

توسعه مدل‌های پیش‌بینی برای مدول مرکب برشی و زاویه فاز ماستیک اصلاح شده با استایرن بوتادین استایرن

علمی - پژوهشی

پوریا حاجی‌کریمی*، استادیار، دانشکده مهندسی عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران
مهرداد احسانی، دانشجوی دکتری، دانشکده مهندسی عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران
محمد راهی، مدیر واحد تحقیق و توسعه، شرکت نفت پاسارگاد، تهران، ایران
سحر منیعی، کارشناس مسئول واحد تحقیق و توسعه، شرکت نفت پاسارگاد، تهران، ایران
*پست الکترونیکی نویسنده مسئول: phajikarimi@aut.ac.ir

دریافت: ۱۴۰۱/۰۵/۲۰ - پذیرش: ۱۴۰۱/۱۰/۱۵

صفحه ۲۵۴-۲۴۱

چکیده

پیش‌بینی خصوصیات ویسکوالاستیک ماستیک در مهندسی روسازی از اهمیت بالایی برخوردار است. تاکنون پیش‌بینی خصوصیات ویسکوالاستیک ماستیک با استفاده از ابزارهای یادگیری ماشین که رابطه ریاضی‌ارایه می‌دهند مورد توجه قرار نگرفته است. هدف از این تحقیق پرکردن این خلا تحقیقاتی و توسعه مدل‌های پیش‌بینی برای مدول مرکب برشی (G^*) و زاویه فاز (δ) ماستیک با قیر اصلاح شده توسط استایرن بوتادین استایرن (SBS) در دمای پایین و متوسط می‌باشد. سه مقدار متفاوت SBS (۲، ۴ و ۶ درصد) برای اصلاح قیر و چهار درصد مختلف پرشدگی فیلر (۱۰، ۱۸، ۲۵ و ۳۵ درصد) برای ساخت نمونه‌های ماستیک در نظر گرفته شده است. آزمایش رنومتر برشی دینامیکی (DSR) در حالت جاروب فرکانس در ۲۱ فرکانس بارگذاری از ۰/۱ تا ۱۰۰ هرتز و در هفت دمای ۲۲-، ۱۶-، ۱۰-، ۰-، ۱۰، ۱۶ و ۲۲ درجه سانتیگراد انجام شده است. با استفاده از این آزمایش مقدار G^* و δ قیر پایه، قیر اصلاح شده و همچنین نمونه‌های ماستیک اندازه‌گیری شده است. به عبارت دیگر، از نتایج حاصل از انجام آزمایش جاروب فرکانس به منظور تهیه داده‌های مورد نیاز برای ساخت مدل پیش‌بینی استفاده شده است. از برنامه‌ریزی ژنتیکی چند ژنی برای توسعه مدل پیش‌بینی G^* و δ ماستیک با در نظر گرفتن متغیرهای ورودی درصد افزودنی، فرکانس، دما، درصد پرشدگی فیلر و G^* و δ قیر پایه استفاده شده است. در نهایت دو مدل پیش‌بینی مجزا برای G^* و δ ارایه شده است که بترتیب دارای ضریب تعیین ۰/۹۶ و ۰/۹۸ می‌باشند. نتایج نشان می‌دهد که برنامه‌ریزی ژنتیکی چند ژنی می‌تواند با دقت بسیار مناسب رفتار ویسکوالاستیک ماستیک را پیش‌بینی نماید. پس از بررسی عملکرد مدل‌ها، با انجام تحلیل حساسیت روی آن‌ها، نشان داده شد که خصوصیات ویسکوالاستیک قیر پایه به عنوان متغیرهای ورودی بیشترین تاثیر را در پیش‌بینی متغیرهای خروجی دارند.

واژه‌های کلیدی: برنامه‌ریزی ژنتیک چند ژنی، رفتار ویسکوالاستیک، ماستیک، قیر اصلاح شده، SBS

۱-مقدمه

بین سنگدانه‌های مختلف با ابعاد متفاوت قرار می‌گیرد (Hajikarimi & Nejad, 2021). با توجه به دما، سطح تنش / نرخ کرنش می‌توان از قابلیت ارتجاعی، ویسکوالاستیسیته خطی یا غیرخطی برای توصیف رنولوژی و مکانیکی مواد

قیر به عنوان یکی از مهمترین اجزاء ساخت مخلوط آسفالتی مورد استفاده در روسازی‌های انعطاف‌پذیر می‌باشد. قیر ماده‌ای ویسکوالاستیک است که رفتار آن به زمان/فرکانس، دما و سرعت بارگذاری وابسته است و در ساختار مخلوط آسفالتی

در این مطالعه از سه مقدار مختلف SBS (۲، ۴ و ۶ درصد) استفاده شده است. همچنین چهار مقدار مختلف فیلر (۱۰، ۱۸، ۲۵ و ۳۵ درصد) برای ساخت نمونه‌های ماستیک در نظر گرفته شده است. دو پارامتر ویسکوالاستیک مدول مرکب برشی (G^*) و زاویه فاز (δ) برای تمام نمونه‌ها با انجام آزمایش جاروب فرکانس در دماهای ۲۲، -۱۶، -۱۰، ۰، ۱۰، ۱۶ و ۲۲ اندازه‌گیری شده است. یکی از نگرانی‌های اصلی در مورد ماستیک تهیه شده با قیر اصلاح شده، پیش‌بینی دقیق ویژگی‌های ویسکوالاستیک آن در دما، فرکانس، مقدار افزودنی و درصد پرشدگی فیلر مورد نظر می‌باشد (Hajikarimi, Fakhari Tehrani, Moghadas Nejad, Absi, Khodaii, et al., 2019; Kim & Buttlar, 2010). در مطالعات گذشته (Hajikarimi, Fakhari Tehrani, Moghadas Nejad, Absi, Khodaii, et al., 2019; Kim & Buttlar, 2010) نشان داده شده است که پیش‌بینی رفتار رئولوژی و مکانیکی ماستیک به ویژه زمانی که مقدار درصد پرشدگی فیلر زیاد باشد، بدلیل برخی پدیده‌ها مانند مکانیزم سفت شدن به سادگی امکان‌پذیر نمی‌باشد. با توجه به ماهیت پیچیده مسئله استفاده از ابزار یادگیری ماشین می‌تواند مفید باشد. در سال‌های اخیر یادگیری ماشین برای حل مسائل مهندسی روسازی به شدت مورد توجه قرار گرفته است. شفافبخش و تناکی‌زاده (Shafabakhsh & Tanakizadeh, 2016) برای پیش‌بینی سختی مخلوط آسفالتی از تکنیک برنامه‌ریزی ژنتیکی چند ژنی استفاده کردند. ایشان از نتایج آزمایش کشش غیرمستقیم، داده‌های مورد نیاز را فراهم نمودند و دو مدل مجزا برای دو شکل بارگذاری ارائه دادند. همچنین در مطالعه ایشان از دما، مدت بارگذاری، دوره استراحت و شکل بارگذاری بعنوان متغیرهای ورودی به منظور پیش‌بینی سختی مخلوط آسفالتی استفاده شده است. مجیدی‌فرد و همکاران (Majidifard et al., 2019) با استفاده از برنامه‌ریزی ژنتیک، مقدار انرژی شکست مخلوط آسفالتی را با ۵۷ داده بدست آمده از آزمایش DCT پیش‌بینی کردند. ایشان متغیرهای ورودی درجه عملکرد قیر (PG)، درصد قیر، حداکثر اندازه اسمی سنگدانه (NMAS)، مقدار پورد لاستیک و دما را در نظر گرفتند. در نهایت، ایشان نشان دادند که ضریب تعیین مدل پیش‌بینی توسعه داده شده ۰/۹۶ می‌باشد که نشان از عملکرد خوب روش برنامه‌ریزی ژنتیک می‌باشد. در سال ۲۰۲۱، مجیدی‌فرد و همکاران (Majidifard et al., 2021)

