این مصالح با توجه به ضریب یکنواختی^{۲۱} بزرگتر از ۶ و ضریب انحنای^{۲۲} که در محدوده بین ۱ و ۳ می‌باشد، از نوع ماسه خوب دانه‌بندی شده هست و بر اساس سیستم طبقه‌بندی متحد^{۲۳} با علامت SW نمایش داده می‌شود. آزمایش حدود اتربرگ نیز انجام شد و مشخص گردید که بخش ریزدانه این مصالح، غیر خمیری است. دیگر مشخصات مصالح از قبیل منحنی دانه بندی مصالح تراشه آسفالت و همچنین خصوصیات شیمیایی سیمان و افزودنی شیمیایی در مطالعه دیگری (Mansoorzadeh et al., 2026) ارائه شده است.

شده‌اند که نتایج آزمایشگاهی آن قبلاً منتشر شده است؛ با این حال، در پژوهش حاضر، این داده‌ها به‌منظور توسعه و تحلیل مدل‌های یادگیری ماشین مورد استفاده قرار گرفته‌اند.

با وجود مطالعات متعدد در زمینه پیش‌بینی مقاومت با ML مطالعات محدودی روی مخلوط‌های CTB حاوی ۱۰۰٪ مصالح خرد آسفالتی انجام شده؛ و مهم‌تر این که تحلیل اهمیت نسبی پارامترهای طرح اختلاط و ساخت در این مخلوط‌ها کمتر بررسی شده است. بر این اساس، هدف این پژوهش، توسعه مدل‌های مبتنی بر یادگیری ماشین به‌منظور پیش‌بینی مقاومت فشاری محدود نشده مخلوط‌های اساس تثبیت‌شده با سیمان حاوی ۱۰۰٪ مصالح خرد آسفالتی و همچنین تحلیل اهمیت پارامترهای طرح اختلاط و ساخت بر مقاومت فشاری این مخلوط‌ها می‌باشد. بدین منظور، عملکرد الگوریتم‌های مختلف یادگیری ماشین مورد ارزیابی قرار گرفته و میزان تأثیر هر یک از پارامترهای ورودی بر مقاومت فشاری تعیین شده است.

جدول ۱. پارامترهای دانه‌بندی مصالح تراشه آسفالت مورد مطالعه

پارامترهای دانه‌بندی	ویژگی‌ها	مقدار (میلی‌متر)
اندازه موثر ^{۲۴}	D ₁₀ (mm)	۰/۵۵
اندازه روزه که ۳۰ درصد از مصالح از آن کوچکتر است	D ₃₀ (mm)	۲
اندازه متوسط ^{۲۵}	D ₅₀ (mm)	۳/۸
اندازه روزه که ۳۰ درصد از مصالح از آن کوچکتر است	D ₆₀ (mm)	۵
ضریب یکنواختی	C _u	۹/۰۹
ضریب انحنای	C _c	۱/۴۵
درصد رد شده از الک ۲۰۰	Fine content (%) (less than 0.075 mm)	۱
درصد ذرات با اندازه ماسه	% Sand Size	۵۷
درصد ذرات با اندازه شن	%(4.75–19)mm	۴۲
حداکثر اندازه سنگدانه ^{۲۶}	Maximum size (D _{max}) mm	۱۹

لازم به ذکر است به منظور بررسی تغییرات رطوبت ساخت، علاوه بر رطوبت بهینه، رطوبت‌های کمتر و بیشتر از بهینه نیز مورد ارزیابی قرار گرفت. لذا به منظور ادامه روند تحقیق، درصد آب مصرفی در سه درصد ۵،۵، ۶،۵ و ۷،۵ درصد انتخاب گردید. نمونه‌های استوانه‌ای تثبیت شده با سیمان (با و بدون افزودنی) در قالب استوانه‌ای فلزی با قطر

۲-۲- برنامه آزمایشگاهی و تهیه نمونه‌ها

در این مطالعه از دو نوع آزمایش تراکم با دو سطح متفاوت انرژی تراکم استفاده گردید. یکی آزمایش تراکم اصلاح شده با انرژی تراکم ۲۷۰۰ کیلو نیوتن (ASTM D1557) و دیگری آزمایش تراکم ویژه مخلوط‌های خاک-سیمان با انرژی تراکم ۶۰۰ کیلو نیوتن (ASTM D558) هست.

۱۰/۱ سانتی‌متر و ارتفاع ۱۱/۶ سانتی‌متر در ۳ لایه یا ۵ لایه (با توجه به میزان انرژی تراکم) با ضخامت یکسان مطابق با استاندارد مربوطه کوبیده شدند. برای ساخت نمونه‌ها مطابق جدول ۲ وزن مخصوص خشک حداکثر^{۲۷} و مقدار رطوبت بهینه^{۲۸} در روش تراکم اصلاح شده (ASTM D1557) به ترتیب برابر با ۲۱/۳ کیلو نیوتن بر متر مکعب (معادل با ۲/۱۷ گرم بر سانتیمتر مکعب) و ۶/۵ درصد و در روش تراکم ASTM D558 به ترتیب برابر با ۲۰/۷ کیلو نیوتن بر متر مکعب (معادل با ۲/۱۱ گرم بر سانتیمتر مکعب) و ۷/۵ درصد در نظر گرفته شد. عمل آوری نمونه‌های مورد نیاز برای انجام آزمایش UCS در اتاق رطوبت در دمای ۲۳ درجه سلسیوس و رطوبت نسبی حدود ۱۰۰ درصد در دوره‌های ۳، ۷، ۲۸، ۵۶ و ۹۰ روزه مطابق با استاندارد ASTM D1632 انجام شده است. سایر مشخصات مربوط به تهیه مخلوط و نمونه‌ها و همچنین روش انجام آزمایش مقاومت فشاری محدود نشده در مطالعه دیگری (منصورزاده، ۱۴۰۲) ارائه شده است.

۲-۳- تشکیل پایگاه داده

پایگاه داده مورد استفاده در این پژوهش شامل ۵۴۰ نتیجه آزمایش مقاومت فشاری محدود نشده حاصل از ۱۸۰ ترکیب آزمایشی بود. به طوری که برای هر ترکیب، سه نمونه مستقیلاً ساخته و سپس عمل آوری و آزمایش شده و مقادیر به دست آمده

به عنوان رکوردهای پایگاه داده در توسعه و ارزیابی مدل‌های یادگیری ماشین مورد استفاده قرار گرفتند. متغیرهای ورودی شامل درصد سیمان، درصد آب، سن عمل‌آوری، روش تراکم و وجود یا عدم وجود افزودنی پلیمری-معدنی نیکوفلاک بودند و مقاومت فشاری محدود نشده به عنوان متغیر هدف در نظر گرفته شد. برای مخلوط‌های اساس تثبیت شده سیمانی، سیمان با درصد‌های ۴، ۵ و ۶ درصد با و بدون افزودن نیکوفلاک (به میزان ۱۰ درصد وزن سیمان مصرفی در هر مخلوط) استفاده گردید. درصد آب مصرفی نیز در سه حالت ۵، ۶، ۷ و ۸٪ استفاده شد. نهایتاً تعداد ۳۶ طرح مخلوط در این تحقیق مطابق جدول ۲ بکار گرفته شد. با توجه به تعداد دوره عمل‌آوری برابر با ۵ و ساخت نمونه‌ها با سه تکرار مجموع کل نمونه‌های تحت آزمایش فشاری محدود نشده برابر با ۵۴۰ نمونه است. در نام گذاری نمونه‌ها، از حروف C (سیمان)، CN (سیمان حاوی نیکوفلاک) و W (آب) استفاده شد. عدد ذکر شده بعد از هر حرف نشان دهنده درصد مصرفی آن ماده و عدد ۷ و ۸ بعد از حرف D به ترتیب نشان دهنده روش تراکم ASTM D1557 یا ASTM D558 است. بطور مثال در نمونه C4W6D7، ۴ درصد سیمان و ۶،۵ درصد آب استفاده شده است که با روش تراکم ASTM D1557 متراکم گردیده است. در جدول ۳ مشخصات متغیرهای ورودی و خروجی و در جدول ۴ آمار توصیفی متغیر هدف ارائه شده است.

