

ساخت مدل تحلیلی به منظور پیش‌بینی زاویه فاز (δ)

در آزمایش رئومتر برشی دینامیکی (DSR)

مقاله علمی - پژوهشی

حسن حسین زاده*، دانش آموخته کارشناسی ارشد، موسسه آموزش عالی اقبال لاهوری، مشهد، ایران

سینا آرمان، دانش آموخته کارشناسی ارشد، دانشگاه آزاد اسلامی، مشهد، ایران

بهنام خیاط، دانش آموخته کارشناسی ارشد، دانشگاه آزاد اسلامی، مشهد، ایران

*پست الکترونیکی نویسنده مسئول: hosseinzadeh-ha@mashhad.ir

دریافت: ۱۴۰۲/۰۷/۲۰ - پذیرش: ۱۴۰۳/۰۱/۲۵

صفحه ۴۷۴-۴۶۱

چکیده

مشخصات سوپرپیو قیر به‌منظور بهبود عملکرد روسازی با کنترل مشکلات روسازی تحت طیف وسیعی از دماها و شرایط پیری طراحی شده است. رئومتر برشی دینامیکی (DSR) یکی از آزمایش‌های سوپرپیو است که برای تعیین خواص رئولوژیکی قیر استفاده می‌شود. هدف این مطالعه ایجاد مدل پیش‌بینی باقابلیت پیش‌بینی زاویه فاز (δ) به‌عنوان یک نتیجه اصلی از روش آزمایش DSR است. این به‌نوبه خود می‌تواند زمان به دست آوردن نتایج آزمایشگاهی و در نتیجه هزینه را کاهش دهد. برای این هدف یک روش یادگیری ماشین گروهی با رویکرد جنگل تصادفی استفاده شده است. بر این اساس، هفت متغیر مؤثر بر زاویه فاز قیر از نتایج ۱۲۲۵ نمونه از وب‌سایت LTPP جمع‌آوری شد. این عوامل عبارت‌اند از: دمای آزمایش، نوع پیری، درجه عملکرد پایین (PG-low)، درجه عملکرد بالا (PG-high)، نفوذ، ویسکوزیته سینماتیک و ویسکوزیته مطلق (دینامیک). روش پیشنهادی از طریق یک روش اعتبارسنجی متقاطع ۱۰ برابری تأیید شده و بر اساس تجزیه و تحلیل انجام شده به‌دقت بیش از ۹۰ درصد از نظر ضریب تعیین می‌رسد. در نهایت، تأثیر برخی از عوامل کلیدی در رویکرد جنگل تصادفی نیز بررسی شد، به‌عنوان مثال، میزان تأثیر حساسیت پارامترهای ورودی زاویه فاز. همچنین بر اساس نتایج تحلیل حساسیت، اهمیت متغیرهای ورودی مختلف به دست آمد. بر اساس بررسی انجام شده، دمای آزمایش و نوع پیرشدگی بیشترین تأثیر را بر زاویه فاز قیر دارند. می‌توان با افزایش تعداد و تنوع داده‌های آموزشی مدل را جهت رسیدن به نتایج بهتر و پیش‌بینی سایر خواص عملکردی قیر استفاده کرد.

واژه‌های کلیدی: LTPP، رئومتر برشی دینامیکی، زاویه فاز، یادگیری ماشین، جنگل تصادفی

۱- مقدمه

کند و پس از برداشتن بار اعمال‌شده به شکل اولیه خود بازگردد و به‌عنوان مایع ویسکوز، جایی که مقداری از انرژی در قیر تلف می‌شود، منجر به تغییر شکل دائمی می‌شود. در دماهای بالا، قیر به‌راحتی جریان می‌یابد و مانند یک مایع ویسکوز رفتار می‌کند، درحالی‌که رفتار آن در دماهای پایین به جامد الاستیک تبدیل می‌شود. قیر ماهیت شیمیایی پیچیده‌ای

رئومتر برشی دینامیکی ابزار قدرتمندی است که برای مشخص کردن رفتارهای الاستیک و ویسکوز قیر استفاده می‌شود (Al-Omari et al., 2018). رفتار ویسکوالاستیک قیر به طیف وسیعی از دماها و فرکانس بارگذاری بستگی دارد. اصطلاح ویسکوالاستیک به این معنی است که وقتی بار بر روی قیر اعمال می‌شود، ماده می‌تواند به‌عنوان یک جامد الاستیک رفتار

باید آن را در طیف وسیعی از دماهایی که انتظار می‌رود آسفالت در طول عمر خود تحت آن قرار گیرد، آزمایش شود. حساسیت قیر به دما یکی از مشکلات اصلی مرتبط با روسازی است (Hafeez et al., 2013). دمای آزمایش مورد استفاده در این مطالعه بین ۴ تا ۷۶ درجه سانتی‌گراد است. روسازی آسفالتی تحت تأثیر پیری در طول عمر خود قرار می‌گیرد که با دو دوره مشخص می‌شود. پیری کوتاه‌مدت که منعکس‌کننده پیری در طول اختلاط، حمل و ساخت است و پیری طولانی‌مدت که منعکس‌کننده پیری در طول عمر روسازی است. لعاب نازک چرخشی (RTFO) و محفظه تسریع پیری (PAV) به ترتیب برای توصیف دو فرآیند پیری استفاده می‌شوند (Liu et al., 2008; Tarsi et al., 2018). قیر معمولاً توسط چندین سیستم درجه‌بندی با توجه به ویژگی‌های فیزیکی آن‌ها مانند سیستم درجه‌بندی نفوذ، سیستم درجه‌بندی ویسکوزیته و سیستم درجه‌بندی عملکرد طبقه‌بندی می‌شود. سیستم درجه‌بندی PG بر شرایط آب و هوایی مورد انتظار متمرکز است، جایی که قرار است از قیر استفاده شود. درجه PG با دو عدد (هر دو در درجه سانتی‌گراد) شناخته می‌شود، یعنی: میانگین حداکثر دمای طراحی روسازی ۷ روزه و حداقل دمای طراحی روسازی.

فرآیند مستقیم درجه‌بندی PG نیاز به اندازه‌گیری مستقیم عملکرد روسازی با استفاده از دستگاه‌هایی مانند DSR و آزمایش‌های رئومتر تیرچه خمشی دارد؛ بنابراین، بودجه نسبتاً زیادی مورد نیاز است و شرایط دشواری را برای محققان و آزمایشگاه‌های روسازی در برخی کشورها ایجاد می‌کند (Abbas et al., 2010; CHAROENTHAM & KANITPONG, 2012). بسیاری از این محققان روش‌های جدیدی را برای بررسی غیرمستقیم عملکرد روسازی مورد مطالعه قرار دادند که در دسترس تر و ارزان تر است. یکی از این روش‌های تخمین غیرمستقیم، استفاده از داده‌های آب‌وهوا است؛ حداکثر و حداقل دمای هوا در مناطق اقلیمی ساخت که به‌عنوان اصل برای بررسی PG استفاده می‌شود (Abbas et al., 2010; CHAROENTHAM & KANITPONG, 2012; Khalil et al., 2009). باهیا و ویوانکو پیشنهاد کردند که انجام یک تخمین غیرمستقیم PG بر اساس ویژگی‌های روسازی مانند دمای «شرایط کاربردی واقعی» در مقایسه با حفظ مشخصات درجه‌بندی سنتی در