قیری استفاده کرد (Di Benedetto et al., 2004; Krishnan & Rajagopal, 2005). ترکیب قیر و فیلر (عموما سنگدانه با اندازه کوچکتر از ۷۵ میکرومتر) که در ادبیات با عنوان ماستیک شناخته می‌شود، می‌تواند برای پیش‌بینی رفتار مکانیکی مخلوط آسفالتی مورد استفاده قرار گیرد. فخاری تهرانی و همکاران (Tehrani et al., 2013) چندین مطالعه روی توصیف رفتار مکانیکی ماستیک با استفاده از رویکردهای آزمایشگاهی و عددی برای افزایش درک رفتار مخلوط آسفالت داشته‌اند (Chaudhary et al., 2020; Hajikarimi, Fakhari Tehrani, Moghadas Nejad, Absi, Khodaii, et al., 2019; Hajikarimi, Fakhari Tehrani, Moghadas Nejad, Absi, Rahi, et al., 2019).

دو پارامتر اصلی برای توصیف رفتار ویسکوالاستیک مواد قیری وجود دارد: مدول مرکب برشی (G^*) و زاویه فاز (δ). این دو پارامتر مهم را می‌توان با انجام چند آزمایش محدود روی قیرها و ماستیک‌های آسفالتی با استفاده از رئومتر برشی دینامیک (DSR) اندازه‌گیری نمود. عملکرد قیر و ماستیک در طیف وسیعی از فرکانس‌ها و دماها با استفاده از اصل برهم‌نهی دما و زمان (Brinson & Brinson, 2008) و مفهوم منحنی جامع (Yusoff et al., 2011) به طور دقیق قابل درک است. یک روش شناخته شده و متعارف برای بهبود خواص رئولوژی و مکانیکی قیر، استفاده از افزودنی مناسب برای دستیابی به معیارهای استاندارد در دمای پایین، متوسط و بالا با توجه به شرایط آب و هوایی می‌باشد.

چندین کار تحقیقاتی به بررسی تاثیر افزودنی‌های مختلف بر خواص رئولوژی، رفتار مکانیکی، دوام و ویژگی‌های قیر اختصاص داده شده است (Aflaki et al., 2014; Behnood & Gharehveran, 2019; Yildirim, 2007). در این مطالعه از افزودنی استایرن بوتادین استایرن (SBS) استفاده شده است. این افزودنی بعنوان اصلاح‌کننده قیر در سراسر جهان به منظور افزایش ویسکوزیته قیر پایه، نقطه نرمی، مقاومت شیارشدگی و مقاومت خستگی مورد استفاده قرار می‌گیرد (Modarres, 2013; Nejad et al., 2017). به طور گسترده مقدار معمول SBS مورد استفاده در مقالات بین ۵ تا ۷ درصد جرم قیر می‌باشد. بهنود و اُلک (Behnood & Olek, 2017) نشان دادند که SBS ویژگی‌های دمای بالای قیر را بهبود می‌بخشد زیرا سفتی و مدول مرکب برشی را افزایش و مقدار زاویه فاز را کاهش می‌دهد.

افزایش سرعت می‌شود. در این مطالعه از روش برنامه‌ریزی ژنتیکی چند ژنی برای پیش‌بینی مدول مرکب برشی (G^*) و زاویه فاز (δ) ماستیک استفاده شده است. مدول مرکب برشی (G^*) و زاویه فاز (δ) قیر، دمای آزمایش، فرکانس، مقدار افزودنی و درصد پرشدگی فیلر به عنوان متغیرهای ورودی در نظر گرفته شده‌اند. با استفاده از دو مدل ارائه شده برای مدول مرکب برشی (G^*) و زاویه فاز (δ) ماستیک می‌توان خواص ویسکوالاستیک ماستیک را در درصدهای مختلف افزودنی و درصدهای مختلف پرشدگی فیلر تعیین نمود. این دو مدل می‌توانند به صورت گسترده توسط محققان، مهندسان و طراحان جهت برآورد رفتار ویسکوالاستیک آسفالت مورد استفاده قرار گیرند.

۲- مصالح و روش‌های آزمایش

۲-۱- مصالح

قیر پایه مورد استفاده در این مطالعه PG58-22 می‌باشد که از شرکت نفت پاسارگاد واقع در تهران تهیه شده است. مهمترین خصوصیات متعارف این قیر در جدول (۱) گزارش شده است. نوع SBS مورد استفاده در این مطالعه C-502 است که دارای ۳۱ درصد استایرن و ساختار خطی می‌باشد. خواص اصلی SBS مورد استفاده در جدول (۲) ذکر شده است. همچنین در این مطالعه سه مقدار متفاوت ۲، ۴ و ۶ درصد (برحسب وزن قیر پایه) در نظر گرفته شده است.

