

# ارزیابی رفتار خودترمیم شونده‌ی مخلوط آسفالتی نیمه گرم به کمک سازوکار شکست و لحاظ ویژگی‌های القا با استفاده از شبکه‌های عصبی مصنوعی

اسراء عمرمحمد صالح<sup>۱</sup>، میثم عفتی<sup>۲\*</sup>، ماهرخ جلالی<sup>۳</sup> و سید محمد میر عبدالعظیمی<sup>۴</sup>

- ۱- دانشجوی کارشناسی ارشد، گروه مهندسی عمران (راه و ترابری)، دانشکده فنی، دانشگاه گیلان
- ۲- دانشیار، گروه مهندسی عمران (راه و ترابری)، دانشکده فنی، دانشگاه گیلان
- ۳- کارشناس ارشد، گروه مهندسی عمران (راه و ترابری)، دانشکده فنی، دانشگاه گیلان
- ۴- استادیار گروه مهندسی عمران (راه و ترابری)، دانشکده فنی، دانشگاه گیلان

Meysameffati@guilan.ac.ir

تاریخ پذیرش: ۱۴۰۲/۰۷/۲۷

تاریخ دریافت: ۱۴۰۲/۰۱/۱۶

## چکیده

بهبود عملکرد خودترمیمی آسفالت نیمه گرم به عوامل و پارامترهای متعددی وابسته است که به شدت وابسته به هم هستند و پیچیدگی قابل توجهی دارند. بنابراین، در این مطالعه عملکرد خودترمیمی مخلوط آسفالت نیمه گرم با استفاده از قابلیت‌های یادگیری و پیش‌بینی شبکه عصبی مصنوعی پرسپترون چندلایه و شعاعی پایه مورد بررسی قرار خواهد گرفت. برای انجام این مطالعه از دو افزودنی ساسوبیت و زایکوترم استفاده شده است. آزمون خمش سه نقطه در دو دمای ۲۵ و ۱۶- درجه سانتی‌گراد و با دو طول ترک ۱۰ و ۲۰ میلی‌متر انجام شد و شاخص‌های چقرمگی شکست، انرژی شکست و بار بحرانی برای هر کدام از حالت‌ها تعیین شد. نمونه‌های آسفالتی تحت گرمایش القایی در دو فرکانس ۸۸ و ۸۹ کیلوهرتز و سه زمان القا ۶۰، ۹۰ و ۱۲۰ ثانیه قرار گرفتند. متغیرهای ورودی به مدل هوشمند پیشنهادی تحقیق شامل چقرمگی شکست، انرژی شکست بعد از القا، نوع افزودنی، دمای آزمایش، زمان القا، انرژی شکست قبل از القا، طول ناچ، مساحت و فرکانس بود. نتایج تحلیل حساسیت در دو مدل شبکه عصبی مصنوعی نشان داد که در شبکه MLP پارامتر چقرمگی شکست بیشترین تأثیر را بر خروجی داشت. همچنین مشاهده شد که پارامتر دمای آزمایش بالاترین ضریب حساسیت را در شبکه RBF دارد. نتایج نشان داد که در شبکه عصبی پرسپترون با دو لایه در بخش آزمون مقادیر ریشه میانگین مربعات خطا (RMSE) از ۱۰/۴۶ در مدل اول به ۴/۲۷ در مدل چهارم خواهد رسید. همچنین نتایج شبکه عصبی مصنوعی شعاعی پایه نشان داد که اضافه شدن پارامترهای ورودی سبب کاهش مقدار ریشه میانگین مربعات خطا (RMSE) بخش آزمون از ۱۰/۵۶ به ۴/۳۵ شده است. نتایج تخمین شبکه MLP و RBF نشان داده است که افزودن متغیرهای ورودی به مدل باعث افزایش NS در هر سه بخش آزمون، آموزش و اعتبار سنجی شده است. به این ترتیب در شبکه MLP مقدار NS در قسمت آزمون از ۰/۴۵ به ۰/۹۰ رسیده و دقت تخمین دو برابر شده است. در شبکه RBF مشابه MLP، با اضافه شدن پارامتر NS، مقدار NS از ۰/۴۴ به ۰/۹۰ افزایش یافته است. همچنین، نتایج این مطالعه نشان داد که در هر دو نوع شبکه MLP و RBF، مقدار R<sup>2</sup> در گروه دوم در تمامی بخش‌های آزمون، آموزش و اعتبارسنجی بالاتر از گروه اول بود. به‌طور کلی نتایج حاصل از این مطالعه نشان داد که شبکه عصبی مصنوعی به دلیل ماهیت یادگیری و قابلیت آموزش از نتایج آزمایشگاهی پیشین در برآورد قابلیت خودترمیمی و مدل‌سازی ارتباط پیچیده متغیرهای تأثیرگذار ورودی دارای عملکرد و دقت مناسب می‌باشد و استفاده از مدل هوشمند پیشنهادی با کاهش تعداد آزمایش‌ها و هزینه می‌تواند در ارزیابی رفتار خودترمیم شونده‌ی مخلوط آسفالتی نیمه‌گرم مؤثر باشد.