جدول ۲. معرفی شناسه و تفاسیر نمونه‌های این پژوهش

ردیف	کد مخلوط	سیمان (%)	نیکوفلاک (%)	آب (%)	سن عمل‌آوری (روز)	ASTM-D	ردیف	کد مخلوط	سیمان (%)	نیکوفلاک (%)	آب (%)	سن عمل‌آوری (روز)	ASTM-D
1	C4W5D7	4	-	5.5	3, 7, 28, 56, 90	1557	19	C4W5D8	4	-	5.5	3, 7, 28, 56, 90	558
2	C4W6D7	4	-	6.5	3, 7, 28, 56, 90	1557	20	C4W6D8	4	-	6.5	3, 7, 28, 56, 90	558
3	C4W7D7	4	-	7.5	3, 7, 28, 56, 90	1557	21	C4W7D8	4	-	7.5	3, 7, 28, 56, 90	558
4	CN4W5D7	4	0.4	5.5	3, 7, 28, 56, 90	1557	22	CN4W5D8	4	0.4	5.5	3, 7, 28, 56, 90	558
5	CN4W6D7	4	0.4	6.5	3, 7, 28, 56, 90	1557	23	CN4W6D8	4	0.4	6.5	3, 7, 28, 56, 90	558
6	CN4W7D7	4	0.4	7.5	3, 7, 28, 56, 90	1557	24	CN4W7D8	4	0.4	7.5	3, 7, 28, 56, 90	558
7	C5W5D7	5	-	5.5	3, 7, 28, 56, 90	1557	25	C5W5D8	5	-	5.5	3, 7, 28, 56, 90	558
8	C5W6D7	5	-	6.5	3, 7, 28, 56, 90	1557	26	C5W6D8	5	-	6.5	3, 7, 28, 56, 90	558
9	C5W7D7	5	-	7.5	3, 7, 28, 56, 90	1557	27	C5W7D8	5	-	7.5	3, 7, 28, 56, 90	558
10	CN5W5D7	5	0.5	5.5	3, 7, 28, 56, 90	1557	28	CN5W5D8	5	0.5	5.5	3, 7, 28, 56, 90	558
11	CN5W6D7	5	0.5	6.5	3, 7, 28, 56, 90	1557	29	CN5W6D8	5	0.5	6.5	3, 7, 28, 56, 90	558
12	CN5W7D7	5	0.5	7.5	3, 7, 28, 56, 90	1557	30	CN5W7D8	5	0.5	7.5	3, 7, 28, 56, 90	558
13	C6W5D7	6	-	5.5	3, 7, 28, 56, 90	1557	31	C5W5D8	6	-	5.5	3, 7, 28, 56, 90	558
14	C6W6D7	6	-	6.5	3, 7, 28, 56, 90	1557	32	C5W6D8	6	-	6.5	3, 7, 28, 56, 90	558
15	C6W7D7	6	-	7.5	3, 7, 28, 56, 90	1557	33	C5W7D8	6	-	7.5	3, 7, 28, 56, 90	558
16	CN6W5D7	6	0.6	5.5	3, 7, 28, 56, 90	1557	34	CN5W5D8	6	0.6	5.5	3, 7, 28, 56, 90	558
17	CN6W6D7	6	0.6	6.5	3, 7, 28, 56, 90	1557	35	CN5W6D8	6	0.6	6.5	3, 7, 28, 56, 90	558
18	CN6W7D7	6	0.6	7.5	3, 7, 28, 56, 90	1557	36	CN5W7D8	6	0.6	7.5	3, 7, 28, 56, 90	558

جدول ۳. مشخصات متغیرهای ورودی و خروجی


دامنه	نوع متغیر	متغیر
۴ تا ۶ درصد	عددی	درصد سیمان
۵,۵ تا ۷,۵ درصد	عددی	درصد آب
۳ تا ۹۰ روز	عددی	سن عمل‌آوری
ASTM D1557 و ASTM D558	طبقه‌ای	روش تراکم
با افزودنی و بدون افزودنی	طبقه‌ای	افزودنی پلیمری-معذنی نیکوفلاک
۱۶,۲ تا ۷۷,۳ کیلوگرم بر سانتیمتر مربع	خروجی	مقاومت فشاری محدودنشده

جدول ۴. آمار توصیفی متغیر هدف


انحراف معیار	میانگین	حداکثر	چارک سوم (Q3)	میان (Q2)	چارک اول (Q1)	حداقل	متغیر
11.74	43.20	77.3	51.83	43.00	35.38	16.2	مقاومت فشاری محدودنشده (UCS)

بررسی آمار توصیفی پایگاه داده نشان می‌دهد که مقادیر مقاومت فشاری محدودنشده در بازه ۱۶,۲ تا ۷۷,۳ کیلوگرم بر سانتی‌متر مربع قرار داشته و میانگین آن برابر با ۴۳,۲ کیلوگرم بر سانتی‌متر مربع است. همچنین، وجود دامنه مناسب تغییرات در متغیرهای ورودی و خروجی، شرایط لازم برای توسعه و ارزیابی مدل‌های یادگیری ماشین را فراهم نموده است. برای استفاده از الگوریتم‌های یادگیری ماشین در این تحقیق لازم است که ابتدا متغیرهای ورودی و خروجی در این بخش معرفی


شوند. متغیرهای ورودی عبارتند از سیمان، آب، افزودنی، میزان تراکم و دوره عمل‌آوری و متغیرهای خروجی نیز مقادیر UCS متناظر با هر ترکیب هستند. لذا ۵۴۰ داده خروجی داریم که این داده‌ها خود به عنوان ورودی در یادگیری ماشین هستند. در شکل‌های ۱ و ۲ و ۳ به ترتیب نمودارهای هیستوگرام^{۲۹}، جعبه‌ای^{۳۰} (باکس پلات) و پراکندگی^{۳۱} (اسکتر) داده‌های مقاومت فشاری محدود نشده به عنوان داده هدف ارائه شده است.



شکل ۱. هیستوگرام داده‌های هدف



شکل ۲. نمودار باکس پلات داده‌های هدف



شکل ۳. نمودار پراکندگی داده‌های هدف

در ابتدا نیاز است تا داده‌ها استاندارد شوند. برای این کار از رابطه ۱ استفاده شد.

$$Z = \frac{x - \mu}{\sigma} \quad (1)$$

که در رابطه فوق μ میانگین و σ انحراف از معیار است. لازم به ذکر است که عملیات استانداردسازی پس از تفکیک داده‌ها به دو دسته آموزش^{۳۳} و ارزیابی^{۳۴} صورت گرفت. همچنین نسبت داده آموزش به تست برابر با ۸۵ درصد به ۱۵ درصد در نظر گرفته شد.

۲-۴-۲- روش‌های بکار گرفته شده

جنگل تصادفی (RF)

جنگل تصادفی یک الگوریتم یادگیری ماشینی است که هم برای وظایف رگرسیون و هم برای طبقه بندی استفاده می‌شود. این یک روش یادگیری گروهی است که چندین درخت تصمیم را برای ایجاد یک مدل دقیق‌تر و قوی‌تر ترکیب می‌کند.

ایده اصلی پشت الگوریتم جنگل تصادفی ایجاد تعداد زیادی درخت تصمیم است که هر کدام بر روی یک زیرمجموعه تصادفی از داده‌ها و یک زیر مجموعه تصادفی از ویژگی‌ها آموزش داده شده‌اند. این تصادفی بودن به جلوگیری از برازش بیش از حد کمک می‌کند و تعمیم مدل را بهبود می‌بخشد. در طول فرآیند آموزش، هر درخت در الگوریتم جنگل تصادفی یک پیش‌بینی برای یک ورودی داده شده انجام می‌دهد و

با توجه به تعداد بالای نتایج بدست آمده، با بکارگیری الگوریتم‌های ML و همچنین یادگیری عمیق^{۳۳} (DL)، مقاومت UCS مخلوط CTB حاوی ۱۰۰ درصد تراشه آسفالت بر اساس یک سری از پارامترهای موجود همچون درصد آب و سیمان و ... پیش‌بینی گردید. برای دستیابی به مدل پیش‌بینی مناسب، باید تلاش شود تا مدل ارائه شده بر اساس مشاهده داده‌های در دسترس که حاصل از آزمایشات تجربی در آزمایشگاه می‌باشند به یک تعمیم کلی دست یابد و از این طریق بتواند میزان UCS مخلوط برای ترکیباتی که تاکنون مشاهده نکرده است را تخمین بزند. به طور کلی، برآورد مقاومت مبتنی بر ML می‌تواند نتایج دقیق، کارآمد و مقرون به صرفه تری را در مقایسه با روش‌های سنتی ارائه دهد و آن را به ابزاری ارزشمند برای تخمین مقاومت لایه اساس تثبیت شده در پروژه‌های راهسازی تبدیل کند.