دارد که خواص آن را به بخش‌های فیزیکی و رئولوژیکی تقسیم می‌کند (Bari & Witezak, 2007). آزمایش DSR روشی برای تعیین خواص قیر در دماهای متوسط تا بالا است. این آزمایش بر روی نمونه‌های آسفالتی پیر شده با لعاب نازک چرخشی و محفظه تسریع پیری انجام می‌شود (Yener & Himsloğlu, 2014). اصل عملکرد آزمایش DSR این است که یک نمونه قیر بین دو صفحه موازی قرار می‌گیرد. یکی ایستاده و دیگری نوسانی. تنش برشی با چرخش صفحه نوسانی به دست می‌آید. دو پارامتر قابل‌توجه با آزمایش DSR روی قیر به دست می‌آید: G^* مدول برشی دینامیکی و δ زاویه فاز. خواص رئولوژیکی که بر تغییر شکل قیر و روانی آن تأثیر می‌گذارد را می‌توان با مدول برشی دینامیکی و زاویه فاز نشان داد (Remišová et al., 2016)، زیرا مقاومت قیر را در برابر تغییر شکل برشی در ناحیه ویسکوالاستیک خطی توصیف می‌کنند. زاویه فاز (δ) فاصله زمانی بین تنش برشی اعمال‌شده و کرنش برشی حاصل است (T315, 2012). مقدار زاویه فاز خواص ویسکوالاستیک قیر را توضیح می‌دهد (Hafeez et al., 2013). مقادیر δ بین صفر و نود درجه متغیر است. به‌خوبی شناخته شده است که وقتی $\delta=0$ باشد، قیر کاملاً الاستیک خواهد بود، درحالی‌که $\delta=90$ یک ماده کاملاً ویسکوز را نشان می‌دهد. قیر به‌عنوان ماده ویسکوز با زاویه فاز بالا نزدیک به ۹۰ درجه در دماهای بسیار بالا رفتار می‌کند. مشخصات سوپرپیو از مدول برشی دینامیکی و زاویه فاز برای درجه‌بندی قیر به شکل پارامترهای شیار ($G^*/\sin \delta$) و ترک‌خوردگی خستگی ($G^* \times \sin \delta$) استفاده می‌کند (Abdulhaq, 2015). پیشگیری از شیار شدن مستلزم به حداکثر رساندن پارامتر شیار شدگی با افزایش مدول برش دینامیکی و کاهش زاویه فاز است؛ بنابراین، قیر برای مقاومت در برابر تغییر شکل سفت است و به‌جای تغییر شکل دائمی، قادر به بازیابی تغییر شکل در زمان وقوع است. از سوی دیگر، پیشگیری از ترک‌خوردگی ناشی از خستگی در روسازی آسفالتی نیازمند قیری است که خیلی سفت نباشد، زیرا قیرهای بسیار سفت در برابر ترک‌خوردگی آسیب‌پذیرتر هستند تا اینکه تغییر شکل دهند و سپس بازیابی شوند. گرما، هوا، رطوبت و نور خورشید عوامل اساسی هستند که نقش مهمی در تغییر خواص مهندسی قیر دارند (Yener & Himsloğlu, 2014)؛ بنابراین، برای نشان دادن کامل خواص رئولوژیکی یک قیر،

DSR ارزیابی کردند. نتیجه‌گیری شد که δ قیر به‌طور قابل‌توجهی تحت تأثیر پیری قرار می‌گیرد و رفتار ویسکوالاستیک نیز تحت تأثیر قرار می‌گیرد که به‌نوبه خود بر پارامتر ترک‌خوردگی خستگی ($G * \sin\delta$) تأثیر منفی می‌گذارد. علاوه بر این، از نتایج مشاهده شد که ویسکوزیته قیر پیر شده به‌شدت افزایش می‌یابد. فیصل رابطه بین DSR را در فرکانس ۱۰ رادیان بر ثانیه و انواع مختلف پیری چهار قیر درجه عملکردی موردمطالعه قرار داد. نتایج نشان داد که پیری، مقاومت شیار شدگی بهتری را در قیر ایجاد می‌کند. علاوه بر این، قیرهای سخت‌تر PG مقادیر δ بالاتری نسبت به قیر PG نرم‌تر داشتند (Faisal et al., 2017).

حساسیت دمایی قیر آسفالتی یکی از نگرانی‌های اصلی در ارتباط با روسازی‌های آسفالتی است (Hafeez et al., 2013). رمیشوا و همکاران با استفاده از پارامترهای ویسکوزیته، مدول برشی و زاویه فاز، خواص رئولوژیکی قیر را در دمای ۶۶ تا ۸۰ درجه سانتی‌گراد بررسی کردند. نتایج نشان داد که ویسکوزیته قیر با افزایش دما کاهش می‌یابد و قیر مانند سیالات نیوتنی در دماهای بالای آزمایش رفتار می‌کند (Remišová et al., 2016).

عوامل مهم دیگری که بر خواص رئولوژیکی قیر تأثیر می‌گذارد، نفوذ و ویسکوزیته است. لی و همکاران مطالعه‌ای را برای مقایسه نتایج آزمایش DSR در برابر آزمایش‌های قیر معمولی (ویسکوزیته و نفوذ) انجام دادند. مشخص شد که با افزایش ویسکوزیته، مقادیر زاویه فاز کاهش می‌یابد که نشان می‌دهد ویسکوزیته منجر به مقاومت شیار شدگی بهتری می‌شود ($G*/\sin\delta$). درحالی‌که زاویه فاز با افزایش مقدار نفوذ افزایش می‌یابد و $G*\sin\delta$ با کاهش نفوذ افزایش می‌یابد (Lee et al., 2004). تکنیک‌های تحلیلی مختلفی برای به دست آوردن خواص رئولوژیکی قیر مانند تحلیل رگرسیون و شبکه‌های عصبی استفاده شد. کبیر و همکاران مدول برشی و زاویه فاز قیر مدل‌سازی کرده‌اند. دما، مدول دینامیکی، پارامترهای حجمی و درجه‌بندی کل به‌عنوان پیش‌بینی‌کننده استفاده شد. تجزیه و تحلیل رگرسیون غیرخطی با فرآیند آزمون و خطا از حدس ضرایب اولیه بر روی مجموعه داده اعمال شد. این مطالعه مدل‌های پیش‌بینی‌کننده زاویه فاز را با دقت بالا و خطای پایین به دست آورد (Kabir et al., 2014). مطالعه‌ای توسط رحمان و همکاران، مدل‌های جدیدی از

کشورهای توسعه‌یافته بهتر است (Bahia & Vivanco, 2005). هدف اصلی این کار تحقیقاتی، توسعه مدل پیش‌بینی‌کننده باقابلیت پیش‌بینی یک نتیجه DSR (زاویه فاز) بر اساس داده‌های جمع‌آوری‌شده از وبسایت LTPP است. عوامل متعددی که بر خواص رئولوژیکی قیر تأثیر می‌گذارند به‌عنوان پیش‌بینی‌کننده در این مدل پیشنهادی استفاده شد. این عوامل بیشتر مربوط به شرایط آزمایش و خواص قیر است. این عوامل عبارتند از: دمای آزمایش، نوع پیری، درجه عملکرد پایین (PG-low)، درجه عملکرد بالا (PG-high)، نفوذ، ویسکوزیته سینماتیک و ویسکوزیته مطلق (دینامیک) سپس مبانی نظری جنگل تصادفی و پیاده‌سازی مربوطه معرفی می‌شود. با آموزش مدل مبتنی بر جنگل تصادفی و با استفاده از داده‌های جمع‌آوری‌شده، یک یادگیرنده قوی به دست می‌آید که می‌تواند برای پیش‌بینی مقدار زاویه فازی استفاده شود. درنهایت، تأثیر برخی از عوامل کلیدی در رویکرد جنگل تصادفی نیز موردبحث قرار می‌گیرد، به‌عنوان مثال، میزان داده‌های آموزشی، حساسیت و تعداد متغیرهای ورودی. در ادامه ابتدا مروری بر پیشینه تحقیق انجام خواهد و سپس در مورد مجموعه داده و پردازش‌های آن بحث خواهد شد. در نهایت مدل‌سازی صورت خواهد گرفت.

۲- پیشینه تحقیق

آزمایش‌های سنتی قیر مانند نفوذ، ویسکوزیته، کشش و نقطه نرمی برای بررسی خواص فیزیکی قیر مورد استفاده قرار می‌گیرند. با این حال، توانایی این آزمایش‌ها در تعیین عملکرد قیر مورد تردید است.