با استفاده از ۹۶ داده بدست آمده از آزمایش هامبورگ، عمق شیارشدگی مخلوط آسفالتی را با تکنیک برنامه‌ریزی بیان ژنی پیش‌بینی کردند. ایشان از متغیرهای PG، نوع مخلوط آسفالتی، اندازه و دانه‌بندی سنگدانه، مقدار قیر و کل مقدار قیر بازیافتی برای پیش‌بینی عمق شیارشدگی مخلوط آسفالتی استفاده کردند. سادات حسینی و همکاران (Hosseini et al., 2021) در سال ۲۰۲۱ با موفقیت از برنامه‌ریزی ژنتیک برای پیش‌بینی رفتار ویسکوالاستیک قیر اصلاح شده با SBS، خرده لاستیک (CR) و اسید پلی فسفریک (PPA) استفاده کردند. آنها روابط جداگانه‌ای برای مدول مرکب پیچشی و زاویه فاز بر اساس دما، فرکانس بارگذاری و مقدار افزودنی ارائه دادند. غفاری و همکاران (Ghafari et al., 2022) در سال ۲۰۲۲ از برنامه‌ریزی ژنتیک برای پیش‌بینی منحنی مقاومت در برابر شکست استفاده کردند. ایشان آزمایش تیر سه نقطه‌ای را برای فراهم نمودن داده‌های مورد نیاز انجام دادند و متغیرهای مستقل متفاوتی مانند دما، درصد قیر و درصد خرده لاستیک را در نظر گرفتند. ضریب تعیین مدل ساخته شده ۰/۸۷ گزارش شده است که دقت مناسبی می‌باشد. با توجه به مطالب بیان شده، تاکنون پیش‌بینی خواص ویسکوالاستیک ماستیک (G^* و δ) با در نظر گرفتن خواص ویسکوالاستیک قیر با رویکرد یادگیری ماشین مورد توجه قرار نگرفته است. ساخت مدل‌های پیش‌بینی خواص ویسکوالاستیک ماستیک با رویکرد یادگیری ماشین می‌تواند بسیار مفید باشد زیرا از انجام آزمایش رتومتر برشی دینامیکی جلوگیری می‌کند و باعث کاهش هزینه و

جدول ۱. خواص متعارف قیر پایه مورد استفاده در این مطالعه

مقدار	استاندارد	آزمایش
۹۲	ASTM D5	درجه نفوذ (۱۰۰ گرم، ۵ ثانیه، ۲۵ درجه سانتیگراد)، ۰/۱ میلیمتر
۴۷/۹	ASTM D36	نقطه نرمی، درجه سانتیگراد
>۱۰۰	ASTM D113	شکل‌پذیری (۲۵ درجه سانتیگراد، ۵ سانتی‌متر بر دقیقه)، سانتیمتر
۲۷۵	ASTM D92	نقطه اشتعال، درجه سانتیگراد
۰/۳۱۵	ASTM D4402	گرانروی در ۱۳۵ درجه سانتیگراد، پاسکال.ثانیه
۰/۱	ASTM D1754	کاهش جرم پس از TFOT، %

جدول ۰۲. ویژگی‌های فیزیکی و شیمیایی استایرن بوتادین استایرن (SBS)

مقدار	استاندارد	مشخصات پلیمر
۵	MA04-3-064	گرانروی در محلول تولوئن ۲۵٪، پاسکال.ثانیه
۱۳	MA 04-3-003	گرانروی در محلول تولوئن ۲۵٪، ۵/۲۳٪، میلی پاسکال.ثانیه
۰/۴	ASTM D-5668	مواد فرار، درصد
۲	ASTM D -1925-70	Hunterlab Color
۳۱	ASTM D -5775	مقدار استیرن، درصد
۷۶	ASTM D-2240	سختی (shore A)
<۰/۱	MA 04-3-01	انحلال‌پذیری در تولوئن، ۳۲۵ مش، درصد
<۰/۳۵	ASTM D -566	مقدار خاکستر

۲-۲- ماستیک‌های پایه و اصلاح شده

به منظور ساخت نمونه‌های ماستیک از چهار درصد مختلف پرشدگی فیلر (۱۰، ۱۸، ۲۵ و ۳۵ درصد) براساس حجم کل ماستیک در نظر گرفته شده است. در این تحقیق وزن مخصوص قیر و فیلر بترتیب ۱/۰۳ و ۲/۶۵۵ گرم بر سانتیمتر مکعب می‌باشد. نرخ جرمی نمونه‌های حاوی ۱۰، ۱۸، ۲۵ و ۳۵ درصد فیلر بترتیب برابر ۲۲/۳، ۳۶/۸، ۴۶/۲ و ۵۸/۵ می‌باشد. اعداد گزارش شده با استفاده از روابط ۱ و ۲ بدست آمده‌اند.

$$\rho_{bitumen} = \frac{m_b}{v_b} \quad (1)$$

$$\rho_{filler} = \frac{m_f}{v_f} \quad (2)$$

که در آن از زیرنویس **b** و **f** بترتیب برای قیر و فیلر سیلیسی استفاده شده است. برای تعیین جرم مخصوص (M) و حجم

(V) ماستیک، می‌توان از معادلات ۳ و ۴ با صرف نظر کردن میزان فضای خالی استفاده نمود.


$$m_b + m_f = M \quad (3)$$

$$v_b + v_f = V \quad (4)$$

با جایگزین کردن اعداد ۰/۱، ۰/۱۸، ۰/۲۵ و ۰/۳۵ بجای مقدار v_f ، می‌توان درصد جرمی فیبر سیلیسی را با توجه به رابطه (۵) تعیین نمود.

$$\%mass = \frac{m_f}{M} = \frac{m_f}{m_b + m_f} \quad (5)$$

منحنی دانه‌بندی فیلر طبق دستورالعمل ISO 13320 (Blott et al., 2004) انجام شده و در شکل (۱) نشان داده شده است. فیلرها به تدریج و در دمای ۱۶۰ درجه سانتیگراد به قیر پایه اضافه و به مدت ۴-۵ دقیقه مخلوط شده‌اند.



شکل ۱. دانه‌بندی فیلر سیلیسی


۲-۳- آزمایش جاروب فرکانس

پس از آماده‌سازی نمونه‌های قیر که شامل قیر پایه و قیرهای حاوی ۲، ۴ و ۶ درصد افزودنی می‌باشد، نمونه‌های ماستیک با ۱۰، ۱۸، ۲۵ و ۳۵ درصد پرشدگی فیلر ساخته شد. از دستگاه DSR (Anton-Paar 302) برای اندازه‌گیری مدول مرکب برشی (G^*) و زاویه فاز (δ) به عنوان دو ویژگی اصلی و مهم برای توصیف رفتار ویسکوالاستیک قیر پایه و اصلاح شده و همچنین نمونه‌های ماستیک استفاده شده است. آزمایش جاروب فرکانس در محدوده فرکانس ۰/۱ تا ۱۰۰ هرتز (۲۱ فرکانس) انجام شده است. در این مطالعه، آزمایش در هفت دمای ۲۲-، ۱۶-، ۱۰-، ۰، ۱۰، ۱۶ و ۲۲ درجه سانتیگراد انجام شده است. مطابق ASTM D7175 از نمونه‌هایی با قطر ۸ میلیمتر و فاصله ۲ میلیمتر بین صفحه‌های موازی استفاده شده است. همه نمونه‌ها روی صفحات DSR در دمای ۲۲ درجه سانتیگراد قرار گرفتند و سپس با سرد کردن آنها سایر دماهای آزمایش تأمین شده‌اند. لازم به ذکر است که دستگاه DSR مورد استفاده در این پژوهش قابلیت تأمین دماهای زیر صفر درجه سانتیگراد را با استفاده از سیستم کمپرسور تعبیه شده و محفظه کنترل دما دارا می‌باشد.