**واژگان کلیدی:** خودترمیمی، ساسوبیت، زایکوترم، شبکه عصبی مصنوعی پرسپترون چند لایه، تابع شعاعی پایه

## ۱- مقدمه

فناوری‌هایی که در آن‌ها مخلوط‌های آسفالتی در دمایی نسبتاً کمتر از مخلوط‌های آسفالتی گرم (HMA)، تولید و اجرا می‌شوند به عنوان مخلوط‌های آسفالتی نیمه گرم (WMA) نامیده می‌شوند. در مخلوط آسفالتی نیمه گرم، نمونه‌های آسفالتی در محدوده دمایی ۱۰۰ تا ۱۳۵ درجه سانتی‌گراد امکان تولید و متراکم شدن را خواهند داشت که این کاهش دما باعث صرفه‌جویی چشمگیر اقتصادی و کاهش آلاینده‌های زیست‌محیطی می‌شود. کاهش دما در آسفالت نیمه گرم با استفاده از افزودنی‌هایی از جمله ساسوبیت، اووترم، زایکوترم و اسفامین ... انجام می‌شود [1]. ترک خوردگی روسازی یکی از بزرگ‌ترین مشکلات راه‌سازی محسوب می‌شود که سهم قابل توجهی از خرابی‌ها را به خود اختصاص داده است که در نهایت می‌تواند به فروپاشی روسازی منجر شود. وقتی بار به یک روسازی انعطاف‌پذیر اعمال می‌شود، در زیر لایه آسفالتی، تنش‌های کششی به وجود خواهد آمد که منجر به پیدایش ترک‌های ریز گشته که در صورت افزایش و تکرار بارگذاری بر تعداد آن‌ها افزوده شده و به تدریج با پیوستن آن‌ها به هم ترک‌های بزرگ‌تر شکل گرفته که در صورت ادامه این روند فروپاشی و گسیختگی روسازی رقم خواهد خورد [2]. بنابراین برای بررسی ترک خوردگی روسازی‌ها استفاده از روش مکانیک شکست پیشنهاد شده است [3]. مکانیک شکست علمی است که به بررسی انتشار ترک‌ها در مواد می‌پردازد [4]. در سال‌های اخیر با توجه به عوامل متعددی از جمله افزایش قیمت مصالح، ازدیاد بار ترافیکی، بالا رفتن فشار مجاز چرخ‌های وسایل نقلیه و کاهش عملیات ترمیم و نگهداری، استفاده از آسفالت‌های خودترمیم نظر پژوهشگران را به خود جلب کرده است. در حال حاضر، پژوهشگران عرصه علم مواد تلاش می‌کنند تا با افزودن اجزای خودترمیم به مخلوط‌های آسفالتی، عمر بهره‌برداری آن‌ها را بهبود بخشند. مصالح با قابلیت خودترمیمی می‌توانند به صورت ذاتی خرابی‌های ناشی از استفاده معمولی را بهبود دهند و سبب کاهش ناکارآمدی به وجود آمده در آسفالت شوند. همچنین، با افزایش عمر مخلوط‌های آسفالتی در طولانی مدت، هزینه‌های مربوط به