رئولوژی مطالعه تغییر شکل و نرمی قیر است که رفتار ویسکوز و الاستیک تحت شرایط تنش را بررسی می‌کند (Hafeez et al., 2013). پارامترهای رئولوژیکی اساسی نتایج DSR هستند (مدول برشی دینامیکی $G*$) و زاویه فاز (δ). مدول برشی دینامیکی نشان‌دهنده یک رابطه ریاضی بین تنش برشی به کرنش برشی و زاویه فاز است که خواص ویسکوالاستیک قیر را نشان می‌دهد (Huang & Zeng, 2007). عوامل متعددی بر خواص رئولوژیکی قیر مانند پیرشدگی تأثیر می‌گذارد. ژیاو و همکاران (Tian et al., 2004) و جوشی (Joshi et al., 2013) اثر شرایط مختلف پیری را بر عملکرد ویسکوالاستیک قیر با استفاده از آزمون

ضعیف را برای ساختن یک یادگیرنده قوی ادغام کنیم. یادگیرنده ضعیف در واقع بر اساس الگوریتم‌های یادگیری فردی هستند؛ بنابراین، دقت پیش‌بینی و استحکام مدل‌های یادگیری گروهی (یادگیرنده قوی) به‌وضوح بهبود می‌یابد. سه گروه اصلی از الگوریتم‌ها برای یادگیری گروهی وجود دارد، یعنی بسته‌بندی، تقویت و انباشته کردن که تفاوت‌های آن‌ها را می‌توان در مقاله مروری یافت (Zhou, 2009). در میان الگوریتم‌های مختلف یادگیری گروهی، الگوریتم جنگل تصادفی یکی از الگوریتم‌های رایج است. در این مقاله، یک رویکرد هوشمند بر اساس الگوریتم جنگل تصادفی را برای پیش‌بینی نتیجه زاویه فازی در آزمایش DSR پیشنهاد شده است.

۳- جمع‌آوری و پردازش داده‌ها

داده‌های مورد استفاده در این مطالعه از وب‌سایت LTTP که به‌عنوان بخشی از برنامه تحقیقات استراتژیک بزرگراه در نظر گرفته شده است، به دست آمده است. عوامل انتخاب‌شده برای این مطالعه عبارت‌اند از: دمای آزمایش، نوع پیری، PG-کم، PG-بالا، نفوذ، ویسکوزیته سینماتیکی و مطلق (جدول ۱).

در مجموع ۸۹۵۶ داده زاویه فازی با متغیرهای ورودی جمع‌آوری شد. پس‌از آن مجموعه داده‌ها باید فیلتر شدند تا از وجود داده‌های گم‌شده و داده‌های خارج از ردیف در مجموعه داده جلوگیری شود و یک مجموعه داده سازگار با روش‌های تجزیه و تحلیل شکل بگیرد. مجموعه داده نهایی شامل ۱۲۲۵ رکورد از مقادیر زاویه فازی است. آزمایش DSR در دماهای متوسط تا بالا و با فرکانس ثابت ۱۰ رادیان بر ثانیه انجام شده است. نوع پیری نیز برای نمونه عادی با کد ۱، نمونه پیر شده در لعاب لایه‌نازک با کد ۲ و محفظه تسریع پیری با کد ۳ کدگذاری شد. در جدول ۲ آمار توصیفی پارامترهای مؤثر بر مدل‌سازی فهرست شده است.

رئولوژی قیر تحت دماها و فرکانس‌های مختلف ایجاد کرد. متغیرهای ورودی درجه‌بندی کل، پارامترهای حجمی مخلوط و رئولوژیکی بودند. در این مطالعه از رگرسیون غیرخطی استفاده شد و نتایج نشان داد که هم مدول دینامیکی و هم زاویه فاز با ضرایب تعیین (R^2) به ترتیب $۸۳/۷۳$ و $۶۹/۶۷$ درصد به‌خوبی پیش‌بینی شده‌اند (Asifur Rahman et al., 2017). اوشون و همکاران قدرت پیش‌بینی زاویه فاز را از مجموعه داده‌های سختی مخلوط‌های آسفالتی بررسی کرد. زاویه فاز با دو روش برای مقایسه با اندازه‌گیری‌های آزمایشگاهی محاسبه شد، روش‌ها عبارت‌اند از شیب ورود به سیستم منحنی اصلی مدول دینامیکی $(|E^*|)$ و مقادیر مدول هیرش. در این مطالعه از رابطه خطی استفاده شد و مشاهده شد که روش شیب دارای $R^2=0.94$ و ریشه میانگین مربعات خطا $RMSE=1.97$ و روش هیرش دارای $R^2=0.83$ و $RMSE=3.17$ است (Oshone et al., 2017). علاوه بر این، خامس و همکاران از مدل شبکه عصبی پیش‌خور چندلایه و یک شبکه تابع پایه شعاعی برای پیش‌بینی خواص رئولوژیکی ماستیک آسفالت از نظر زاویه فاز با سه نوع فیلر (سنگ آهک، سیمان و سنگ‌ریزه) و دو درصد حجمی فیلر (۳۵ و ۶۵ درصد جرمی) استفاده کردند. نتیجه‌گیری شد که مدل‌ها قادر به پیش‌بینی با R^2 بیش از ۹۸ درصد و میانگین مربعات خطای پایین هستند (Khamis et al., 2018). محمد و دنیا از یک رویکرد تلفیقی تحلیل مؤلفه اصلی و شبکه عصبی مصنوعی جهت پیش‌بینی زاویه فاز استفاده کردند. در تحقیق زاویه فاز با دقت بالایی تعیین شد. پارامترهای ورودی در این مطالعه درجه نفوذ، ویسکوزیته، دمای آزمایش بود (Khasawneh & Al-Oqaily, 2022). همان‌طور که از ادبیات موجود مشاهده می‌شود، استفاده از هر هفت عوامل (دمای آزمایش، نوع پیری، درجه عملکرد پایین (PG-کم)، درجه عملکرد بالا (PG-بالا)، نفوذ، ویسکوزیته سینماتیکی و ویسکوزیته مطلق (دینامیک)) برای پیش‌بینی نتیجه DSR (زاویه فاز) با استفاده نشده است. همچنین بیشتر الگوریتم‌های ذکر شده در بالا، الگوریتم‌های یادگیری فردی هستند، درحالی‌که خانواده دیگری از الگوریتم‌های یادگیری گروهی وجود دارد که دقیق‌تر، قوی‌تر و قدرتمندتر است (Zhou, 2009, 2012). ایده اصلی مدل‌های یادگیری گروهی این است که چندین یادگیرنده ضعیف را با استفاده از داده‌های آموزشی آموزش دهیم و سپس یادگیرندگان

جدول ۱. تعریف و توصیف متغیرها برای پیش‌بینی زاویه فاز

متغیر	نماد	نوع متغیر	توضیحات
X1: دمای آزمایش (سانتی‌گراد)	T	پیوسته	بین ۴ تا ۷۶ درجه سانتی‌گراد
X2: نوع پیرشدگی	Age	کیفی	۱. اصلی، ۲. RTFO و ۳. PAV
X3: ویسکوزیته کینماتیکی (استوکس)	Kin	پیوسته	در دمای ۱۳۵ درجه سانتی‌گراد اندازه‌گیری شده است
X4: ویسکوزیته مطلق (کیلو پوز)	Abs	پیوسته	در دمای ۶۰ درجه سانتی‌گراد اندازه‌گیری شده است
X5: درجه نفوذ (۰/۱ میلی‌متر)	Pen	پیوسته	در دمای ۲۵ درجه سانتی‌گراد اندازه‌گیری شده است
X6: دمای بالای عملکرد (سانتی‌گراد)	H-PG	پیوسته	بین ۴۶ تا ۷۶ درجه سانتی‌گراد
X7: دمای پایین عملکرد (سانتی‌گراد)	L-PG	پیوسته	محدوده از ۱۶- تا ۴۰- درجه سانتی‌گراد

جدول ۲. آمار توصیفی متغیرهای استفاده شده در مدل‌سازی

متغیر	میانگین	انحراف معیار	تعداد
زاویه فاز (درجه)	۶۲/۸۳	۱۳/۹۶	
دمای آزمایش (سانتی‌گراد)	۴۲/۸۷	۱۲/۲۴	
نوع پیرشدگی		متغیر کیفی	
ویسکوزیته کینماتیکی (استوکس)	۸/۵۷	۱۳/۱۱۷	۱۲۲۵
ویسکوزیته مطلق (کیلو پوز)	۷۰/۷۱	۳۸/۸۴	
درجه نفوذ (۰/۱ میلی‌متر)	۷۱/۷۶	۵۰/۵۸	
دمای بالای عملکرد (سانتی‌گراد)	۶۰/۲۵	۴/۶۹	
دمای پایین عملکرد (سانتی‌گراد)	-۲۷/۶۷	۵/۳۸	

همبستگی پیرسون متغیرهای استفاده شده در این مطالعه در جدول ۳ ارائه شده است. همانطور که در جدول نشان داده شده است، قدرمطلق اکثر مقادیر نشان دهنده همبستگی خوب بین برخی ورودی‌ها با یکدیگر و با مقدار زاویه فازی است.