۳- برنامه‌ریزی ژنتیک چند ژنی

ایده اصلی الگوریتم ژنتیک توسط هالند در دهه ۱۹۷۰ میلادی بیان شد (Nasari et al., 2021). الگوریتم ژنتیک یک الگوریتم تکاملی است که مسائل پیچیده بهینه‌سازی را با الهام گرفتن از نظریه داروین حل می‌کند (Alkasawneh, 2007). برنامه‌ریزی ژنتیک یک ابزار پیش‌بینی قوی است که برای تعیین رابطه بین متغیرهای ورودی و خروجی مورد استفاده قرار می‌گیرد (Qi et al., 2019). در مرور ادبیات از الگوریتم ژنتیک و برنامه‌ریزی ژنتیک برای حل مسائل

مهندسی روسازی استفاده شده است (Elhadidy et al., 2020; Pattanaik et al., 2020). یکی از مهمترین تفاوت‌های الگوریتم ژنتیک و برنامه‌ریزی ژنتیک در نوع جمعیت آنها می‌باشد. همانطور که در شکل (۲) نشان داده شده است اعضای جمعیت در الگوریتم ژنتیک به صورت رشته‌ای از اعداد هستند اما در برنامه‌ریزی ژنتیک ساختاری درختی دارند (Goldberg & Holland, 1988; Koza & Koza, 1992). برنامه‌ریزی ژنتیک چندژنی از ترکیب چندین درخت برنامه‌ریزی ژنتیک و یک ترکیب خطی بین آنها تولید می‌شود. یک مدل شماتیک برنامه‌ریزی ژنتیک چند ژنی در شکل (۳) ارایه شده است. این مدل نمونه تلاش می‌کند متغیر خروجی y را بر اساس متغیرهای ورودی x_1, x_2, x_3, x_4 پیش‌بینی نماید. متغیر خروجی (y) یک بردار به اندازه $a \times 1$ می‌باشد و همچنین متغیرهای ورودی نیز یک ماتریس با ابعاد $a \times b$ هستند. در ابعاد بیان شده a تعداد داده‌های موجود و b تعداد متغیرهای ورودی می‌باشند. این مدل نمونه از پارامترهای غیرخطی مانند لگاریتم و تعدادی ضرایب ثابت (C_0, C_1, C_2 و C_3) استفاده نموده است تا فرم نهایی مدل شکل خطی بگیرد (Gandomi & Alavi, 2012). یک موضوع بسیار مهم در هنگام حل مسائل با استفاده از برنامه‌ریزی ژنتیک چندژنی ایجاد تعادل بین دقت و پیچیدگی مدل می‌باشد. با استفاده از دو پارامتر حداکثر تعداد ژن (G_{max}) و حداکثر عمق درختان (D_{max}) می‌توان میزان دقت و پیچیدگی مدل را تحت تاثیر قرار داد. برای دستیابی به یک مدل بهینه باید بین این دو پارامتر تعادل برقرار شود زیرا بین مقادیر این دو پارامتر و پیچیدگی رابطه مستقیمی وجود دارد (Ghafari et al., 2022).




(الف)



(ب)

شکل ۲. اعضای جمعیت در الف) الگوریتم ژنتیک و ب) برنامه‌ریزی ژنتیک



شکل ۳. نمونه مدل توسعه داده شده با برنامه‌ریزی ژنتیک چند ژنی

۴- توسعه مدل

(درجه) ماستیک و قیر است. P (%) درصد افزودنی SBS بر اساس جرم قیر پایه، VFR (%) درصد پرشدگی فیلر و در نهایت T(°C) و fr (Hz) بترتیب دمای آزمایش و فرکانس بارگذاری می‌باشند.

۴-۱- توصیف داده‌ها

داده‌های تولید شده در قسمت (۳-۲) برای توسعه مدل پیش‌بینی مورد استفاده قرار گرفته است. برای این منظور داده‌ها به دو قسمت تقسیم گردیدند. قسمت اول مربوط به متغیر خروجی زاویه فاز و قسمت دوم مربوط به مدول مرکب برشی می‌باشد. آماره توصیفی این دو دسته داده در جدول‌های (۳) و (۴) گزارش شده است.

هدف از این مطالعه توسعه مدل پیش‌بینی برای مدول مرکب برشی (G^*) و زاویه فاز (δ) ماستیک می‌باشد. بدین منظور متغیرهای ورودی مختلفی در نظر گرفته شده است. G^* و δ قیر پایه به عنوان متغیرهای ورودی که به طور قابل توجهی بر متغیرهای خروجی ماستیک تاثیرگذار هستند در نظر گرفته شده‌اند. همانطور که مشخص است رفتار مکانیکی ماستیک به دما و فرکانس آزمایش بستگی دارد که باید بعنوان متغیرهای ورودی در نظر گرفته شوند. همچنین قابل درک است که میزان افزودنی SBS و مقدار پرشدگی فیلر تاثیر قابل توجهی بر متغیرهای خروجی این مطالعه دارند. روابط ۶ و ۷ متغیرهای مستقل و وابسته این تحقیق را نشان می‌دهند.

$$G^* = f(G_0^*, P, VFR, T, fr) \quad (6)$$

$$\delta^* = f(\delta_0^*, P, VFR, T, fr) \quad (7)$$

که در آن G_0^* و δ_0^* به ترتیب مدول مرکب برشی ماستیک و قیر پایه بر حسب پاسکال می‌باشد. همچنین δ و δ_0 زاویه فاز

جدول ۳. آماره توصیفی متغیرهای مورد استفاده برای مدل G^*

متغیر	دامنه	کمینه	بیشینه	میانگین	انحراف معیار
G^* (Pa)	۱۳۴۳۸۹۶۳۴۹	۱۴۲۴۷۴/۷	۱۳۴۴۰۳۸۸۲۴	۲۳۸۷۳۴۳۴۴/۲	۲۷۸۲۱۲۱۸۳/۳
G_0^* (Pa)	۵۲۲۸۷۳۰۰۰	۱۲۷۰۰۰	۵۲۳۰۰۰۰۰۰	۱۳۲۹۴۹۶۲۵/۹	۱۴۶۱۳۱۳۷۰/۵
P (%)	۴	۲	۶	۴	۱/۶
VFR (%)	۲۵	۱۰	۳۵	۲۱/۹	۹/۱۵
T (°C)	۴۴	-۲۲	۲۲	۰	۱۵/۵
fr (Hz)	۹۹/۹	۰/۱	۱۰۰	۱۶/۳	۲۶/۳