۲-۴-۲- الگوریتم‌های یادگیری ماشین

۲-۴-۲-۱- پیش پردازش و آماده سازی داده‌ها

نتایج این تحقیق شامل ۵۴۰ داده بدست آمده از نتایج آزمایش UCS برای مخلوط CTB با ۵ متغیر موثر شامل: درصد سیمان (C)، درصد رطوبت (W)، وجود یا عدم وجود افزودنی، روش تراکم (D) و همچنین سن یا دوره عمل آوری مخلوط (A) هستند. و به عبارت دیگر فیچرها یا ویژگی‌های ورودی مدل یادگیری ماشین (ML) موارد گفته شده هستند. از آن جایی که مقادیر هر یک از این ویژگی‌ها دارای بازه‌های متفاوت هستند،

ب) انتخاب مقدار k می‌تواند بر دقت الگوریتم تأثیر بگذارد و ممکن است برای تعیین مقدار بهینه نیاز به آزمون و خطا داشته باشد.

ج) می‌تواند به انتخاب متریک فاصله و نرمال سازی ویژگی‌ها حساس باشد.

به طور کلی، این الگوریتم می‌تواند ابزار مفیدی برای حل مسائل طبقه‌بندی و رگرسیون باشد، به ویژه در سناریوهایی با مجموعه داده‌های کوچک و فضاهای ویژگی کم‌بعد.

برای آموزش مدل به کمک الگوریتم KNN بر روی داده‌های موجود با کمک سعی و خطا تعداد K برابر با ۲ در نظر گرفته شد.

رگرسیون بردار پشتیبان (SVR)

یک الگوریتم یادگیری ماشینی است که برای وظایف رگرسیون استفاده می‌شود. این بر اساس همان اصول ماشین‌های بردار پشتیبان SVM^{۳۶} است که یک الگوریتم محبوب برای کارهای طبقه‌بندی است. ایده اصلی پشت الگوریتم SVR یافتن یک ابر صفحه^{۳۷} در فضای ویژگی است که به بهترین وجه با نقاط داده مطابقت داشته باشد و در عین حال حاشیه یا فاصله بین ابر صفحه و نقاط داده نزدیک به آن را نیز به حداکثر برساند. این ابر صفحه توسط زیرمجموعه‌ای از نقاط داده که به عنوان بردارهای پشتیبانی شناخته می‌شوند، تعریف می‌شود.

هایپرپلن به صورت تکراری توسط SVM تولید می‌شود تا با یافتن بیشینه سطح حاشیه‌ای^{۳۸} MMH بتوان خطا را به حداقل رساند. در طول فرآیند آموزش، الگوریتم SVR به دنبال به حداقل رساندن خطا بین مقادیر پیش‌بینی‌شده و مقادیر واقعی داده‌های آموزشی است. در این راستا در SVR یک پارامتر قابل تنظیم^{۳۹} ϵ توسط کاربر تعریف می‌شود که ϵ برابر با عرض (پهنای) یک ناحیه در اطراف تابع تخمین است. این ناحیه اجازه می‌دهد تا برخی از خطاها را در پیش‌بینی تحمل کند، که می‌تواند به جلوگیری از برازش بیش از حد و بهبود تعمیم مدل کمک کند. برخی از ویژگی‌های کلیدی الگوریتم SVR عبارتند از:

الف) می‌تواند مشکلات رگرسیون خطی و غیرخطی را مدیریت کند.

ب) در برابر نقاط پرت و نویز در داده‌ها مقاوم است.

ج) این الگوریتم می‌تواند به خوبی با فضاهای ویژگی با ابعاد بالا کار کند.

پیش‌بینی نهایی میانگین (برای وظایف رگرسیون) یا حالت (برای وظایف طبقه‌بندی) پیش‌بینی‌های انجام شده توسط همه درختان است. برخی از مزایای کلیدی الگوریتم جنگل تصادفی عبارتند از:

الف) می‌تواند داده‌های دسته بندی و عددی را مدیریت کند.

ب) در برابر نقاط پرت و نویز در داده‌ها مقاوم است.

ج) در مقایسه با یک درخت تصمیم واحد، احتمال بیش از حد برازش شدن آن کم‌تر است.

د) این الگوریتم می‌تواند امتیازهای اهمیت ویژگی را ارائه دهد که برای انتخاب و تفسیر ویژگی‌ها مفید است.

برای آموزش مدل به کمک این الگوریتم بر روی داده‌های موجود از ۲۰۰۰ درخت تصمیم‌گیری استفاده شد.

نزدیک‌ترین همسایه (KNN)

یک الگوریتم یادگیری ماشینی است که برای کارهای طبقه‌بندی و رگرسیون استفاده می‌شود. نزدیک‌ترین همسایه، یک الگوریتم یادگیری غیر پارامتری است، به این معنی که هیچ فرضی در مورد توزیع داده‌های اساسی ایجاد نمی‌کند و نیازی به آموزش روی یک مجموعه داده از پیش تعریف شده ندارد. این الگوریتم با یافتن k نزدیک‌ترین همسایه به یک نقطه داده معین در فضای ویژگی^{۳۵} بر اساس یک متریک شباهت مانند فاصله اقلیدسی یا شباهت کسینوس کار می‌کند. سپس کلاس یا مقدار پیش‌بینی‌شده نقطه داده با در نظر گرفتن کلاس اکثریت یا مقدار میانگین k نزدیک‌ترین همسایه‌ها تعیین می‌شود.

برخی از ویژگی‌های کلیدی این الگوریتم عبارتند از:

الف) درک و پیاده سازی آن آسان است.

ب) می‌تواند مشکلات طبقه بندی چند کلاسه را حل کند.

ج) می‌تواند با مجموعه داده‌های کوچک و فضاهای ویژگی کم‌بعد به خوبی کار کند.

د) این الگوریتم نیازی به مرحله آموزش ندارد و از این رو می‌تواند در سناریوهایی که داده‌ها دائماً در حال تغییر هستند مفید باشد.

با این حال، برخی از اشکالات احتمالی این الگوریتم عبارتند از:

الف) این الگوریتم می‌تواند از نظر محاسباتی گران باشد، به ویژه برای مجموعه داده‌های بزرگ و فضاهای ویژگی با ابعاد بالا.

و ممکن است برای تعیین مقادیر بهینه نیاز به آزمون و خطا داشته باشد.

ج) ممکن است با مجموعه داده‌های نامتعادل یا مجموعه داده‌ها با تعداد کمی از نمونه‌های آموزشی، عملکرد خوبی نداشته باشد. به طور کلی، الگوریتم SVR می‌تواند ابزار مفیدی برای حل مسائل رگرسیون باشد، به ویژه در سناریوهایی با فضاهای ویژگی با ابعاد بالا و روابط پیچیده بین متغیرها. برای آموزش مدل به کمک الگوریتم SVR از پارامترهای ارائه شده در جدول ۵ استفاده گردید.

جدول ۵. هاپر پارامترهای الگوریتم SVR

Kernel	C	Epsilon
RBF	5	0.1

-لایه خروجی: این لایه خروجی نهایی شبکه را تولید می‌کند که می‌تواند یک برچسب طبقه بندی، یک مقدار پیش بینی شده یا یک توزیع احتمال باشد.

نورون‌ها در لایه‌های پنهان توسط وزنه‌هایی به هم متصل می‌شوند که در طول فرآیند آموزش تنظیم می‌شوند تا خطا بین خروجی‌های پیش‌بینی شده و خروجی‌های واقعی داده‌های آموزشی به حداقل برسد.

این فرآیند معمولاً با استفاده از تکنیکی به نام پس انتشار انجام می‌شود، که گرادینت‌های خطا را با توجه به وزن‌ها محاسبه می‌کند و با استفاده از یک الگوریتم بهینه سازی مانند نزول گرادینت، آن‌ها را تنظیم می‌کند.

برخی از ویژگی‌های کلیدی آن عبارتند از:

-می‌تواند روابط غیر خطی بین ورودی‌ها و خروجی‌ها را یاد بگیرد.

-این الگوریتم می‌تواند مجموعه داده‌های پیچیده را با ویژگی‌های با ابعاد بالا مدیریت کند.

-این الگوریتم می‌تواند پس از آموزش، به خوبی به داده‌های دیده نشده تعمیم دهد.

با این حال، برخی از اشکالات احتمالی آن عبارتند از:

-این الگوریتم می‌تواند از نظر محاسباتی گران باشد، به خصوص برای مجموعه داده‌های بزرگ و معماری‌های عمیق.

-ممکن است برای دستیابی به عملکرد مطلوب نیاز به تنظیم فرآپارامتر گسترده داشته باشد.

د) این الگوریتم یک راه حل پراکنده ارائه می‌دهد که می‌تواند برای انتخاب ویژگی و تفسیر مفید باشد.