برخی از فرآیندهای تولید (به عنوان نمونه هزینه مربوط به سنگدانه و قیر جدید) کاهش می‌یابد و از هزینه‌های به وجود آمده توسط خرابی روسازی نیز جلوگیری می‌شود [5]. روش‌های مختلف خودترمیمی آسفالت گرمایش ماکروویو، گرمایش القایی، میکرو کپسول‌ها، پلیمر یونی و ... است. فرآیند گرمایش القایی با فرستادن جریان متناوب از طریق سیم پیچ و تولید میدان مغناطیسی متناوب به وجود می‌آید. زمانی که نمونه آسفالتی حاوی مواد رسانا زیر سیم پیچ قرار می‌گیرد انرژی حرارتی در جسم رسانا تولید می‌شود و سپس انرژی حرارتی باعث می‌شود دما در قیر افزایش یابد [6]. کارگری و همکاران [7] تأثیر کپسول‌های روغن پالم بر خواص خودترمیمی مخلوط‌های آسفالتی پیرشده و پیرنشده با گرمایش ماکروویو را مورد بررسی قرار دادند. در این تحقیق از روغن پالم به عنوان یک عامل جوانساز برای بررسی خواص خودترمیمی مخلوط‌های آسفالتی پیرشده و پیرنشده استفاده شده است. به منظور بررسی خواص خودترمیمی مخلوط‌های ساخته شده، از آزمایش خمش نیم‌دایره‌ای و ترمیم با اعمال گرمایش ماکروویو استفاده شد. نتایج نشان داد که استفاده از کپسول‌های روغن پالم به طور قابل توجهی قابلیت خودترمیمی مخلوط‌های آسفالتی پیرشده و پیرنشده را افزایش می‌دهد. بسیاری از عوامل، از جمله عوامل داخلی و خارجی، بر قابلیت خودترمیمی مخلوط‌های آسفالتی تأثیر می‌گذارند. عوامل داخلی بیشتر شامل ویژگی‌های فیزیکی، ترکیب شیمیایی آسفالت، ویژگی‌های حجمی مخلوط، مواد افزودنی در مخلوط‌ها و ... می‌باشد. عوامل خارجی شامل بارگذاری، محیط (دما، رطوبت)، خواص پیرشدگی آسفالت و ... است [5]. همان‌گونه که ملاحظه می‌شود بهبود عملکرد خودترمیمی در آسفالت به عوامل و پارامترهای متعددی وابسته است که به شدت وابسته به هم هستند و پیچیدگی قابل توجهی دارند و نقش ترکیبی در بهبود عملکرد آسفالت دارند. این امر باعث می‌شود که مدل‌سازی و پیش‌بینی اثر خودترمیمی آسفالت با استفاده از این مجموعه از پارامترها دشوار شود. همچنین ساخت نمونه و انجام آزمایش‌های مختلف، امری زمان‌بر بوده و از نظر اقتصادی نیز به صرفه نمی‌باشد. بر همین اساس، مدل‌های