جدول ۴. آماره توصیفی متغیرهای مورد استفاده برای مدل δ

متغیر	دامنه	کمینه	بیشینه	میانگین	انحراف معیار
G^* (Pa)	۶۷	۴/۶	۷۱/۶	۳۱/۸	۱۸/۱
G_0^* (Pa)	۶۴/۶	۹/۴	۷۴	۳۷	۱۸/۴
P (%)	۴	۲	۶	۴	۱/۶
VFR (%)	۲۵	۱۰	۳۵	۲۲	۹/۲
T (°C)	۴۴	-۲۲	۲۲	۰	۱۵/۵
fr (Hz)	۹۹/۹	۰/۱	۱۰۰	۱۶/۳	۲۶/۳

$$R^2 = \left(\frac{\sum_{i=1}^n (T_i - \bar{T})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (T_i - \bar{T})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (9)$$

$$MSE = \frac{\sum_{i=1}^n (T_i - P_i)^2}{n} \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (T_i - P_i)^2}{n}} \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n (|T_i - \bar{T}_i|) \quad (12)$$

که در آن T و \bar{T} بترتیب مقادیر اندازه‌گیری شده و مقدار متوسط داده‌های هدف می‌باشد. P مقدار پیش‌بینی شده، \bar{P} مقدار میانگین داده‌های پیش‌بینی شده توسط مدل و n تعداد داده‌های مورد بررسی می‌باشد.

۴-۳-مدلسازی با استفاده از برنامه‌ریزی ژنتیک چندژنی

هدف اصلی این مطالعه، ارزیابی مدل‌های پیش‌بینی برای خواص ویسکوالاستیک ماستیک اصلاح شده با SBS می‌باشد. برنامه‌ریزی ژنتیک چندژنی مانند سایر روش‌های یادگیری ماشین پارامترهایی دارد که باید تنظیم شود. پارامترهای اندازه جمعیت، تعداد تکرار، حداکثر تعداد ژن‌های مجاز در فرد و حداکثر عمق درخت از مهمترین مواردی هستند که در دقت و پیچیدگی مدل تاثیر زیادی دارند. یکی از روش‌های متداول برای تنظیم پارامتر برنامه‌ریزی ژنتیک چندژنی آزمون و خطا

از آنجایی که تابع هدف بسیاری از روش‌های یادگیری ماشین براساس فاصله اقلیدسی می‌باشد (Safak, 2020). بنابراین متغیرهای ورودی که مقادیر بزرگتری دارند از اهمیت بیشتری برخوردار خواهند بود. بعنوان نمونه تابع هدف برخی روش‌های یادگیری ماشین به متغیر G_0^* اهمیت بیشتری نسبت به متغیر P می‌دهد زیرا رنج اعداد آن‌ها بزرگتر است (طبق جدول ۳). برای پیش‌گیری از این موضوع متغیرهای ورودی و خروجی بین $0/1$ و $0/9$ با رابطه (۸) مقیاس شده‌اند (Nasari et al., 2020).

$$S_i = 0.1 + 0.8 \times \frac{O - O_{\min}}{O_{\max} - O_{\min}} \quad (8)$$

که در آن S_i مقدار مقیاس شده متغیر O ، مقدار واقعی متغیر، O_{\max} و O_{\min} به ترتیب مقادیر بیشینه و کمینه متغیر مورد بررسی می‌باشند. پس از مقیاس کردن، داده‌ها به دو قسمت تقسیم شده‌اند که عبارتند از: داده‌های آموزش (۸۰ درصد داده‌ها) برای آموزش مدل و داده‌های آزمایش (۲۰ درصد داده‌ها) برای اعتبارسنجی و آزمایش مدل می‌باشند.

۴-۲-ارزیابی مدل‌ها

پس از توسعه دو مدل پیش‌بینی G^* و δ میزان دقت و خطای آن‌ها با استفاده از شاخص‌های آماری مختلفی قابل محاسبه است. در این مطالعه از ضریب تعیین (R^2)، میانگین مربعات خطا (MSE)، مجذور میانگین مربعات خطا ($RMSE$) و میانگین قدرمطلق خطا (MAE) برای ارزیابی عملکرد مدل‌ها استفاده شده است که در معادلات ۹-۱۲ روابط آنها نشان داده شده‌اند.

آن G^* و G_0^* به ترتیب مدول مرکب برشی ماستیک و قیر پایه بر حسب پاسکال می‌باشد. همچنین δ و δ_0 زاویه فاز (درجه) ماستیک و قیر، P درصد افزودنی SBS، VFR درصد پرشدگی فیلر، $T(^{\circ}C)$ دمای آزمایش و f_r (Hz) فرکانس بارگذاری می‌باشد. برای استفاده از مدل‌های ارائه شده حتماً متغیرهای ورودی باید با استفاده از رابطه (۸) مقیاس شوند و در مدل‌ها قرار داده شوند. در نهایت نیز مقادیر متغیر خروجی بدست آمده باید از حالت مقیاس به کمک رابطه (۸) خارج شود.

اعتبارسنجی مدل‌ها

همانطور که قبلاً اشاره شد، ۸۰ درصد داده‌ها بعنوان داده‌های آموزش و ۲۰ درصد باقیمانده برای اعتبارسنجی مدل استفاده شده است. عملکرد دو مدل ارائه شده با استفاده از پارامترهای R^2 ، MSE، RMSE و MAE سنجیده شده است. این شاخص‌های آماری به تفکیک داده‌های آموزش و آزمایش محاسبه شده است و در جدول (۶) گزارش شده است. همانطور که قابل مشاهده است مقدار R^2 داده‌های آموزش و آزمایش در هر دو مدل بالا بوده و به عدد یک نزدیک است که نشان از عملکرد خوب مدل‌های ارائه شده از نظر دقت است. همچنین MSE، RMSE و MAE دو مدل توسعه داده شده نسبت به دامنه متغیر خروجی ناچیز است که نشان دهنده خطای پایین دو مدل G^* و δ ماستیک می‌باشد.

می‌باشد. در این مطالعه نیز از روش آزمون و خطا و مقادیر توصیه شده در مطالعات گذشته (Gandomi & Alavi, 2012) برای تنظیم پارامترهای مدل استفاده شده است. جدول (۵) مقادیر در نظر گرفته شده برای پارامترهای مختلف گزارش شده است. همانطور که در جدول (۵) نشان داده شده است، $36=3 \times 3 \times 2 \times 2$ ترکیب مختلف برای ساخت هر مدل وجود دارد. برای کسب اطمینان بیشتر، هر یک از این حالت‌ها دو بار اجرا شده است. به عبارت دیگر برای توسعه هر مدل پیش‌بینی ۷۲ بار الگوریتم برنامه‌ریزی ژنتیک در نرم‌افزار متلب (Matlab 2018a) اجرا شده است. یکی از مسائل مهم در مهندسی، دستیابی به مدل پیش‌بینی دقیق و در عین حال ساده می‌باشد. برای این منظور دو تابع هدف زیر برای انتخاب مدل بهینه از بین ۷۲ تکرار الگوریتم در نظر گرفته شده است.