با این حال، برخی از اشکالات احتمالی الگوریتم SVR عبارتند از:

الف) این الگوریتم می‌تواند از نظر محاسباتی گران باشد، به خصوص برای مجموعه داده‌های بزرگ و مسائل غیر خطی.

ب) این الگوریتم نیاز به انتخاب فرآپارامترها، مانند تابع هسته و پارامتر تنظیم، دارد که می‌تواند بر عملکرد الگوریتم تأثیر بگذارد.

رگرسیون خطی

رگرسیون خطی یک روش آماری است که برای مدلسازی رابطه بین یک متغیر وابسته (مثلاً y) و یک یا چند متغیر مستقل (مثلاً x) استفاده می‌شود. هدف رگرسیون خطی یافتن بهترین رابطه خطی بین متغیرها است که بتواند تغییرات متغیر وابسته را توضیح دهد. رگرسیون خطی به طور گسترده در زمینه‌های مختلف از جمله اقتصاد، مالی، مهندسی و علوم اجتماعی برای مدل سازی و تجزیه و تحلیل روابط بین متغیرها و پیش بینی بر اساس داده‌های مشاهده شده استفاده می‌شود.

پرسترون چند لایه (MLP)

نوعی شبکه عصبی مصنوعی است که به طور گسترده در یادگیری ماشین برای کارهای مختلفی مانند طبقه بندی، رگرسیون و تشخیص الگو استفاده می‌شود. این الگوریتم شامل چندین لایه از گره‌های به هم پیوسته (یا نورون‌ها) است که در آن هر نورون مجموع وزنی ورودی‌ها را می‌گیرد و آن را از طریق یک تابع فعال‌سازی غیرخطی عبور می‌دهد. معماری اصلی یک MLP معمولاً از سه نوع لایه تشکیل شده است:

-لایه ورودی: این لایه داده‌های ورودی را دریافت کرده و به لایه بعدی ارسال می‌کند.

-لایه‌های پنهان: این لایه‌ها حاوی چندین نورون هستند که محاسبات را روی داده‌های ورودی انجام می‌دهند و نتایج را به لایه بعدی منتقل می‌کنند.


می‌تواند به بیش از حد برازش حساس باشد و برای جلوگیری از آن نیاز به تکنیک‌های منظم سازی دارد.

به طور کلی، پرسپترون چند لایه یک الگوریتم قدرتمند و همه کاره است که می‌تواند برای طیف گسترده‌ای از وظایف یادگیری ماشین اعمال شود، به ویژه در سناریوهایی که داده‌ها دارای الگوها و روابط پیچیده هستند.

برای آموزش مدل با شبکه‌های عصبی پرسپترون چند لایه، از ساختار شبکه عصبی با ۴ لایه نورون استفاده گردید. لایه‌ها به ترتیب با ۶۴، ۳۲، ۱۶ و ۱ نورون تعبیه شدند. در بین تمامی لایه‌ها نیز از دروپ اوت^{۴۱} جهت جلوگیری از برازش بیش از حد^{۴۱} بر روی داده‌های آموزش استفاده شد. همچنین تابع

فعالساز^{۴۲} همه نورون‌های موجود، به جز لایه خروجی، ReLu^{۴۳} در نظر گرفته شد و برای لایه خروجی از آن جا که مسأله یک مسأله رگرسیون است، تابع فعالساز خطی^{۴۴} قرار داده شد. برای آموزش شبکه از تابع هزینه میانگین مربعات خطا^{۴۵} استفاده شد. همچنین برای بهینه سازی شبکه از بهینه ساز ادم^{۴۶} استفاده شد. برای آموزش شبکه دسته‌های ۳۲ تایی از داده‌ها به عنوان ورودی در نظر گرفته شد و همچنین فرایند آموزش در ۵۰۰ دور اتفاق افتاد. در شکل ۴ نمودار آموزش شبکه آورده شده است و می‌توان دید که برازش بیش از حد رخ نداده است، چرا که خطای آموزش با خطای ارزیابی روند نزدیک یکدیگر را طی می‌کنند.

MLP Model Training Plot



شکل ۴. نمودار خطا بر حسب دور آموزش در مدل MLP.

توجه به خود

توجه به خود^{۴۷} مکانیزمی در یادگیری عمیق است که به مدل اجازه می‌دهد در هنگام پردازش هر عنصر دنباله به بخش‌های مختلف توالی ورودی خود توجه کند. اغلب در پردازش زبان طبیعی^{۴۸} NLP و وظایف بینایی کامپیوتری استفاده می‌شود. در توجه به خود، دنباله ورودی به سه بردار تبدیل می‌شود: بردار پرس و جو، بردار کلید و بردار مقدار. این بردارها با اعمال


تبدیل‌های خطی قابل یادگیری به دنباله ورودی به دست می‌آیند. بردار پرس و جو برای امتیاز دادن به هر عنصر دنباله بر اساس شباهت آن با عناصر دیگر استفاده می‌شود، در حالی که بردار کلید و بردار مقدار برای نشان دادن عناصر دنباله استفاده می‌شوند. تابع امتیاز دهی می‌تواند بر اساس معیارهای شباهت مختلف، مانند شباهت کسینوس^{۴۹} یا دات پروداکت^{۵۰} مقیاس شده

شد. همچنین برای بهبود سرعت و دقت نتایج در بین لایه‌های شبکه عصبی از لایه‌های بچ نرمالیزیشن^{۵۲} نیز استفاده شد. ساختار مدل طراحی شده از ۵ لایه عصبی تشکیل شده است و بین هر یک از این لایه‌ها علاوه بر لایه دروپ اوت، لایه بچ نرمالیزیشن و همچنین self-attention نیز تعبیه شده است. تعداد نوروں موجود در لایه‌های شبکه عصبی طراحی شده به ترتیب ۶۴، ۳۲، ۱۶، ۸ و ۱ نوروں هستند تا به نوعی همچون انکودر عمل کرده و نتایج را بهبود دهند. سایر تنظیمات قرار داده شده برای آموزش شبکه همچون تنظیمات مدل MLP است که در بالا گفته شد، تنظیماتی همچون تابع هزینه و تابع بهینه ساز مورد استفاده قرار گرفته است. در شکل ۵ نمودار آموزش شبکه آورده شده است و می‌توان دید که برازش بیش از حد رخ نداده است، چرا که خطای آموزش با خطای ارزیابی روند نزدیک یکدیگر را طی می‌کنند.

باشد. امتیازات حاصل سپس برای محاسبه مجموع وزنی بردارهای ارزش استفاده می‌شوند، جایی که وزن‌ها توسط امتیازها تعیین می‌شوند. این جمع وزنی خروجی مکانیسم توجه به خود را نشان می‌دهد. با توجه به بخش‌های مختلف توالی ورودی در زمان‌های مختلف، توجه به خود به مدل اجازه می‌دهد تا بر مرتبط‌ترین اطلاعات برای هر عنصر دنباله تمرکز کند و وابستگی‌های دوربرد و روابط متنی بین عناصر را به تصویر بکشد. این الگوریتم می‌تواند به ویژه برای کارهایی مانند ترجمه زبان مفید باشد، جایی که معنای یک کلمه می‌تواند به سایر کلمات در جمله بستگی داشته باشد.

یکی از پیاده‌سازی‌های محبوب توجه به خود، معماری ترنسفورمر^{۵۱} است که برای دستیابی به عملکرد پیشرفته در کارهای مختلف NLP، مانند مدل‌سازی زبان، ترجمه ماشینی و پاسخ‌گویی به سؤال، استفاده شده است.

برای بهبود نتایج حاصل از آموزش شبکه با استفاده از MLP (مدل قبلی)، از ساختار توجه نیز در ساختار شبکه عصبی استفاده



شکل ۵. نمودار خطا بر حسب دور آموزش در مدل MLP + self-attention

۲-۵- معیارهای ارزیابی مدل‌ها

برای مقایسه نتایج حاصل از مدل‌های گوناگون از ۴ متریک MAE ، MSE ، $RMSE$ و R -squared استفاده شد که در ادامه آورده شده‌اند:

الف) میانگین قدر مطلق خطاها (MAE)

یک متریک متداول برای مسائل رگرسیون است و رابطه آن به صورت زیر است.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

معیار فوق، معیاری محبوب برای ارزیابی مدل‌های رگرسیون است، زیرا اندازه‌گیری از فاصله متوسط پیش‌بینی‌ها با مقادیر واقعی را ارائه می‌دهد. مقدار MAE پایین‌تر نشان می‌دهد که مدل در پیش‌بینی متغیر هدف بهتر است، زیرا میانگین خطای آن کمتر است. با این حال، تفسیر مقدار MAE به مقیاس متغیر هدف بستگی دارد و نسبت به جهت خطاها حساس نیست (به عنوان مثال، خطاهای مثبت و منفی را به طور مساوی تفسیر می‌کند). به طور کلی، MAE یک معیار مفید برای ارزیابی عملکرد مدل‌های رگرسیونی است و می‌توان آن را به راحتی محاسبه و تفسیر کرد.