هوشمند با قابلیت یادگیری از آزمایش‌های موجود و تحلیل روابط پیچیده بین متغیرهای ورودی شبکه‌های عصبی مصنوعی با قابلیت تخمین و پیش‌بینی داده‌ها با استفاده از نتایج آزمایش‌های پیشین، می‌تواند روشی کارا و مناسب به منظور تعیین عملکرد خودترمیمی آسفالت باشد [8]. مطابق با نظر عادل [8] شبکه‌های عصبی، مدلی مشاهداتی هستند که بر مبنای داده‌های موجود که ارائه‌دهنده نداشت بین متغیرهای ورودی و خروجی هستند، ایجاد می‌شود. مزیت اصلی شبکه‌های عصبی این است که در آن در نظر گرفتن صریح مدل که در روش‌های متداول امری ضروری به شمار می‌رفت، امروزه دیگر نیازی نیست. شبکه‌های عصبی یک ابزار قابل اعتماد را ارائه می‌دهند که می‌تواند مشکلات پیچیده را مدل و پیش‌بینی کند. این روش به طور کلی از دستگاه‌های محاسباتی الهام گرفته شده و از یادگیری بیولوژیکی در مغز انسان الگو گرفته و تشکیل شده است. شبکه عصبی مصنوعی توانایی یادگیری را دارد که می‌تواند تعاملات پیچیده بین متغیرهای مختلف را تحلیل نماید. سزاوار و همکاران [9] از شبکه‌های عصبی نوع GMDH برای مدل‌سازی و پیش‌بینی حساسیت رطوبتی بتن آسفالتی اصلاح‌شده با نانو سیلیس استفاده کردند. در این تحقیق، ۵ نوع مخلوط با درصد متفاوت نانو سیلیس (۰، ۰،۲، ۰،۴، ۰،۷، ۰،۹ و درصد) تهیه و حساسیت رطوبتی مخلوط‌های اصلاح‌شده مورد ارزیابی قرار گرفت. ورودی‌ها به دو دسته آموزش (حاوی حداقل ۷۰ درصد داده‌ها) و داده‌های آزمایشی (شامل حداکثر ۳۰ درصد داده‌ها) تقسیم شدند که منجر به خروجی چند ورودی-تک می‌شود. مقادیر پیش‌بینی شده با مقادیر تجربی به منظور تخمین عملکرد شبکه عصبی GMDH مقایسه شد. مقادیر مدل رگرسیون بسیار خوبی را با نتایج تجربی نشان دادند.

اوزترک و کیوتای [10] با استفاده از شبکه عصبی مصنوعی با سه لایه و متغیرهای ورودی درجه‌بندی مخلوط، وزن مخصوص سنگدانه‌ها، درجه عملکردی پایین و بالایی قیر، مقدار قیر و تعداد چرخش در دستگاه سوپریو ( $N_{ini}$ ,  $N_{des}$ )،  $N_{max}$ ) اقدام به طراحی مخلوط آسفالتی کردند. این پژوهشگران با استفاده از اطلاعات به دست آورده از جاده‌های

مختلف، ۱۸۱۷ طرح مختلف را توسط شبکه عصبی مصنوعی آموزش دادند. این پژوهشگران نشان دادند که استفاده از شبکه عصبی مصنوعی ابزار بسیار مفیدی برای طراحی مخلوط آسفالتی است که سبب کاهش زمان طراحی بین ۳ تا ۶ روز می‌شود. دومیتروویچ و همکاران [11] کاربرد شبکه عصبی مصنوعی در سیستم مدیریت روسازی را تحلیل و بررسی کردند. آن‌ها از شبکه عصبی مصنوعی back propagation به منظور ارزیابی وضعیت روسازی موجود و کاربرد احتمالی آن برای تعریف استراتژی نگهداری جاده‌های ملی استفاده کردند. نتایج به دست آمده از مطالعات آن‌ها نشان داد که از شبکه‌های عصبی مصنوعی می‌توان برای بهینه‌سازی استراتژی‌های نگهداری و ارزیابی وضعیت روسازی در سطح پروژه و شبکه استفاده کرد. بالندو و همکاران [12] از شبکه‌های عصبی مصنوعی برای پیش‌بینی رفتار مکانیکی بتن آسفالتی از نظر استحکام مارشال، روانی، ضریب مارشال و مدول سختی استفاده کرد. این پژوهشگران از هفت پارامتر ورودی با یک لایه پنهان و ده نرون برای پیش‌بینی یک خروجی استفاده کردند. نتایج آنها نشان داد که مدل شبکه‌های عصبی مصنوعی می‌تواند برای پیش‌بینی خواص مکانیکی بتن آسفالتی مورد استفاده قرار گیرد، به طوری که مدل‌های توسعه یافته با ضرایب همبستگی در محدوده ۰/۹۱۰ تا ۰/۹۸۸ بسیار خوب بودند. نگوین و همکاران [13] با استفاده هوش مصنوعی ترکیبی و الگوریتم ماشین بردار پشتیبان<sup>۱</sup> به بررسی پارامترهای مارشال مخلوط آسفالتی با استخوان‌بندی سنگدانه‌ای (SMA) پرداختند. این پژوهشگران نشان دادند که استفاده از هر دو ابزار برای تخمین مناسب هستند اما الگوریتم ماشین بردار پشتیبان دارای خطای کمتری بوده است. این پژوهشگران مقدار RMSE و  $R^2$  را به ترتیب در دامنه ۰/۷۲۱۳-۰/۳۴۲۹ و ۰/۹۲۶۶-۰/۸۱۸۱ به دست آوردند. کیه‌بادرودی و همکارانش [14] پژوهشی به منظور ارزیابی و پیش‌بینی پدیده خستگی در مخلوط‌های آسفالتی نیمه‌گرم اصلاح شده با نانو سیلیس و همچنین حاوی تراشه آسفالت بازیافتی انجام دادند. آن‌ها با استفاده از رفتار خودترمیمی مخلوط‌های آسفالتی، نتایج