– به منظور جلوگیری از معادلات طولانی و توابع تو در تو، پیچیدگی مدل کمینه شود.
– به منظور دستیابی به دقت بالا باید ضریب تعیین مدل توسعه داده شده بیشینه شود.

در نهایت، مدل‌های بهینه G^* و δ ماستیک با توجه به نکات بیان شده انتخاب گردید و در روابط ۱۳ و ۱۴ گزارش شده‌اند.

$$G^* = 0.44 \times G_0^* \times \exp(VFR^2) - 0.013 \times \exp(1.4VFR - P) + 0.065 \quad (13)$$

$$\delta = 0.81 \times \delta_0 + 0.22 \times T \times \exp(-P - VFR^2) + 0.015 \quad (14)$$

جدول ۵. تنظیم پارامتر برای برنامه‌ریزی ژنتیک چندزنی



پارامتر	مقادیر
اندازه جمعیت	۵۰۰، ۲۰۰، ۱۰۰
تعداد تکرار	۵۰۰، ۲۰۰، ۱۰۰
حداکثر تعداد ژن‌های مجاز در فرد	۴، ۲
حداکثر عمق درخت	۴، ۲
نوع توابع	Exp, $\sqrt{\quad}$, \times , $+$, $-$, $/$

جدول ۶. ارزیابی عملکرد مدل‌ها با استفاده از شاخص‌های آماری

MAE	RMSE	MSE	R ²	نوع داده	مدل
۳/۸E+۷	۵/۶E+۷	۳/۲E+۱۵	۰/۹۶	آموزش	G*
۴/۸E+۷	۶/۱E+۷	۳/۷E+۱۵	۰/۹۶	آزمایش	G*
۲	۲/۵	۶/۵	۰/۹۸	آموزش	δ
۲/۱	۲/۵	۶/۳	۰/۹۸	آزمایش	δ

اندازه‌گیری شده به مقدار زیادی نزدیک بوده‌اند و میزان خطا بسیار ناچیز است. در شکل (ب) نیز که مربوط به مدل G* می‌باشد، تقریباً داده‌ها به خط $y=x$ نزدیک هستند و مدل عملکرد خوبی دارد. در کل مدل δ نسبت به G* عملکرد بهتری داشته است و هر دو مدل به خوبی می‌توانند خصوصیات ویسکوالاستیک ماستیک اصلاح شده را پیش‌بینی کنند.

در شکل (۴) مقادیر اندازه‌گیری شده متغیر خروجی هر دو مدل را بر حسب مقادیر پیش‌بینی شده نشان داده است. هرچه این نقاط رسم شده به خط $y=x$ نزدیک‌تر باشد، به معنی اختلاف کمتر مقادیر اندازه‌گیری شده از آزمایش و مقادیر پیش‌بینی شده از مدل می‌باشد و بیانگر عملکرد خوب مدل می‌باشد. داده‌های آموزش و اعتبارسنجی به تفکیک در شکل (۳) نشان داده شده‌اند. همانطور که مشخص است، در شکل (الف) داده‌های آموزش و آزمایش مدل δ به داده‌های



شکل ۴. مقایسه مقادیر اندازه‌گیری شده و پیش‌بینی شده برای مدل (الف) δ (ب) G*

تحلیل حساسیت

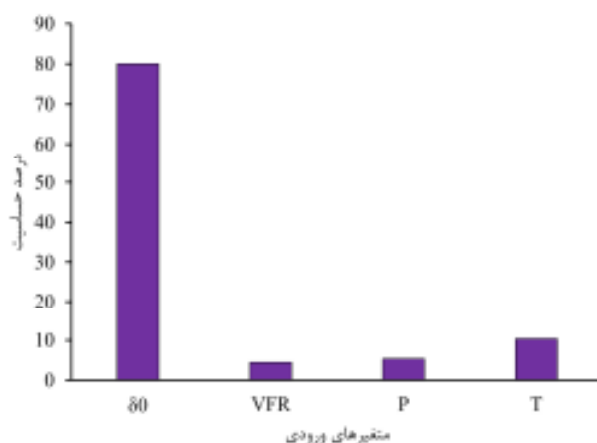
هستند. مجموع مقادیر S_i برابر ۱۰۰ می‌باشد و هرچه مقدار این پارامتر بزرگتر باشد، متغیر ورودی مربوطه برای پیش‌بینی متغیر خروجی حساس‌تر است. شکل (۵) حساسیت متغیرهای ورودی دو مدل ساخته شده برای پیش‌بینی متغیرهای خروجی را نشان می‌دهد. با توجه به شکل (۵) مشخص است که متغیرهای ویسکوالاستیک قیر پایه (G_0^* و δ_0) بیشترین حساسیت را برای پیش‌بینی متغیر خروجی داشته‌اند. در مدل δ_0 بترتیب دما، درصد افزودنی و درصد پرشدگی فیلر پس از δ_0 بیشترین حساسیت را داشته‌اند و نقش اساسی را در پیش‌بینی اختلاف فاز ماستیک اصلاح شده بازی می‌کنند. در مدل G^* نیز درصد پرشدگی فیلر حساس‌تر از درصد افزودنی می‌باشد.

به طور کلی، دقت مدل‌های پیشنهادی از نظر شاخص‌های آماری قابل قبول بوده است. میزان حساسیت متغیرهای ورودی هر یک از مدل‌ها بر اساس روابط ۱۵ و ۱۶ محاسبه شده‌اند (Gandomi et al., 2013).

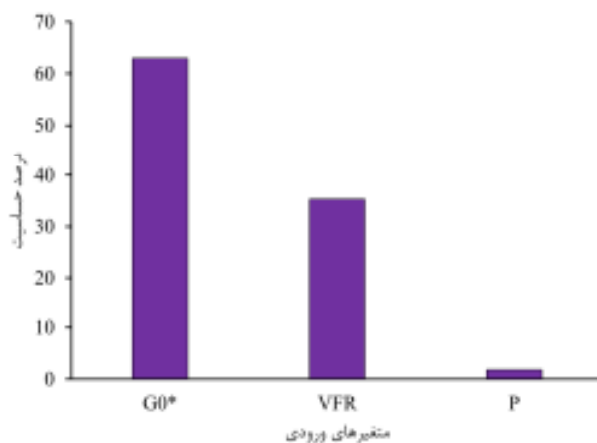
$$D_i = f_{\max}(v_i) - f_{\min}(v_i) \quad (15)$$

$$S_i = \frac{D_i}{\sum D} \times 100 \quad (16)$$

که در آن S_i حساسیت متغیر i ام، $f_{\max}(v_i)$ و $f_{\min}(v_i)$ به ترتیب حداکثر و حداقل مقدار متغیر خروجی برای متغیر i



(الف)



(ب)

شکل ۵. تحلیل حساسیت متغیرهای ورودی در مدل الف) δ ب) G^*

۵- نتیجه گیری

پایه، درصد پرشدگی فیلر و درصد افزودنی بترتیب بیشترین تاثیر را در پیش‌بینی مدول مرکب برشی ماستیک دارند. -در مدل پیش‌بینی زاویه فاز ماستیک متغیرهای ورودی زاویه فاز قیر پایه، دمای آزمایش، درصد افزودنی و درصد پرشدگی فیلر بترتیب بیشترین تاثیر را داشته‌اند.