ب) میانگین مربعات خطاها (MSE)

MSE یک معیار محبوب برای ارزیابی مدل‌های رگرسیون است، زیرا اندازه‌گیری از فاصله پیش‌بینی‌ها با مقادیر واقعی به طور متوسط را ارائه می‌دهد و خطاهای بزرگ را به شدت نسبت به خطاهای کوچک جریمه می‌کند. مقدار MSE پایین‌تر نشان می‌دهد که مدل در پیش‌بینی متغیر هدف بهتر است، زیرا میانگین مربعات خطای آن کمتر است. با این حال، تفسیر مقدار MSE به مقیاس متغیر هدف بستگی دارد و نسبت به جهت خطاها حساس نیست (به عنوان مثال، خطاهای مثبت و منفی را به طور مساوی تفسیر می‌کند).

به طور کلی، MSE یک معیار مفید برای ارزیابی عملکرد مدل‌های رگرسیونی است و می‌توان آن را به راحتی محاسبه و تفسیر کرد. با این حال، ذکر این نکته مهم است که ماهیت مجذور متریک می‌تواند آن را نسبت به موارد پرت حساس کند و تفسیر بزرگی خطا در واحدهای دنیای واقعی دشوار است. رابطه این متریک به شکل زیر است:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (3)$$

ج) ریشه میانگین مربعات خطاها ($RMSE$)

$RMSE$ یک معیار محبوب برای ارزیابی مدل‌های رگرسیونی است، زیرا اندازه‌گیری از فاصله پیش‌بینی‌ها با مقادیر واقعی به طور متوسط را ارائه می‌کند و خطاهای بزرگ را بیشتر از خطاهای کوچک جریمه می‌کند. مانند MSE ، مقدار $RMSE$ پایین‌تر نشان می‌دهد که مدل در پیش‌بینی متغیر هدف بهتر است. با این حال، از آنجایی که $RMSE$ در واحدهای مشابه متغیر هدف بیان می‌شود، تفسیر بزرگی خطا در شرایط واقعی آسان‌تر است. به طور کلی، $RMSE$ یک معیار مفید برای ارزیابی عملکرد مدل‌های رگرسیونی است، به‌ویژه زمانی که مقیاس متغیر هدف مهم است. رابطه این متریک به شکل زیر است:

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_i - \hat{y}_i)^2}{n}} \quad (4)$$

د) ضریب تعیین (R -squared)

معیاری است که معمولاً برای ارزیابی مدل‌های رگرسیون مورد استفاده قرار می‌گیرد، زیرا معیاری را ارائه می‌دهد که چگونه مدل با داده‌ها مطابقت دارد و چه مقدار از تغییرات در متغیر هدف توسط متغیرهای مستقل توضیح داده می‌شود. با این حال، توجه به این نکته مهم است که R^2 می‌تواند تحت تأثیر تعداد متغیرهای مستقل در مدل قرار گیرد و ممکن است تصویر کاملی از عملکرد مدل ارائه نکند. علاوه بر این، R^2 زمانی که برای مقایسه مدل‌ها با تعداد متفاوتی از متغیرهای مستقل استفاده می‌شود یا در مدل‌های رگرسیون غیرخطی استفاده می‌شود، می‌تواند گمراه‌کننده باشد. محدوده R^2 از ۰ تا ۱ است که مقدار ۱ نشان می‌دهد که مدل کاملاً با داده‌ها مطابقت دارد و تمام واریانس متغیر هدف را توضیح می‌دهد و مقدار ۰ نشان می‌دهد که مدل هیچ یک از واریانس‌های متغیر هدف را توضیح نمی‌دهد. رابطه این معیار به شکل زیر است.

$$R^2 = 1 - \frac{SS_{RES}}{SS_{TOT}} = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (5)$$

۲-۶- اهمیت پارامترها

علاوه بر توسعه مدل‌های یادگیری ماشین برای پیش‌بینی مقاومت فشاری محدودنشده، تحلیل اهمیت ویژگی‌ها به منظور شناسایی

ویژگی‌های مبتنی بر GB بر اساس سهم هر متغیر در فرآیند کاهش خطای مدل محاسبه گردید. در این مطالعه، نتایج حاصل از روش‌های مختلف با یکدیگر مقایسه و مقادیر اهمیت به صورت نرمال‌سازی شده و درصدی ارائه شدند. این تحلیل امکان شناسایی مهم‌ترین پارامترهای مؤثر بر مقاومت فشاری و همچنین بررسی میزان توافق روش‌های مختلف در رتبه‌بندی متغیرها را فراهم می‌سازد.

۳- نتایج و بحث

۳-۱- عملکرد مدل‌های پیش‌بینی


نتایج عملکرد حاصل از تمامی مدل‌های گفته شده بر روی داده ارزیابی در جدول ۶ و بر اساس متریک‌های مطرح شده در بالا آورده شده است.

جدول ۶. نتایج حاصل از مدل‌های یادگیری ماشین در این مطالعه

Metric/Algorithm	Random Forest	KNN	SVR	MLP	Linear Regression	MLP + Attention
MAE	4.41	5.19	4.79	3.96	5.41	3.73
MSE	33.21	42.97	37.15	27.89	50.24	25.76
RMSE	5.76	6.56	6.09	5.28	7.08	5.08
R-squared	0.74	0.66	0.70	0.78	0.60	0.80
Correlation Coef	0.86	0.81	0.84	0.88	0.775	0.89

می‌توان دریافت که پیش‌بینی مدل قابل قبول است، چرا که داده‌های به نمایش درآمده رو نیم ساز صفحه قرار گرفته‌اند و عملاً هر چقدر این نقاط بیشتر به نیمساز ۴۵ درجه صفحه نزدیک‌تر باشند، پیش‌بینی مدل به مدل واقعی نزدیک‌تر است.

با نگاه به جدول فوق می‌توان دید که بهترین نتایج مربوط به مدل MLP + Attention هست و بدترین نتیجه حاصل نیز مربوط به مدل رگرسیون خطی است. از این رو در ادامه تنها نمودار مربوط به پیش‌بینی انجام شده در مدل MLP + Attention نسبت به مقادیر واقعی آورده شده است. با مشاهده شکل ۶



شکل ۶. مقادیر تخمین زده شده حاصل از اجتماع مدل پرسپترون چندلایه و توجه به خود، در مقایسه با مقادیر واقعی


۲-۳- تحلیل اهمیت پارامترها

در این بخش تاثیر هر یک از ویژگی‌های ورودی مدل در تعیین میزان UCS محاسبه گردید. با توجه به اینکه برخی از مدل‌های مورد استفاده در این پژوهش نظیر ماشین بردار پشتیبان، نزدیک‌ترین همسایه و شبکه عصبی مصنوعی امکان استخراج مستقیم اهمیت ویژگی‌ها را فراهم نمی‌کنند، به منظور تحلیل اثر نسبی متغیرهای ورودی از روش‌های مستقل SHAP، اهمیت جایگشتی و گرادیانت بوسستینگ استفاده شد.

روش SHAP

در این روش اهمیت ویژگی‌ها با تخمین سهم هر ویژگی در تفاوت بین پیش‌بینی واقعی و میانگین پیش‌بینی در تمام زیر مجموعه‌های ویژگی ممکن محاسبه شده است. این کار با محاسبه مقادیر شیبی برای هر ویژگی انجام می‌شود، که نشان دهنده سهم حاشیه‌ای مورد انتظار از ویژگی در پیش‌بینی، با توجه به همه ترکیب‌های ویژگی ممکن است. ارزش شیبی، مفهومی از تئوری بازی‌های تعاونی^{۵۷} است که سهم هر ویژگی را در پیش‌بینی، برای یک نمونه خاص اندازه‌گیری می‌کند.