جدول ۳. همبستگی بین متغیرهای استفاده شده در مدل‌سازی

	L-PG	H-PG	Age	Pen	Abs	Kin	T	δ
δ								۱
T							۱	۰/۸۲۰
Kin						۱	-۰/۲۶۴	-۰/۳۹۴
Abs					۱	۰/۶۳۰	-۰/۲۵۰	-۰/۳۶۴
Pen				۱	-۰/۲۹۳	-۰/۳۳۸	۰/۰۹۰	۰/۲۰۶
Age			۱	-۰/۳۶۳	۰/۰۹۸	۰/۱۰۴	-۰/۹۴۰	-۰/۸۷۵
H-PG		۱	۰/۱۹۷	-۰/۵۶۷	۰/۰۲۸	۰/۰۳۷	-۰/۲۴۲	-۰/۲۰۰
L-PG	۱	۰/۶۰۰	۰/۲۵۷	-۰/۶۸۳	۰/۲۶۳	۰/۳۱۶	-۰/۳۴۳	-۰/۴۵۷

تا مقادیر بی‌مقیاس شوند. برای این منظور از رابطه زیر استفاده است.

$$Z = \frac{X - \min}{\max - \min} \quad (1)$$

با توجه به اینکه رنج داده‌ها و واحد اندازه‌گیری آن‌ها در مجموعه داده‌ها متفاوت است، در الگوریتم‌های یادگیری ماشین عملکرد تابع با محدودیت سخت‌افزاری و نرم‌افزاری همراه است و نمی‌تواند عملکرد مثبتی داشته باشد؛ بنابراین نیاز است

۴- روش تحقیق

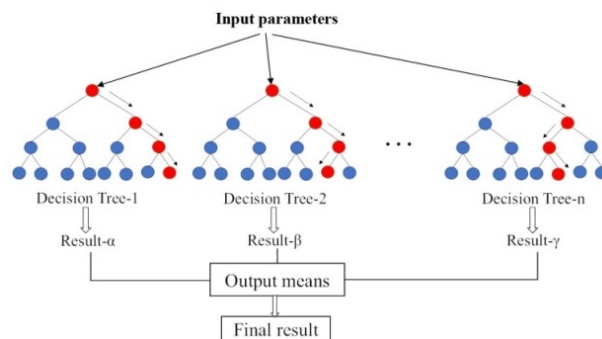
مدل پیش‌بینی جنگل تصادفی که یک الگوریتم یادگیری ماشین گروهی است در این مطالعه برای بررسی پارامتر زاویه فاز DSR توسعه داده شد. مدل‌سازی با استفاده از نرم‌افزار پایتون نسخه ۳.۸ انجام و سکوی گوگل کولب اجرا شد.

۴-۱- مبانی نظری الگوریتم جنگل تصادفی

روش جنگل تصادفی از جمله روش‌های تلفیقی است. در روش‌های تلفیقی مدلی که برای پیش‌بینی انتخاب می‌شود که ترکیبی از چندین مدل است. هر مدل رأی خود را صادر می‌کند و نتیجه نهایی در مورد مقدار مقاومت بتن بر اساس این رأی‌ها صادر می‌شود. اغلب صحت یک روش تلفیقی بهتر از مؤلفه‌های تشکیل‌دهنده آن یعنی زیر مدل‌ها است (Xu et al., 2013). در روش‌های تلفیقی از k مدل M_1, M_2, \dots, M_k برای ایجاد مدل M که به‌گونه‌ای بهبود یافته است استفاده می‌شود. از مجموعه داده‌های D برای تولید k مجموعه آموزشی D_1, D_2, \dots, D_k استفاده می‌شود و با کمک هر یک از آن‌ها مدل‌های پیش‌بینی M_i ($1 \leq i \leq k$) نیز خلق می‌شود. برای پیش‌بینی یک نمونه جدید هر یک از مدل‌های پیش‌بینی نتیجه را به‌عنوان یک رأی برمی‌گردانند و روش بر اساس آراء جمع‌آوری‌شده، رأی نهایی یعنی مقدار مقاومت بتن را تعیین

می‌کند. معمولاً صحت روش تلفیقی بهتر از مدل‌های پایه است. برای مثال روش تلفیقی را در نظر بگیرید که در آن رأی نهایی با توجه به رأی اکثریت مشخص می‌شود؛ بنابراین پیش‌بینی نمونه X از کلیه مدل‌های پایه جمع‌آوری و میانگین نتایج به‌عنوان نتیجه نهایی در خروجی قرار می‌گیرد. مدل‌های پایه ممکن است دچار اشتباه شوند، اما روش تلفیقی تنها در صورتی نمونه X را به نادرستی پیش‌بینی خواهد کرد که بیش از نیمی از مدل‌های تشکیل‌دهنده آن مرتکب خطا یا اشتباه شده باشند (Han et al., 2006).

تصور کنید مدل‌های استفاده‌شده در روش تلفیقی همگی از نوع درخت تصمیم هستند، بدین ترتیب این مجموعه تشکیل یک جنگل را خواهد داد. هر یک از درختان تصمیم با استفاده از یک انتخاب تصادفی صفات خاصی موجود در هر گره جهت تعیین انشعاب ساخته می‌شوند. به‌عبارت‌دیگر هر درخت بر اساس مقادیر یک بردار تصادفی ساخته می‌شود. این مقادیر دارای توزیع یکسانی برای تمام درختان موجود در جنگل هستند و به‌صورت مستقلی نمونه‌گیری می‌شوند. برای پیش‌بینی نیز هر درخت رأی خود را صادر و نتیجه نهایی با میانگین‌گیری از تمام آراء تعیین می‌شود (Biau & Scornet, 2016; Liaw & Wiener, 2002). رویکرد جنگل تصادفی در شکل ۱ نشان داده شده است.



شکل ۱. رویکرد جنگل تصادفی


است. همان‌طور که در بالا توضیح داده شد، در واقع شامل دو سطح است، یعنی یک چارچوب برای ادغام مدل‌های پایه و یک الگوریتم یادگیری رگرسیون برای تولید مدل پایه با استفاده از داده‌های آموزشی. الگوریتم درخت طبقه‌بندی و رگرسیون (CART) (Berk, 2008)، برای تولید یادگیرنده پایه استفاده

۴-۲- فرایند اجرای مدل‌سازی

اجرای جنگل تصادفی به‌طورکلی دارای چهار مرحله است: (۱) جمع‌آوری داده‌های تجربی (۲) ساخت یادگیرنده قوی (۳) آزمون یا اعتبارسنجی یادگیرنده؛ (۴) کاربرد مدل در مسائل مهندسی. بدیهی است که مرحله دوم جنگل تصادفی

مجموعه آموزشی و مجموعه آزمایشی تقسیم شدند. مجموعه آموزشی برای تولید مدل نهایی و مجموعه آزمایشی برای نشان دادن دقت مدل در پیش‌بینی مقاومت فشاری استفاده می‌شود. فرایند اجرای مدل‌سازی با استفاده از روش جنگل تصادفی در شکل ۲ ارائه شده است. معمولاً نسبت درصد دو بخش در کل مجموعه داده‌های تجربی ۹۰٪ - ۱۰٪ است (Feng et al., 2020). نتایج حاصل از روش پیشنهادی در این بخش مورد بحث قرار گرفته است. از هردو ترکیب ذکر شده برای ساخت مدل و ارزیابی آن استفاده شده است.