۶- مراجع

- Aflaki, S., Hajikarimi, P., Fini, E. H., & Zada, B. (2014), "Comparing effects of biobinder with other asphalt modifiers on low-temperature characteristics of asphalt", *Journal of Materials in Civil Engineering*, 26(3), pp.429-439.
- Alkasawneh, W. M., (2007), "Backcalculation of pavement moduli using genetic algorithms University of Akron"]".
- Behnood, A., & Gharehveran, M. M., (2019), "Morphology, rheology, and physical properties of polymer-modified asphalt binders", *European Polymer Journal*, 112, pp.766-791.
- Behnood, A., & Olek, J., (2017), "Rheological properties of asphalt binders modified with styrene-butadiene-styrene (SBS), ground tire rubber (GTR), or polyphosphoric acid (PPA)", *Construction and Building Materials*, 151, pp.464-478.
- Blott, S. J., Croft, D. J., Pye, K., Saye, S. E., & Wilson, H. E., (2004), "Particle size analysis by laser diffraction", *Geological Society, London, Special Publications*, 232(1), pp.63-73.
- Brinson, H. F., & Brinson, L. C., (2008), "Polymer engineering science and viscoelasticity", *An introduction*.
- Chaudhary, M., Saboo, N., Gupta, A., Hofko, B., & Steineder, M., (2020), "Assessing the effect of fillers on LVE properties of asphalt mastics at intermediate temperatures", *Materials and Structures*, 53(4), pp.1-16.
- Di Benedetto, H., Olard, F., Sauzéat, C., & Delaporte, B., (2004), "Linear viscoelastic behaviour of bituminous materials: From binders to mixes", *Road Materials and Pavement Design*, 5(sup1), pp.163-202.
- Elhadidy, A. A., Elbeltagi, E. E., & El-Badawy, S. M., (2020), "Network-Based Optimization System for Pavement Maintenance Using a Probabilistic Simulation-Based Genetic Algorithm Approach", *Journal of Transportation Engineering, Part B: Pavements*, 146(4), 04020069.
- Gandomi, A. H., & Alavi, A. H., (2012), "A new multi-gene genetic programming approach to nonlinear system modeling", *Part I: materials and structural engineering problems. Neural Computing and Applications*, 21(1), pp.171-187.
- Gandomi, A. H., Yun, G. J., & Alavi, A. H., (2013), "An evolutionary approach for modeling of

تاکنون مدل پیش‌بینی که به صورت رابطه ریاضی ارائه شود و خصوصیات ویسکوالاستیک ماستیک را پیش‌بینی کند، توسط محققان مورد توجه قرار نگرفته است. در صورتیکه این موضوع از اهمیت بالایی برخوردار است و باعث کاهش هزینه، افزایش سرعت و جلوگیری از انجام آزمایش می‌شود. در این مطالعه از ابزار برنامه‌ریزی ژنتیک چندژنی برای توصیف رفتار ویسکوالاستیک ماستیک استفاده شده است. مدول مرکب برشی (G^*) و زاویه فاز (δ) به عنوان پارامترهای اصلی و نماینده رفتار ویسکوالاستیک ماستیک انتخاب گردیدند و متغیرهای خروجی در نظر گرفته شدند. از آزمایش جاروب فرکانس برای تعیین این دو پارامتر در ۲، ۴ و ۶ درصد SBS و در دماهای ۲۲-، ۱۶-، ۱۰-، ۰، ۱۰، ۱۶ و ۲۲ درجه سانتیگراد استفاده شده است. با استفاده از داده‌های تولید شده و تکنیک برنامه‌ریزی ژنتیک چندژنی دو مدل جداگانه برای مدول مرکب برشی (G^*) و زاویه فاز (δ) توسعه داده شد. با استفاده از چهار شاخص آماری R^2 ، MSE، RMSE و MAE میزان عملکرد مدل‌ها مورد ارزیابی قرار گرفت که مشخص شد میزان دقت مدل‌ها بالا و خطای آنها پایین می‌باشد. در انتها نیز بر روی دو مدل پیش‌بینی توسعه داده شده تحلیل حساسیت انجام گرفت. همچنین نتایج و نتیجه‌گیری‌های بیان شده در این تحقیق مربوط به قیر و فیلر معرفی شده در این مقاله است و تعمیم این نتایج به سایر قیرها، فیلرها و افزودنی‌ها مستلزم بررسی‌های بیشتر است. به طور کلی نتیجه‌گیری‌های زیر از این مطالعه حاصل شده است.

-مقدار R^2 و MSE برای مدل پیش‌بینی زاویه فاز ماستیک اصلاح شده با SBS برای داده‌های اعتبارسنجی بترتیب برابر ۰/۹۸ و ۶/۵ می‌باشد. همچنین این مقادیر برای مدل مدول مرکب برشی ۰/۹۶ و ۳/۲×۱۰۱۵ گزارش شده است. موارد بیان شده نشان از عملکرد خوب مدل‌های پیش‌بینی است.

-با استفاده از مدل‌های پیش‌بینی ارائه شده به راحتی خصوصیات ویسکوالاستیک ماستیک اصلاح شده را بدون انجام آزمایش، صرف هزینه و زمان با دقت مناسبی پیش‌بینی نمود.