برای این کار از کتابخانه SHAP استفاده شد. کتابخانه SHAP از یک نوع مقدار شیبی به نام مقدار Kernel Shapley استفاده می‌کند که با استفاده از یک مدل رگرسیون خطی وزن دار، مقدار شیبی را تقریب می‌زند. به طور خاص، کتابخانه تعداد زیادی نمونه را با برهم زدن مقادیر ویژگی نمونه مورد علاقه تولید می‌کند و سپس یک مدل خطی را برای هر نمونه برازش می‌دهد. ضرایب مدل خطی نشان دهنده سهم هر ویژگی در پیش‌بینی آن نمونه است. سپس کتابخانه ضرایب را در تمام نمونه‌ها میانگین می‌گیرد و هر نمونه را بر اساس شباهت آن به نمونه مورد علاقه وزن دهی می‌کند. مقادیر اهمیت ویژگی حاصل، مقادیر مطلق ضرایب میانگین هستند. نتایج به دست آمده از تخمین اهمیت هر یک از ویژگی‌ها با استفاده از این روش در شکل ۷ آورده شده است. با مشاهده شکل می‌توان دریافت که سن عمل‌آوری مخلوط (A)، بیشترین تاثیر را در تخمین خروجی دارد. پس از آن درصد سیمان (C)، وجود افزودنی نیکوفلاک (N)، میزان رطوبت (W) و در آخر روش تراکم (D) است. درصد اهمیت هر ویژگی بر اساس این روش نیز در جدول ۷ ارائه شده است.



شکل ۷. اهمیت هر یک از ویژگی‌های ورودی در تخمین مقاومت مخلوط تثبیت شده در مدل پرسپترون چندلایه و توجه به خود


روش اهمیت جایگشتی

اهمیت جایگشتی یک رویکرد مدل-آگنوستیک است، به این معنی که می‌توان آن را برای هر نوع مدلی از جمله مدل‌های خطی، درخت‌های تصمیم‌گیری، جنگل‌های تصادفی و شبکه‌های عصبی اعمال کرد. ایده اصلی در این روش این است که به طور تصادفی مقادیر یک ویژگی را در مجموعه آزمایشی تغییر دهیم و تاثیر آن را بر عملکرد مدل اندازه‌گیری کنیم.

اگر ویژگی مهم باشد، تغییر مقادیر آن باید تاثیر منفی قابل توجهی بر عملکرد مدل داشته باشد، زیرا مدل یاد گرفته است برای پیش‌بینی به آن ویژگی تکیه کند. نتایج به دست آمده از تخمین اهمیت هر یک از ویژگی‌ها با استفاده از روش اهمیت جایگشتی در جدول ۷ و شکل ۸ آورده شده است.

جدول ۷. اهمیت ویژگی‌های ورودی بر خروجی مدل با استفاده از روش‌های مختلف

ویژگی	SHAP*	SHAP (%)	Permutation Importance (%)	Gradient Boosting (%)	رتبه نهایی
سن عمل‌آوری	0.55	43.0	75.63	62.54	1
درصد سیمان	0.25	19.5	9.14	18.21	2
نیکوفلاک	0.23	18.0	6.58	9.54	3
درصد رطوبت	0.14	10.9	3.22	6.32	4
روش تراکم	0.11	8.6	5.44	3.40	5



شکل ۸. درصد اهمیت متغیرهای ورودی

روش گرادینت بوستینگ

در یک مدل گرادینت بوستینگ، تابع هزینه، تفاوت بین مقادیر پیش‌بینی‌شده و مقادیر واقعی را برای یک مجموعه مشخص از ویژگی‌ها اندازه‌گیری می‌کند. این مدل سعی می‌کند با اضافه کردن مکرر یادگیرندگان ضعیف به مجموعه، این تابع از هزینه را کمینه کند، جایی که هر یادگیرنده سعی می‌کند اشتباهات یادگیرندگان قبلی را تصحیح کند. اهمیت ویژگی در یک مدل گرادینت بوستینگ را می‌توان با اندازه‌گیری کاهش در تابع هزینه، زمانی که یک ویژگی خاص از مدل حذف می‌شود محاسبه کرد. این کار با محاسبه امتیاز برای هر ویژگی انجام می‌شود که این امتیاز متناسب با کاهش کل تابع هزینه با استفاده از آن ویژگی است. نتایج به دست آمده از تخمین اهمیت هر یک از ویژگی‌ها در جدول ۷ و شکل ۸ آورده شده است.

۳-۳- بحث مهندسی نتایج

نتایج حاصل از سه روش SHAP، اهمیت جایگشتی و گرادینت بوستینگ نشان داد که اگرچه میزان اهمیت نسبی ویژگی‌ها در هر روش دارای تفاوت‌هایی است، اما در رتبه‌بندی کلی متغیرهای ورودی توافق قابل توجهی بین روش‌ها مشاهده می‌شود. اگرچه مقادیر اهمیت ویژگی‌ها در سه روش یکسان نیست، این تفاوت از مبنای محاسباتی متفاوت آن‌ها ناشی می‌شود. در روش SHAP، اهمیت ویژگی‌ها بر اساس میانگین سهم هر ویژگی در پیش‌بینی‌های مدل محاسبه می‌شود، در حالی که اهمیت جایگشتی کاهش عملکرد مدل پس از جابه‌جایی تصادفی هر ویژگی را اندازه‌گیری می‌کند و گرادینت بوستینگ نیز اهمیت را بر اساس میزان کاهش خطا در گره‌های درخت‌های تصمیم برآورد می‌کند. بنابراین، تفاوت در مقادیر عددی طبیعی است، اما سازگاری رتبه‌بندی ویژگی‌ها در هر سه روش، قابلیت اعتماد نتایج و استحکام تحلیل اهمیت ویژگی‌ها را تأیید می‌کند. روش SHAP درصدهای کوچک‌تری نسبت به دو روش دیگر داده است. اما این اختلاف ناشی از تفاوت در مبنای محاسباتی روش‌ها بوده و به معنای اختلاف در نتیجه نیست. در حالی که SHAP سهم متوسط هر ویژگی را در پیش‌بینی مدل اندازه‌گیری می‌کند، دو روش دیگر بر کاهش عملکرد مدل یا کاهش خطا در ساخت درخت‌های تصمیم استوار هستند. نتایج تحلیل اهمیت ویژگی‌ها در هر سه روش مطالعه شده نشان داد که سن عمل‌آوری مهم‌ترین عامل مؤثر بر مقاومت فشاری محدودنشده

مخلوط‌های اساس تثبیت‌شده با سیمان حاوی ۱۰۰ درصد مصالح خرده آسفالتی است. این نتیجه بیانگر نقش غالب فرآیند هیدراتاسیون سیمان و بلوغ مخلوط در توسعه مقاومت فشاری محدود نشده این نوع مخلوط‌ها بوده و نشان می‌دهد که بخش عمده ظرفیت مقاومتی مخلوط در طول زمان و با ادامه واکنش‌های هیدراتاسیون حاصل می‌شود. اهمیت بالای سن عمل‌آوری حاکی از آن است که ارزیابی عملکرد این نوع مصالح در سنین اولیه نمی‌تواند بیانگر رفتار نهایی آنها باشد و زمان کافی برای تکمیل فرآیندهای سیمان‌شدگی ضروری است. همچنین، درصد سیمان در هر سه روش در رتبه دوم قرار گرفت که بیانگر نقش اساسی آن در تشکیل محصولات هیدراتاسیون و افزایش پیوند بین ذرات است. این موضوع احتمالاً ناشی از آن است که درصد سیمان تنها در محدوده نسبتاً محدود ۴ تا ۶ درصد تغییر کرده، در حالی که سن عمل‌آوری بازه گسترده‌تری از ۳ تا ۹۰ روز را در بر گرفته است. از سوی دیگر، وجود افزودنی نیکوفلاک در تمامی روش‌ها اهمیت بیشتری نسبت به درصد رطوبت و روش تراکم نشان داد و بیانگر آن است که با تقویت عملکرد مخلوط تأثیر قابل توجه این افزودنی سبب بهبود عملکرد مکانیکی مخلوط‌های تثبیت‌شده می‌شود. درصد رطوبت و روش تراکم سهم کمتری در تغییرات مقاومت نسبت به سن عمل‌آوری، درصد سیمان و افزودنی نیکوفلاک داشتند. با این حال، تأثیر این عوامل قابل چشم‌پوشی نبوده و می‌توانند از طریق بهبود شرایط تراکم بر مقاومت نهایی اثرگذار باشند. به طور کلی، نتایج حاصل از روش‌های مختلف تحلیل اهمیت ویژگی‌ها نشان داد که فرآیندهای وابسته به زمان، به ویژه بلوغ و تکامل واکنش‌های هیدراتاسیون، مهم‌ترین مکانیزم کنترل‌کننده مقاومت فشاری مخلوط‌های RAP تثبیت‌شده با سیمان هستند. همگرایی این نتایج با رفتار شناخته‌شده مصالح تثبیت‌شده سیمانی، بیانگر آن است که مدل‌های یادگیری ماشین توسعه‌یافته علاوه بر قابلیت پیش‌بینی مناسب، توانایی قابل قبولی در شناسایی و تفسیر روابط فیزیکی حاکم بر رفتار این نوع مخلوط‌ها دارند.