می‌شود. پارامترهای جنگل تصادفی همچنین شامل دو سطح است، یک سطح برای چارچوب جنگل تصادفی و دیگری برای الگوریتم یادگیرنده پایه، یعنی CART. پارامتر مهم برای چارچوب جنگل تصادفی، تعداد درخت است (Biau & Scornet, 2016). برای مسئله پیش‌بینی مقاومت فشاری بتن که ویژگی‌های آن بزرگ نیست، پارامترهای کلیدی CART عبارت‌اند از: حداکثر عمق ریشه، حداقل نمونه‌ها برای تقسیم، حداقل نمونه‌های گره برگ و حداقل کاهش ناخالصی قبل از انجام تقسیم (Berk, 2008). برای ایجاد مدل پیش‌بینی جنگل تصادفی، داده‌های تجربی جمع‌آوری شده به دو بخش، یعنی



شکل ۲. فلوچارت برای اجرای جنگل تصادفی در این مطالعه

است. این روش برای به حداقل رساندن سوگیری مرتبط با نمونه‌گیری تصادفی از مجموعه داده‌های آموزشی توسعه یافته است. داده‌های تجربی به‌طور مساوی به ۱۰ زیرمجموعه تقسیم و سپس از ۹ زیرمجموعه برای ایجاد یک یادگیرنده قوی استفاده می‌شود و از ۱ زیرمجموعه باقی‌مانده برای اعتبارسنجی مدل استفاده می‌کند. مقادیر بهینه‌شده برای پارامترهای فوق در جدول ۴ آورده شده است. روش اعتبارسنجی متقاطع ۱۰ برابری می‌تواند تعمیم و قابلیت اطمینان عملکرد مدل را نشان دهد (Kohavi, 1995).

برای دستیابی به بهترین عملکرد مدل، در اینجا یک استراتژی بهینه‌سازی برای تعیین پارامترهای ذکر شده در بالا به کار گرفته شده است. در ابتدا، محدوده مقادیر این پارامترها با توجه به تحقیقات قبلی در سایر موضوعات تعیین و سپس یک روش جستجوی شبکه‌ای برای یافتن مقادیر خاص استفاده می‌شود، مثلاً یک شبکه پارامتر از محدوده مقادیر اولیه تعریف می‌شود و سپس به‌طور مکرر مدل را با استفاده از اعتبارسنجی متقاطع آموزش و آزمایش می‌کند تا مجموعه پارامتر با بهترین عملکرد را پیدا کند. برای نشان دادن بیشتر عملکرد مدل جنگل تصادفی، از روش اعتبارسنجی متقابل ۱۰ برابری استفاده شده

جدول ۴. تنظیمات الگوریتم برای جنگل تصادفی


تنظیمات	پارامتر	سطح
۱۰۰۰	تعداد درخت	چارچوب کلی
۵۰	حداکثر عمق ریشه	
۴	حداقل نمونه‌ها برای تقسیم	CART
۳	حداقل نمونه‌های گره برگ	
۱۰ ^{-۵}	حداقل کاهش ناخالصی قبل از انجام تقسیم	

$$R^2 = 1 - \frac{\sum_{i=1}^m (P_i - T_i)^2}{\sum_{i=1}^m (T_i - T_i)^2} \quad (2)$$

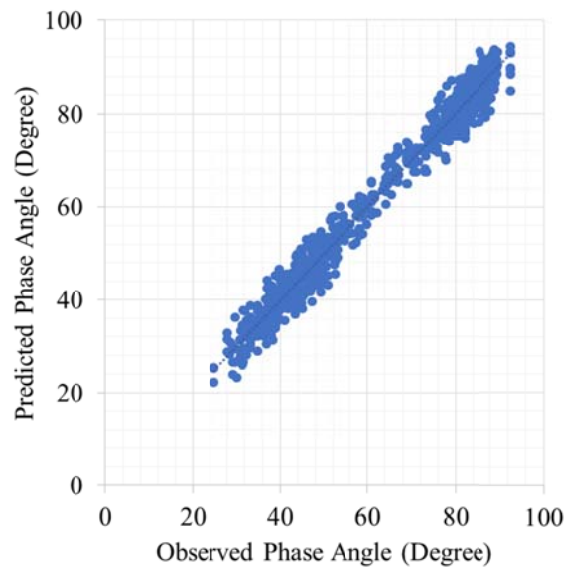
$$RMSE = \sqrt{\frac{\sum_{i=1}^m (P_i - T_i)^2}{m}} \quad (3)$$

دو معیار محاسبه شده برای نتایج مدل جنگل تصادفی در جدول ۵ فهرست شده است. بدیهی است که مدل عملکرد بسیار خوبی در پیش‌بینی مقادیر فشاری از خود نشان می‌دهد. برای مجموعه داده‌های آموزشی R^2 برابر با ۰/۹۴۳۰ که به معنای مقدار پیش‌بینی شده تقریباً مشابه مقدار آزمایش شده است. همه این نتایج نشان می‌دهد که مدل جنگل تصادفی توانایی یادگیری بسیار قوی از داده‌های آموزشی دارد. برای داده‌های آزمایشی، R^2 برابر با ۰/۹۰۴۵ و RMSE مطلوب است. باین حال، نسبت خطا هنوز از نظر عملکرد مهندسی بسیار پایین است. به‌طور خلاصه، مدل جنگل تصادفی مقاومت فشاری را با دقت بسیار بالایی تولید می‌کند.

در مجموع ۹۰ درصد داده‌ها به‌طور تصادفی برای آموزش و ۱۰ درصد داده باقی‌مانده برای آزمایش استفاده شد. شکل ۳ رابطه بین مقادیر زاویه فازی پیش‌بینی شده و مقادیر زاویه فازی آزمایش شده را به ترتیب برای مجموعه آموزش و مجموعه آزمایش نشان می‌دهد. بدیهی است که برای هر دو مجموعه یک رابطه خطی بین مقادیر پیش‌بینی شده و آزمایش شده نشان می‌دهد. به‌خصوص، برای مجموعه آموزشی، نقاط پراکندگی تقریباً با خطوط سیاه ایده آل در شکل‌ها منطبق است (که به معنای مقدار پیش‌بینی شده برابر است با مقدار آزمایش شده)، درحالی‌که برای مجموعه آزمایش، پراکندگی کمی وجود دارد. برای ارزیابی بهتر عملکرد مدل پیش‌بینی توسط الگوریتم جنگل تصادفی، دو شاخص مختلف معرفی شده‌اند که به ترتیب به‌صورت زیر تعریف می‌شوند (روابط ۲ و ۳). اندازه‌گیری R^2 میزان همبستگی خطی بین مقادیر پیش‌بینی شده و آزمایش شده را نشان می‌دهد، هر چه R^2 به ۱ نزدیک‌تر باشد، عملکرد مدل بهتر است. معیار RMSE انحراف بین مقادیر پیش‌بینی شده و مقادیر آزمایش شده را نشان می‌دهد.