-تحلیل حساسیت انجام شده روی مدل مدول مرکب برشی ماستیک اصلاح شده نشان می‌دهد که مدول مرکب برشی قیر

- Modarres, A., (2013), "Investigating the toughness and fatigue behavior of conventional and SBS modified asphalt mixes", *Construction and Building Materials*, 47, pp.218-222.
- Naseri, H., Ehsani, M., Golroo, A., & Moghadas Nejad, F., (2021), "Sustainable pavement maintenance and rehabilitation planning using differential evolutionary programming and coyote optimisation algorithm", *International Journal of Pavement Engineering*, pp.1-18.
- Naseri, H., Jahanbakhsh, H., Moghadas Nejad, F., & Golroo, A., (2020), "Developing a novel machine learning method to predict the compressive strength of fly ash concrete in different ages", *AUT Journal of Civil Engineering*, 4(4), pp.3-3.
- Nejad, F. M., Shahabi, M., Rahi, M., Hajikarimi, P., & Kazemifard, S., (2017), "An investigation on the effect of SBS+ vacuum bottoms residue modification on rheological characteristics of asphalt binder", *Petroleum Science and Technology*, 35(22), pp.2115-2120.
- Pattanaik, M. L., Choudhary, R., & Kumar, B., (2020), "Prediction of frictional characteristics of bituminous mixes using group method of data handling and multigene symbolic genetic programming", *Engineering with Computers*, 36(4), pp.1875-1888.
- Qi, C., Tang, X., Dong, X., Chen, Q., Fourie, A., & Liu, E., (2019), "Towards Intelligent Mining for Backfill: A genetic programming-based method for strength forecasting of cemented paste backfill", *Minerals Engineering*, 133, pp.69-79.
- Safak, V., (2020), "Min-Mid-Max Scaling, Limits of Agreement, and Agreement Score", *arXiv preprint arXiv:2006.12904*.
- Shafabakhsh, G., & Tanakizadeh, A., (2016), "Development of Asphalt Concrete Stiffness Modulus Prediction Models Using Genetic Programming".
- Tehrani, F. F., Absi, J., Allou, F., & Petit, C. (2013), "Heterogeneous numerical modeling of asphalt concrete through use of a biphasic approach: Porous matrix/inclusions", *Computational Materials Science*, 69, pp.186-196.
- Yildirim, Y., (2007), "Polymer modified asphalt binders", *Construction and Building Materials*, 21(1), pp.66-72.
- Yusoff, N. I. M., Shaw, M. T., & Airey, G. D., (2011), "Modelling the linear viscoelastic rheological properties of bituminous binders", *Construction and Building Materials*, 25(5), pp.2171-2189.
- shear strength of RC deep beams", *Materials and Structures*, 46(12), pp.2109-2119.
- Ghafari, S., Ehsani, M., & Nejad, F. M., (2022), "Prediction of low-temperature fracture resistance curves of unmodified and crumb rubber modified hot mix asphalt mixtures using a machine learning approach", *Construction and Building Materials*, 314, 125332.
- Goldberg, D. E., & Holland, J. H., (1988), "Genetic algorithms and machine learning".
- Hajikarimi, P., Fakhari Tehrani, F., Moghadas Nejad, F., Absi, J., Khodaii, A., Rahi, M., & Petit, C., (2019), "Mechanical behavior of polymer-modified bituminous mastics", II: numerical approach. *Journal of Materials in Civil Engineering*, 31(1), 04018338.
- Hajikarimi, P., Fakhari Tehrani, F., Moghadas Nejad, F., Absi, J., Rahi, M., Khodaii, A., & Petit, C., (2019), "Mechanical behavior of polymer-modified bituminous mastics. I: Experimental approach", *Journal of Materials in Civil Engineering*, 31(1), 04018337.
- Hajikarimi, P., & Nejad, F. M., (2021), "Applications of Viscoelasticity: Bituminous Materials Characterization and Modeling", Elsevier.
- Hosseini, A. S., Hajikarimi, P., Gandomi, M., Nejad, F. M., & Gandomi, A. H., (2021), "Genetic programming to formulate viscoelastic behavior of modified asphalt binder. *Construction and Building Materials*, 286, 122954.
- Kim, M., & Buttlar, W. G. (2010). Stiffening mechanisms of asphalt-aggregate mixtures: From binder to mixture", *Transportation Research Record*, 2181(1), pp.98-108.
- Koza, J. R., & Koza, J. R., (1992), "Genetic programming: on the programming of computers by means of natural selection (Vol. 1)", MIT press.
- Krishnan, J. M., & Rajagopal, K., (2005), "On the mechanical behavior of asphalt", *Mechanics of materials*, 37(11), pp.1085-1100.
- Majidifard, H., Jahangiri, B., Buttlar, W. G., & Alavi, A. H., (2019), "New machine learning-based prediction models for fracture energy of asphalt mixtures", *Measurement*, 135, pp.438-451.
- Majidifard, H., Jahangiri, B., Rath, P., Contreras, L. U., Buttlar, W. G., & Alavi, A. H., (2021), "Developing a prediction model for rutting depth of asphalt mixtures using gene expression programming", *Construction and Building Materials*, 267, 120543.

Development of Prediction Models for Complex Shear Modulus and Phase Angle of Asphalt Mastic Modified with Styrene-Butadiene-Styrene

Pouria Hajikarimi, Assistant Professor, Department of Civil & Environmental Engineering, Amirkabir University of Technology, Tehran, Iran.

Mehrdad Ehsani, Ph.D. Student, Department of Civil & Environmental Engineering, Amirkabir University of Technology, Tehran, Iran.

Mohammad Rahi, Director of Department of Research & Development, Pasargad Oil Company, Tehran, Iran.

Sahar Maniei, Supervisor of Department of Research & Development, Pasargad Oil Company, Tehran, Iran.

E-mail: phajikarimi@aut.ac.ir

Received: September 2022- Accepted: February 2023

ABSTRACT

Predicting the viscoelastic properties of asphalt mastic is very important in pavement engineering. Prediction of viscoelastic properties of mastic using machine learning methods resulting in closed form formulation is not considered in the technical literature up to now. This study aims to develop prediction models for complex shear modulus (G^*) and phase angle (δ) of modified asphalt mastic with Styrene-Butadiene-Styrene (SBS) at low and medium temperatures. Three different amounts of SBS (2, 4, and 6%) are considered for bitumen modification and four different volume filling rates (10, 18, 25, and 35%) are considered for making asphalt mastic samples. Dynamic Shear Rheometer (DSR) test was performed in frequency sweep mode at 21 loading frequencies from 0.1 to 100 Hz and seven temperatures of -22, -16, -10, 0, 10, 16, and 22 ° C. This test was used to measure the G^* and δ of samples of asphalt, modified asphalt, and asphalt mastic. Multi-gene genetic programming has been used to develop the G^* and δ asphalt mastic prediction model based on the additive's dosage, loading frequency, temperature, filler volume filling rate, G^* and δ of the base asphalt. Finally, two separate prediction models for G^* and δ are developed, with a R2 value of 0.96 and 0.98, respectively. The results show that multi-gene genetic programming can accurately predict the viscoelastic behavior of asphalt mastic. After examining the performance of the models, it was shown that the viscoelastic properties of the asphalt have the greatest impact on the prediction of output variables by performing sensitivity analysis on the prediction models.

Keywords: Multi-Gene Genetic Programming, Asphalt Mastic, Modified Bitumen, Viscoelastic, SBS