بر اساس نتایج تحلیل اهمیت ویژگی‌ها، مجموع سهم سن عمل‌آوری و درصد سیمان و افزودنی بیش از ۸۰ درصد و در اغلب موارد بیش از ۹۰ درصد از تغییرات مقاومت فشاری محدودنشده را تبیین می‌کند که نشان می‌دهد فرآیندهای هیدراتاسیون و سیمان‌شدگی، مکانیزم غالب کنترل‌کننده مقاومت در مخلوط‌های RAP تثبیت‌شده با سیمان هستند.

۴- نتیجه گیری

در این پژوهش، با استفاده از نتایج حاصل از ۵۴۰ آزمایش مقاومت فشاری محدودنشده (UCS) بر روی مخلوط‌های اساس تثبیت‌شده با سیمان حاوی ۱۰۰ درصد مصالح خرد آسفالتی، مدل‌های مختلف یادگیری ماشین شامل رگرسیون خطی، جنگل تصادفی (RF)، نزدیکترین همسایه (KNN)، رگرسیون بردار پشتیبان (SVR)، پرسپترون چند لایه (MLP) و توجه به خود، به منظور پیش‌بینی UCS توسعه داده شدند. متغیرهای ورودی مدل‌ها شامل سن عمل‌آوری، درصد سیمان، درصد رطوبت، وجود یا عدم وجود افزودنی نیکوفلاک، و روش تراکم بودند. نتایج نشان داد که مدل‌های مبتنی بر یادگیری ماشین قادرند با دقت مناسبی رفتار مقاومت فشاری مخلوط‌های مورد مطالعه را پیش‌بینی نمایند و انطباق مطلوبی بین مقادیر اندازه‌گیری‌شده و مقادیر پیش‌بینی‌شده مشاهده گردید. مقایسه شاخص‌های ارزیابی عملکرد مدل‌ها نیز بیانگر آن بود که مدل‌های غیرخطی نسبت به مدل‌های خطی توانایی بیشتری در شناسایی روابط پیچیده میان متغیرهای ورودی و UCS دارند. در این پژوهش علاوه بر توسعه مدل‌های پیش‌بینی، اهمیت نسبی پارامترهای طرح اختلاط و ساخت با استفاده از سه رویکرد مستقل شامل SHAP، اهمیت جایگشتی (PI) و گرادیانت بوستینگ (GB) مورد بررسی و مقایسه قرار گرفته است.

در راستای تحلیل اهمیت ویژگی‌ها، نتایج حاصل از روش‌های مختلف در تفسیر عملکرد مدل‌ها و شناسایی میزان تأثیر هر یک از پارامترهای مؤثر، روندی نسبتاً مشابه را نشان دادند و مشخص گردید که سن عمل‌آوری مهم‌ترین عامل مؤثر بر مقاومت فشاری محدودنشده مخلوط‌های RAP تثبیت‌شده با سیمان است. همچنین درصد سیمان و استفاده از افزودنی نیز از جمله پارامترهای اثرگذار بر مقاومت فشاری بوده و نقش قابل توجهی در عملکرد مکانیکی مخلوط‌ها ایفا می‌کنند. در مقابل، میزان رطوبت و روش تراکم، اگرچه بر مقاومت نهایی تأثیرگذار بوده‌اند، اما در مقایسه با سن عمل‌آوری، درصد سیمان و افزودنی از اهمیت نسبی کمتری برخوردار بوده‌اند.

در مجموع، نتایج این پژوهش نشان داد که استفاده از روش‌های یادگیری ماشین علاوه بر فراهم نمودن امکان پیش‌بینی دقیق مقاومت فشاری محدودنشده، ابزار مناسبی برای تحلیل و رتبه‌بندی عوامل مؤثر بر عملکرد مخلوط‌های تثبیت‌شده حاوی تراشه آسفالت فراهم می‌آورد. این موضوع می‌تواند در

بهینه‌سازی طرح اختلاط، کاهش تعداد آزمایش‌های آزمایشگاهی و تسهیل فرآیند تصمیم‌گیری در طراحی و اجرای لایه‌های اساس تثبیت‌شده مورد استفاده قرار گیرد.

نکته قابل توجه آن است که علی‌رغم تفاوت در مبانی محاسباتی سه روش SHAP، PI و GB، ترتیب اهمیت ویژگی‌ها در هر سه روش کاملاً یکسان به دست آمد. این همگرایی بیانگر پایداری نتایج و قابلیت اعتماد تحلیل اهمیت ویژگی‌ها در پژوهش حاضر است.

نتایج اصلی این پژوهش را می‌توان در قالب موارد ذیل برشمرد: -مدل‌های یادگیری ماشین مورد استفاده توانایی بالایی در پیش‌بینی مقاومت فشاری محدودنشده مخلوط‌های اساس تثبیت‌شده با سیمان حاوی ۱۰۰ درصد مصالح خرد آسفالتی (RAP) از خود نشان دادند و مقادیر پیش‌بینی‌شده انطباق مناسبی با نتایج آزمایشگاهی داشتند.

-در میان پارامترهای مورد بررسی، سن عمل‌آوری بیشترین تأثیر را بر مقاومت فشاری محدودنشده داشته و در تمامی روش‌های تحلیل اهمیت ویژگی‌ها به عنوان مهم‌ترین متغیر ورودی شناسایی شد.

-درصد سیمان و استفاده از افزودنی نیکوفلاک نیز از جمله عوامل مؤثر بر مقاومت فشاری محدودنشده بوده و نتایج نشان دادند که افزایش درصد سیمان و استفاده از افزودنی، منجر به افزایش مقاومت مخلوط‌های مورد مطالعه می‌شود.

-نتایج حاصل از روش‌های مختلف تحلیل اهمیت ویژگی‌ها شامل روش SHAP، PI و GB روندی نسبتاً مشابه را در رتبه‌بندی متغیرها نشان دادند که بیانگر پایداری و قابلیت اعتماد نتایج حاصل از مدل‌های توسعه‌یافته است. برخلاف بسیاری از مطالعات پیشین که صرفاً بر توسعه مدل‌های پیش‌بینی تمرکز داشته‌اند، در این پژوهش سهم نسبی هر یک از پارامترهای طرح اختلاط و ساخت با استفاده از چندین روش تحلیل اهمیت ویژگی مورد بررسی قرار گرفت که امکان تفسیر فیزیکی و مهندسی نتایج مدل‌های یادگیری ماشین را فراهم نمود.

-استفاده از روش‌های یادگیری ماشین علاوه بر فراهم نمودن امکان پیش‌بینی دقیق مقاومت فشاری، ابزار مناسبی برای تفسیر رفتار مخلوط‌ها و شناسایی سهم نسبی هر یک از پارامترهای طرح اختلاط و ساخت فراهم می‌آورد و می‌تواند در بهینه‌سازی طرح اختلاط و کاهش حجم آزمایش‌های آزمایشگاهی مورد استفاده قرار گیرد.

۵- سپاسگزاری

مورخ ۱۴۰۵/۸/۱۵ توسط مرکز تحقیقات راه، مسکن و شهرسازی استخراج شده است.
لذا بدین وسیله از حمایت‌های مادی و معنوی مرکز تحقیقات راه، مسکن و شهرسازی تشکر و قدردانی می‌گردد.