(a) Test Data



(b) Train Data

شکل ۳. رابطه بین زاویه فازی آزمایش شده و پیش‌بینی شده


جدول ۵. نتایج پیش‌بینی برای آموزش و آزمایش

معیار اندازه‌گیری	مجموعه داده	روش
RMSE	R^2	
۳/۷۰۵۶	۰/۹۴۳۰	داده آموزشی
۴/۱۰۱	۰/۹۰۴۵	داده آزمایشی

al., 2008; Saoula et al., 2013; Sirin et al., 2017; Tarsi et al., 2018; Tian et al., 2004). به طور مشابه، دمای بالای عملکردی در رتبه سوم قرار گرفت (۴۱ درصد دمای آزمایش). زاویه فاز با افزایش PG در دمای بالا کاهش می‌یابد (Sirin et al., 2017). ویسکوزیته کنماتیک، درجه نفوذ و ویسکوزیته مطلق سهم نزدیکی دارند در پیش‌بینی زاویه فازی (۳۴ و ۳۱ درصد زمان دمای آزمایش)، آن‌ها در واقع حساسیت قیر به دما را منعکس می‌کنند که طبق تحقیقات انجام‌شده مشخص شده با افزایش ویسکوزیته، مقادیر زاویه فاز کاهش می‌یابد. این پدیده را می‌توان به این واقعیت نسبت داد که قیرها با ویسکوزیته بالا سفت‌تر و الاستیک‌تر می‌شوند. این یافته با تحقیقات ویگل و همکاران، لی و همکاران و امیرخانیان و همکاران مطابقت دارد (Amirkhanian et al., 2011; Bari & Witczak, 2007; Lee et al., 2004; Weigel & Stephan, 2017). تأثیر نفوذ بر زاویه فاز قیر مثبت به نظر می‌رسد. با افزایش نفوذ، زاویه فاز نیز افزایش می‌یابد. مقادیر نفوذ بالاتر رفتار ویسکوزیته بیشتری را نشان می‌دهد که منجر به افزایش زاویه فاز می‌شود (Hafeez et al., 2013; Lee et al., 2004). سن پایین عملکردی دارای اهمیت نسبی ۱۳ درصد است زیرا آزمایش DSR برای اندازه‌گیری خاص قیر در دماهای بالا و متوسط انجام می‌شود. زاویه فاز با افزایش PG-low افزایش می‌یابد (۱۲- درجه سانتی‌گراد بالاتر از ۱۸- درجه سانتی‌گراد است). همان‌طور که قبلاً بحث شد، این حساسیت‌ها در واقع با عملکرد مهندسی و پیشینه فیزیکی مطابقت دارد.

مدل توسعه‌یافته جنگل تصادفی دقت بسیار بالایی در پیش‌بینی زاویه فازی ارائه می‌کند، با این حال، این یک مدل جعبه سیاه است که می‌تواند ارتباط بین ورودی و خروجی را ثبت کند، اما نمی‌تواند مکانیسم دقیق پشت مدل را توضیح دهد. با این حال، اگرچه مدل یک جعبه سیاه است، اما می‌توان از آن به عنوان ابزاری برای مطالعه پدیده‌های فیزیکی زیربنایی استفاده کرد، به عنوان مثال، برای مطالعه حساسیت هر متغیر ورودی بر روی زاویه فازی؛ بنابراین می‌توان اهمیت هر متغیر را درک کرد. شکل ۴ اهمیت نسبی هر یک از متغیرها را نشان می‌دهد. می‌توان دریافت که زمان دمای آزمایش مهم‌ترین عامل مؤثر بر زاویه فازی است؛ زیرا با افزایش دمای آزمایش، زاویه فاز افزایش می‌یابد که دلیل آن تأثیر قابل توجه بر تغییر شکل و روانی قیر در دماهای بالا است. این موضوع با یافته‌های رامیسوا و همکاران، عمری و همکاران، علی و همکاران، ویگل و همکاران و محمد و همکاران مطابقت دارد (Al-Omari et al., 2020; Ali et al., 2016; Hafeez et al., 2013; Khasawneh & Al-Oqaily, 2022; Weigel & Stephan, 2017). سن پیرشدگی همچنین تأثیر قابل توجهی بر مقاومت فشاری دارد، حدود ۸۷ درصد دمای آزمایش، زیرا از نظر شیمیایی بر تمام اجزای قیر تأثیر می‌گذارد. زاویه فاز پیش‌بینی‌شده قیر به طور قابل توجهی با افزایش سن کاهش می‌یابد. این را می‌توان به افزایش کشش و سفتی چسباننده‌ها نسبت داد که به نوبه خود بر خواص قیر تأثیر می‌گذارد. این موضوع مطابق با نتایج تحقیقات لیو و همکاران، تارسی و همکاران، ژیاو و همکاران، جوشی، فیصل، سیرین و همکاران، سائولا و همکاران و هوفکو و همکاران است (Faisal et al., 2017; Hofko et al., 2017; Joshi et al., 2013; Liu et

Relative importance of variables





شکل ۴. اهمیت نسبی متغیرها در پیش‌بینی زاویه فازی

اگرچه ترکیب ۲ دارای ۶ متغیر ورودی است، اما کمترین دقت را دارد زیرا مهم‌ترین عامل یعنی دمای آزمایش در نظر گرفته نشده است. به‌عنوان مقایسه، ترکیب ۳ نیز دارای ۶ متغیر ورودی (بدون متغیر دمای بالای عملکرد) است اما عملکرد آن بسیار بهتر از ترکیب ۲ است و R^2 برابر با ۰/۸۹۲۸ و RMSE برابر با ۴/۸۶ است. ترکیب ۵ تنها ۴ متغیر ورودی دارد اما شامل زمان دمای آزمایش است، بنابراین عملکرد آن بهتر از ترکیب ۲ و ۶ است. ترکیب ۴ مشابه ترکیب ۱ بهترین عملکرد را داشت اگرچه فقط ۵ متغیر ورودی دارد. به‌طور خلاصه، دمای آزمایش و نوع پیرشدگی مهم‌ترین متغیرهای ورودی است که باید در مدل در نظر گرفته شود تا پیش‌بینی با دقت بالا به دست آید. نادیده گرفتن دمای آزمایش منجر به کاهش چشم‌گیر دقت می‌شود (R^2 از ۰/۹۰۴۵ به ۰/۴۳۶)، درحالی‌که نادیده گرفتن نوع پیرشدگی منجر به کاهش نسبتاً کمی دقت (R^2 از ۰/۹۰۴۵ به ۰/۸۹۲۸) می‌شود. نادیده گرفتن یک یا حتی دو جزء دیگر باعث افت کوچک‌تر می‌شود (R^2 از ۰/۹۰۴۵ به ۰/۸۳۱).