داده‌های اولیه در این مقاله، از پروژه تحقیقاتی با عنوان "رفتار دینامیکی و مونوتونیک پساایکی مصالح تراشه آسفالت (RAP) به‌عنوان لایه اساس روسازی و ارائه پیش‌نویس راهنمای استفاده از RAP" ابلاغ شده با شماره ۱۳۶۲۱-۲۲-۰۰

۶- پی‌نوشت‌ها

1. Reclaimed Asphalt Pavement
2. Milling
3. Full-Depth Removal
4. Hot Mix Asphalt (Hma)
5. Reconstruction And Rehabilitation
6. Milling Machine
7. Bulldozer
8. Full-Depth Reclamation (Fdr)
9. Cement Treated Base (Ctb)
10. Machine Learning Algorithms
11. Unconfined Compressive Strength (Ucs)
12. Artificial Neural Network (Ann)
13. Support Vector Regression (Svr)
14. Random Forest
15. Gradient Boosting
16. K-Nearest Neighbors
17. Shap (Shapley Additive Explanations)
18. Permutation Importance
19. Multilayer Perceptron
20. Nicoflok Mineral Polymer
21. Uniformity Coefficient (Cu)
22. Coefficient Of Curvature (Cc)
23. Unified Soil Classification System (Uscs)
24. Effective Size
25. Average Particle Diameter
26. Maximum Size (Dmax)
27. Maximum Dry Unit Weight
28. Optimum Moisture Content (Omc)
29. Histogram
30. Box Plot
31. Scatter Plot
32. Deep Learning
33. Training Data
34. Validation Data
35. Feature Space
36. Support Vector Machines
37. Hyperplane
38. Maximum Marginal Hyperplane (Mmh)
39. Tunable Parameter
40. Dropout
41. Overfitting
42. Activation Function
43. Rectified Linear Unit
44. Linear Activation Function
45. Mean Squared Error Loss Function
46. Adam Optimizer
47. Self-Attention
48. Natural Language Processing (Nlp)
49. Cosine Similarity
50. Dot Product
51. Transformer Architecture
52. Batch Normalization (Batchnorm)
53. Mean Absolute Error

54. Mean Squared Error
55. Root Mean Squared Error
56. Shapley
57. Cooperative

۷- مراجع

treated base mixtures containing 100% Reclaimed Asphalt Pavement. *Road Materials and Pavement Design*, 27(1), 240–266.

doi.org/10.1080/14680629.2025.2486532

-Ngo, A. Q., Nguyen, L. Q., & Tran, V. Q., (2023). Developing interpretable machine learning-Shapley additive explanations model for unconfined compressive strength of cohesive soils stabilized with geopolymer. *Plos One*, 18(6), e0286950.

-Ngo, H. T. T., Pham, T. A., Vu, H. L. T., & Giap, L. V., (2021). Application of artificial intelligence to determined unconfined compressive strength of cement-stabilized soil in Vietnam. *Applied Sciences*, 11(4), 1949.

-Suebsuk, J., Kampala, A., Waiyakorn, P., Suksiripattanapong, C., Chindaprasirt, P., (2023). Variations in strength and stiffness of cement-stabilized reclaimed asphalt pavement and marginal lateritic soil blends in tropical climate. *Construction and Building Materials* 409: 134062.

doi.org/10.1016/j.conbuildmat.2023.134062

-Suddeepong A., Intra A., Horpibulsuk S., Suksiripattanapong C., Arulrajah A., Shen J.S., (2018). Durability against wettingdrying cycles for cement-stabilized reclaimed asphalt pavement blended with crushed rock. *Soils Found.* 58, 333–343.

doi:10.1016/j.sandf.2018.02.017

-Tabarsa, A., Latifi, N., Osouli, A., Bagheri, Y., (2021). Unconfined compressive strength prediction of soils stabilized using artificial neural networks and support vector machines. *Frontiers of Structural and Civil Engineering* 15:520-536,

doi:10.1007/s11709-021-0689-9

-Taha, O.M.E., Majeed, Z.H., Ahmed, S.M., (2018). Artificial neural network prediction models for maximum dry density and optimum moisture content of stabilized soils. *Transportation Infrastructure Geotechnology* 5:146-168.

doi: 10.1007/s40515-018-0053-2

-Tran, V. Q., (2023). Selection of single machine learning model for designing compressive strength of stabilized soil containing lime, cement and bitumen. *Journal of Intelligent & Fuzzy Systems*, 45(1), 239-256.

-Xiong, Z., Wei, W., Liu, F., Cui, C., Li, L., Zou, R., Zeng, Y., (2021). Bond behaviour of recycled aggregate concrete with basalt fibre-reinforced polymer bars. *Composite Structures*, 256, 113078.

-Yuan, D., Nazarian, S., Hoyos, L.R., Puppala, A.J., (2010). Cement treated RAP mixes for roadway bases. Center for Transportation Research Systems, The University of Texas at El Paso, Department of Civil Engineering, *The University of Texas at Arlington, Texas*.

-منصورزاده، سید محمد (۱۴۰۲). رفتار دینامیکی و مونوتونیک پسابسیکلی مصالح تراشه آسفالت (RAP) به عنوان لایه اساس روسازی، رساله دکتری، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران.

-Abdullah, G.M.S., Ahmad, M., Babur, M., (2024). Boosting-based ensemble machine learning models for predicting unconfined compressive strength of geopolymer stabilized clayey soil. *Sci Rep* 14, 2323.

doi.org/10.1038/s41598-024-52825-7

-Aljanabi, K.R.M., Salih, N.B., (2023). Using Artificial Neural Networks to predict the Unconfined Compressive Strength of Clayey Soils Stabilized by Various Stabilization Agents. *KSCE J Civ Eng* 27, 3720–3728.

doi.org/10.1007/s12205-023-0539-5

-Chhabra, R. S., Mahadeva, R., & Ransinchung R.N., G. D., (2024). Unconfined compressive strength prediction of recycled cement-treated base mixes using soft computing techniques. *Road Materials and Pavement Design*, 25(2), 423–437.

doi.org/10.1080/14680629.2023.2199889

-Chhabra, R.S., Ransinchung, G.D.R.N., and Islam, S.S., (2021). Performance analysis of cement treated base layer by incorporating reclaimed asphalt pavement material and chemical stabilizer. *Construction and Building Materials*, 298.

-Fedrigo W., Núñez WP., Castañeda López MA., Kleinert TR., Ceratti JAP., (2018). A study on the resilient modulus of cement-treated mixtures of RAP and aggregates using indirect tensile, triaxial and flexural tests. *Constr. Build. Mater.* 171, 161–169.

-Hanandeh, S., Ardah, A., Abu-Farsakh, M., (2020). Using artificial neural network and genetics algorithm to estimate the resilient modulus for stabilized subgrade and propose new empirical formula. *Transp. Geotech* 24.

doi: 10.1016/j.trgeo.2020.100358

-Hoque, M. I., Hasan, M., Islam, M. S., Houda, M., Abdallah, M., & Sobuz, M. H. R., (2023). Machine learning methods to predict and analyse unconfined compressive strength of stabilised soft soil with polypropylene columns. *Cogent Engineering*, 10(1), 2220492.

-Lundberg, S. M., Lee, S. I., (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30.

-Mansoorzadeh, S. M., Mahboubi Ardakani, A. R., & Aghaei Araei, A. (2026). Evaluating the mechanical performance and durability of cement-

Machine Learning-Based Prediction of Unconfined Compressive Strength and Feature Importance Analysis of Mixture Design and Construction Parameters in Cement-Treated Base Mixtures Containing Reclaimed Asphalt Pavement

Seyed Mohammad Mansoorzadeh, Assistant Professor, Road, Housing and Urban Development Research Center, Tehran, Iran.

E-mail: m.mansoorzadeh@bhrc.ac.ir

Received: March 2026- Accepted: August 2026

ABSTRACT

In this study, machine learning techniques were employed to predict and analyze the unconfined compressive strength (UCS) of cement-treated base (CTB) mixtures containing 100% reclaimed asphalt pavement (RAP). A comprehensive experimental database comprising 540 UCS specimens with different curing ages was established. The specimens were prepared using three cement contents (4%, 5%, and 6%), three moisture contents (5.5%, 6.5%, and 7.5%), and two compaction methods in accordance with ASTM D1557 and ASTM D558. In addition, a polymer–mineral additive (NicoFloK) was incorporated at 10% of the cement weight to enhance the mechanical performance of the mixtures. The predictive performance of several machine learning algorithms, including Random Forest (RF), Linear Regression (LR), Support Vector Regression (SVR), K-Nearest Neighbors (KNN), Multi-Layer Perceptron (MLP), and Self-Attention-enhanced MLP, was evaluated for UCS prediction. The results demonstrated that the developed machine learning models were capable of predicting UCS with satisfactory accuracy, and the predicted values exhibited good agreement with the experimental measurements. Furthermore, the effects of the mixture design and construction variables on UCS were investigated using three feature importance analysis techniques, namely SHAP, Permutation Importance, and Gradient Boosting Feature Importance. The results consistently identified curing age as the most influential parameter affecting UCS, followed by cement content, while the presence of the additive, moisture content, and compaction method ranked as the third, fourth, and fifth most influential factors, respectively. Unlike many previous studies that primarily focused on UCS prediction, this study also provides a comprehensive interpretation of the relative importance of the input variables using three complementary feature importance techniques. The consistent ranking of the input variables obtained from these methods further confirms the robustness and reliability of the proposed machine learning framework for both prediction and interpretation of UCS behavior in cement-treated RAP mixtures.

Keywords: Reclaimed Asphalt Pavement (RAP), Cement-Treated Base Mixtures Containing 100% RAP, Unconfined Compressive Strength, NicoFloK Mineral Polymer Additive, Machine Learning