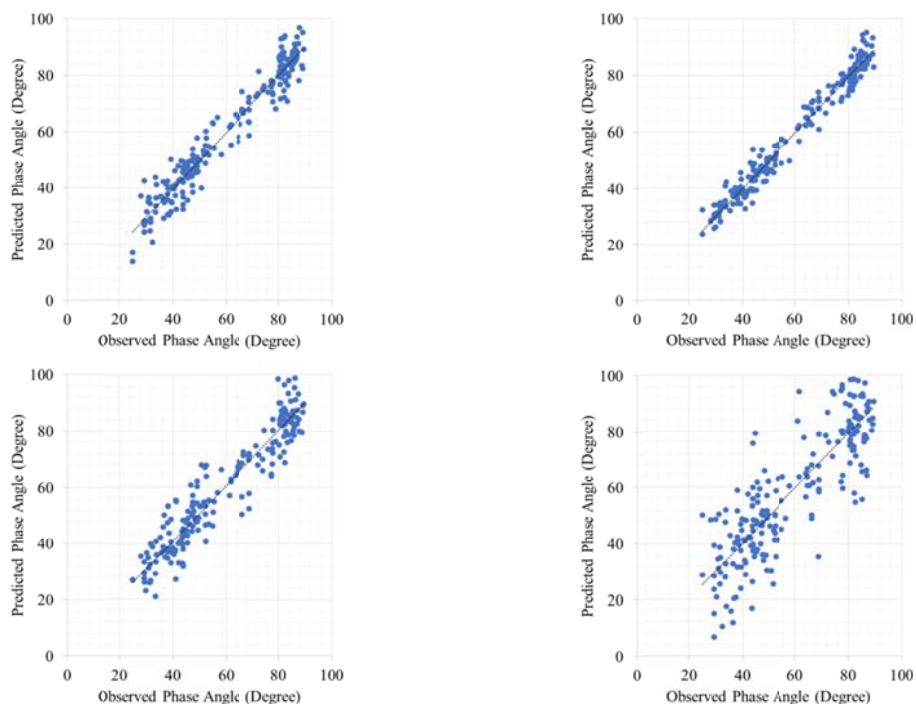
تأثیر حساسیت (تغییر) مقادیر متغیر ورودی در این قسمت مورد مطالعه قرار گرفته است. در اینجا تأثیر عدد متغیر ورودی بر پیش‌بینی نهایی تحلیل می‌شود. هدف این است که بفهمیم در صورت از دست دادن برخی از داده‌ها (ورودی‌ها) عملکرد مدل چگونه تغییر می‌کند. شش ترکیب ورودی در نظر گرفته شده است (جدول ۶). ترکیب ۱ داده خام است درحالی‌که ترکیب ۶ تنها دارای سه ورودی است، یعنی دمای آزمایش، ویسکوزیته کینماتیکی و درجه نفوذ. ترکیب ۲ تا ۵ به تدریج متغیرهای ورودی مختلف را نادیده می‌گیرد تا تأثیر را ببیند. نتایج مقادیر پیش‌بینی شده در مقابل مقادیر آزمایش شده توسط شش ترکیب در شکل ۵ نشان داده شده است و معیارهای عملکرد مربوطه نیز در جدول ۶ آورده شده است. مطمئناً نتایج با ترکیب ۱ بهترین امتیازها را به دست می‌آورند زیرا کل اطلاعات را به‌عنوان ورودی ارائه می‌دهد. عملکرد ترکیب ۲ کمترین است که معیارهای آن R^2 برابر با ۰/۴۳۶ و RMSE برابر با ۱۳/۱۲ است. جالب است که دقت مدل به‌سادگی با افزایش عدد متغیر ورودی افزایش نمی‌یابد، همان‌طور که توسط نتایج ترکیبات ۲ تا ۵ نشان داده شده است.

جدول ۶. معیارهای عملکرد برای تجزیه و تحلیل ترکیبات مختلف متغیر ورودی

ترکیب	معیار ارزیابی	
	R^2	RSME
1: X1; X2; X3; X4; X5; X6; X7	۰/۹۰۴۵	۵/۰۰۶
2: X2; X3; X4; X5; X6; X7	۰/۴۳۶	۱۳/۱۲
3: X1; X3; X4; X5; X6; X7	۰/۸۹۲۸	۴/۸۶
4: X1; X2; X3; X4; X5	۰/۹۰۴۵	۵/۴۸
5: X1; X2; X3; X6	۰/۸۳۱	۶/۰۴۵
6: X1; X3; X4	۰/۴۴	۱۲/۰۴



شکل ۵. تأثیر تعداد متغیرهای ورودی بر روی پیش‌بینی زاویه فازی بر اساس داده‌های آزمایشی



ادامه شکل ۵. تأثیر تعداد متغیرهای ورودی بر روی پیش‌بینی زاویه فازی بر اساس داده‌های آزمایشی

۵- نتیجه‌گیری

با استفاده از مدل جنگل تصادفی، تأثیر متغیرهای ورودی بر متغیر پاسخ مشخص شد که دمای آزمون بالاترین تأثیر را بر δ دارد و به دنبال آن نوع پیرشدگی و دمای بالای عملکرد. دمای پایین عملکرد کمترین تأثیر را در پیش‌بینی زاویه فاز دارد. حساسیت مدل به نوع متغیرهای ورودی بررسی شد که نتایج نشان می‌دهد دمای پیرشدگی مهم‌ترین عامل در پیش‌بینی زاویه فازی است.

نتایج حاصل از این تحقیق با نتایج بسیاری از مقالات و پژوهش‌های مشابه مطابقت دارد.

مدل‌های پیش‌بینی‌کننده می‌تواند به سازمان‌های متولی کمک کند تا رفتار قیر را در شرایط مختلف قبل از اجرا یا ساخت‌وساز واقعی پیش‌بینی کنند. چنین قابلیت‌های تحلیلی پیشرفته‌ای به‌نوبه خود به پیش‌بینی عملکرد روسازی بدون نیاز به صرف زمان و هزینه برای اندازه‌گیری‌های آزمایشگاهی کمک می‌کند. به‌منظور کارهای آتی پیشنهاد می‌شود از سایر مدل‌های یادگیری ماشین نظیر الگوریتم‌های نیمه نظارت‌شده و تقویتی در پیش‌بینی زاویه فازی استفاده شود. همچنین با افزایش تعداد و تنوع داده‌ها می‌توان مدل‌های یادگیری ماشین را برای

در این مطالعه از یک الگوریتم یادگیری ماشین گروهی برای پیش‌بینی زاویه فاز به‌عنوان یکی از نتایج اصلی DSR استفاده شده است. زاویه فاز به‌عنوان متغیر پاسخ با هفت پیش‌بینی‌کننده دمای آزمایش، نوع پیری، PG-کم، PG-بالا، نفوذ، ویسکوزیته سینماتیکی و مطلق در این مطالعه استفاده شد. کل مجموعه داده‌ها به دو مجموعه آموزشی و مجموعه آزمایشی تبدیل گشت. مدل توسط جنگل تصادفی با استفاده از مجموعه آموزشی تولیدشده و سپس توسط مجموعه آزمایشی ارزیابی شد. نتایج حاصل از این مطالعه عبارت‌اند از:

مدل جنگل تصادفی می‌تواند به‌طور دقیق و کارآمد زاویه فازی را با متغیرهای ورودی داده‌شده پیش‌بینی کند. این مدل درست مانند یک جعبه سیاه است و کاربران نیازی به دانستن مکانیسم واقعی ندارند که آن را برای استفاده ساده و راحت می‌کند.

میانگین R^2 با اعتبارسنجی متقاطع ۱۰ برابری برای این مدل به ۰/۹۰۴۵ می‌رسد و به این معنی است که خطای پیش‌بینی بسیار کم است. در همین حال، میانگین RMSE برابر با ۴/۱۰۱ است که نشان می‌دهد مدل دارای اشتقاق پیش‌بینی پایینی است.

-CHAROENTHAM, N., & KANITPONG, K. (2012). Development of a Performance Grading System for Asphalt Binders used in Thailand. *Asian Transport Studies*, 2(2), 121-138.

-Faisal, H. M., Mannan, U. A., Tarefder, R. A., & Arifuzzaman, M. (2017). Evaluating the relationship between dynamic shear modulus and nano scale modulus of asphalt binders at different aging conditions. *GEOMATE Journal*, 13(35), 1-7.

-Feng, D.-C., Liu, Z.-T., Wang, X.-D., Chen, Y., Chang, J.-Q., Wei, D.-F., & Jiang, Z.-M. (2020). Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach. *Construction and Building Materials*, 230, 117000.

-Hafeez, I., Hussain, J., Riaz, K., Khitab, A., Hussain, S., Zaidi, B., Farooqi, U., Hayat, A., Ahmed, I., & Asif, A. (2013). Influence of time and temperature on asphalt binders rheological properties. *Life Science Journal*, 10(12s), 894-898.

-Han, J., Kamber, M., & Mining, D. (2006). Concepts and techniques. *Morgan Kaufmann*, 340, 94104-93205.

-Hofko, B., Cannone Falchetto, A., Grenfell, J., Huber, L., Lu, X., Porot, L., Poulikakos, L., & You, Z. (2017). Effect of short-term ageing temperature on bitumen properties. *Road Materials and Pavement Design*, 18(sup2), 108-117.

-Huang, S.-C., & Zeng, M. (2007). Characterization of aging effect on rheological properties of asphalt-filler systems. *International Journal of Pavement Engineering*, 8(3), 213-223.

-Joshi, C., Patted, A., Archana, M., & Amarnath, M. (2013). Determining the rheological properties of asphalt binder using dynamic shear rheometer (DSR) for selected pavement stretches. *International Journal of Research in Engineering and Technology*, 11, 192-196.

-Kabir, P., Sakhaeifar, M. S., & Newcomb, D. (2014). Analytical approach to estimate the rheological properties of asphalt binders. *Transportation Research Record*, 2447(1), 51-60.

-Khalil, N., Bahia, H., & Clopotel, C. (2009). Developing a performance grading system for asphalt binders in Lebanon. Sixth International Conference on Maintenance and Rehabilitation of Pavements and Technological Control (MAIREPAV6).

-Khamis, N., Yazid, M. R. M., Hamim, A., Rosyidi, S. A. P., Yusoff, N. I. M., & Borhan, M. N. (2018). Predicting the rheological properties of bitumen-filler mastic using artificial neural network methods. *Jurnal Teknologi*, 80(1).

-Khasawneh, M. A., & Al-Oqaily, D. M. (2022). Development of Analytical Models to Predict the Dynamic Shear Rheometer Outcome—Phase Angle. *International Journal of Pavement Research and Technology*, 1-19.

پیش‌بینی زاویه فازی و سایر معیارهای عملکردی قیر استفاده کرد.

۶-مراجع

-Abbas, A. S., Albayati, A., & Alani, H. (2010). The transition to a PG Grading system for asphalt cement in Iraq. *Journal of Engineering*, 16(4), 5911-5931.

-Abdulhaq, H. A. (2015). Predicting complex shear modulus using artificial neural networks. *Journal of Civil Engineering and Construction Technology*, 6(3), 15-26.

-Al-Omari, A., Taamneh, M., Khasawneh, M. A., & Al-Hosainat, A. (2020). Effect of crumb tire rubber, microcrystalline synthetic wax, and nano silica on asphalt rheology. *Road Materials and Pavement Design*, 21(3), 757-779.

-Al-Omari, A. A., Khedaywi, T. S., & Khasawneh, M. A. (2018). Laboratory characterization of asphalt binders modified with waste vegetable oil using SuperPave specifications. *International Journal of Pavement Research and Technology*, 11(1), 68-76.

-Ali, Y., Irfan, M., Ahmed, S., Khanzada, S., & Mahmood, T. (2016). Investigation of factors affecting dynamic modulus and phase angle of various asphalt concrete mixtures. *Materials and structures*, 49(3), 857-868.

-Amirkhanian, A. N., Xiao, F., & Amirkhanian, S. N. (2011). Evaluation of high temperature rheological characteristics of asphalt binder with carbon nano particles. *Journal of Testing and Evaluation*, 39(4), 1.

-Asifur Rahman, A., Mannan, U. A., & Tarefder, R. A. (2017). Binder rheology based dynamic modulus and phase angle predictive models for asphalt concrete. In *Airfield and Highway Pavements 2017* (pp. 215-224).

-Bahia, H., & Vivanco, J. (2005). The transition to a PG grading system for asphalt binders in developing countries. Conference Proceedings, First Middle East International Conference on Advances in Civil, Mechanical and Materials Engineering, May 10-13,

-Bari, J., & Witczak, M. W. (2007). New predictive models for viscosity and complex shear modulus of asphalt binders: for use with mechanistic-empirical pavement design guide. *Transportation Research Record*, 2001(1), 9-19.

-Berk, R. A. (2008). Classification and regression trees (CART). In *Statistical learning from a regression perspective* (pp. 1-65). Springer.

Biau, G., & Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197-227.

- asphalt binders in the State of Qatar: a case study. *Road Materials and Pavement Design*, 18(sup4), 165-184.
- T315, A. (2012). Standard method of test for determining the rheological properties of asphalt binder using a dynamic shear rheometer (DSR). *American Association of State Highway and Transportation Officials*.
- Tarsi, G., Varveri, A., Lantieri, C., Scarpas, A., & Sangiorgi, C. (2018). Effects of different aging methods on chemical and rheological properties of bitumen. *Journal of Materials in Civil Engineering*, 30(3), 04018009.
- Tian, X., Zheng, J., & Zhang, Q. (2004). Effect of aging on viscoelastic performance of asphalt binder. *SATC 2004*.
- Weigel, S., & Stephan, D. (2017). Modelling of rheological and ageing properties of bitumen based on its chemical structure. *Materials and structures*, 50(1), 1-15.
- Xu, G., Zong, Y., & Yang, Z. (2013). *Applied data mining*. CRC Press.
- Yener, E., & Hınıslioğlu, S. (2014). Effects of exposure time and temperature in aging test on asphalt binder properties. *International Journal of Civil & Structural Engineering*, 5(2), 112-124.
- Zhou, Z.-H. (2009). Ensemble learning, *Encyclopedia of Biometrics*. doi, 10, 978-970.
- Zhou, Z.-H. (2012). *Ensemble methods: foundations and algorithms*. CRC press.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *Ijcai*,
- Lee, M.-G., Chiu, C.-T., & Chen, K.-C. (2004). Comparison of results of SHRP and conventional binder tests on paving asphalts. *International Journal of Applied Science and Engineering*, 2(3), 245-245.
- Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R news*, 2(3), 18-22.
- Liu, C.-h., Wu, S.-p., Liu, Q.-t., & Zhu, G.-j. (2008). Rheological characteristics of aged asphalt binder. *Journal of Central South University of Technology*, 15(1), 298-301.
- Oshone, M., Dave, E., Daniel, J. S., & Rowe, G. M. (2017). Prediction of phase angles from dynamic modulus data and implications for cracking performance evaluation. *Road Materials and Pavement Design*, 18(sup4), 491-513.
- Remišová, E., Zatkaliková, V., & Schlosser, F. (2016). Study of rheological properties of bituminous binders in middle and high temperatures. *Civil and Environmental Engineering*, 12(1), 13-20.
- Saoula, S., Soudani, K., Haddadi, S., Munoz, M. E., & Santamaria, A. (2013). Analysis of the rheological behavior of aging bitumen and predicting the risk of permanent deformation of asphalt.
- Sirin, O., Paul, D. K., Kassem, E., & Ohiduzzaman, M. (2017). Effect of ageing on

Creating an Analytical Model to Predict the Phase Angle (Δ) in The Dynamic Shear Rheometer (DSR) Test

Hassan Hosseinzadeh, M.Sc., Grad., Eqbal Lahori Institute of Higher Education, Mashhad, Iran.

Sina Arman, M.Sc., Grad., Islamic Azad University, Mashhad, Iran.
Behnam Khayat, M.Sc., Grad., Islamic Azad University, Mashhad, Iran.

E-mail: hosseinzadeh-ha@mashhad.ir

Received: February 2024- Accepted: June 2024

ABSTRACT

Superpave bitumen specifications are designed to improve pavement performance by controlling pavement problems under a wide range of temperatures and aging conditions. Dynamic shear rheometer (DSR) is one of the superpave tests used to determine the rheological properties of bitumen. The aim of this study is to create a prediction model with the ability to predict the phase angle (δ) as a main result of the DSR test method. This, in turn, can reduce the time to obtain laboratory results and, consequently, the cost. For this purpose, an ensemble machine learning method with a random forest approach has been used. Based on this, seven effective variables on bitumen phase angle were collected from the results of 1225 samples from the LTPP website. These factors are: test temperature, type of aging, low performance degree (PG-low), high performance degree (PG-high), penetration, kinematic viscosity and absolute viscosity (dynamic). The proposed method is confirmed through a 10-fold cross-validation method and based on the analysis, it reaches more than 90% accuracy in terms of coefficient of determination. Finally, the effect of some key factors in the random forest approach was also investigated, for example, the effect of the sensitivity of the phase angle input parameters. Also, based on the results of sensitivity analysis, the importance of different input variables was obtained. Based on the research, the test temperature and the type of aging have the greatest effect on the bitumen phase angle. By increasing the number and variety of training data, the model can be used to achieve better results and predict other performance properties of bitumen.

Keywords: LTPP, Dynamic Shear Rheometer, Phase Angle, Machine Learning, Random Forest