شدند و استفاده از شبکه عصبی مصنوعی توانایی بالایی در پیش‌بینی این دو پارامتر دارد.

از آنجا که محافظت و بازسازی قیر موجود در روسازی، یک معضل بزرگ محسوب می‌شود، اقدام به طراحی اصولی به منظور کاهش استفاده از منابع خام و بهبود شرایط موجود ضروری است. این امر پژوهشگران را بر آن داشت که به مطالعه قابلیت خودترمیمی به روش گرمایش القایی در مخلوط‌های آسفالتی نیمه‌گرم بپردازند؛ اما با توجه به اینکه عوامل داخلی و خارجی فراوانی به‌طور همزمان بر عملکرد خودترمیمی مخلوط‌های آسفالتی تأثیر می‌گذارد، اتکا کردن به آزمایش‌های مختلف امری زمان‌بر بوده و از نظر اقتصادی به صرفه نخواهد بود. مدل‌های هوشمند با قابلیت یادگیری از نتایج آزمایش‌های موجود و تحلیل روابط پیچیده بین متغیرهای ورودی با قابلیت تخمین و پیش‌بینی می‌تواند روشی کارا و مناسب به منظور تعیین عملکرد خودترمیمی آسفالت باشد. بنابراین هدف از انجام این مطالعه بررسی عملکرد دو مدل مبتنی بر یادگیری هوش مصنوعی (شبکه عصبی مصنوعی پرسپترون چند لایه  $^{(8)}$  MLP) و تابع شعاعی پایه  $^{(9)}$  RBF) به منظور تخمین قابلیت خودترمیمی می‌باشد. از اهداف دیگر تحقیق می‌توان به بررسی تغییر متغیرهای ورودی بر دقت هر کدام از مدل‌های پیشنهادی اشاره نمود. در ادامه در بخش روش تحقیق آزمایش‌های انجام شده، انواع شبکه‌های عصبی مصنوعی مختلف بر تخمین قابلیت خودترمیمی و معیارهای ارزیابی آنها بررسی خواهد شد.

## ۲- روش تحقیق

### ۲-۱- مصالح مورد استفاده

دانه‌بندی مصالح سنگی مطابق با حد وسط دانه‌بندی شماره ۴ نشریه شماره ۲۳۴ سازمان برنامه و بودجه کشور برای آستر و رویه است [17]. جنس مصالح سنگی مورد استفاده سیلیسی می‌باشد. فیلر مورد استفاده برای ساخت نمونه‌ها، متشکل از پودر آهن به مقدار یک سوم فیلر و کربن فعال به مقدار ۱۰ درصد فیلر و پودر سیمان مطابق شکل (۱) می‌باشد.

آزمایشگاهی را از طریق شبکه عصبی مصنوعی مدل‌سازی کردند. نتایج تحقیق آن‌ها نشان داد که افزودن نانوسیلیس می‌تواند بر سطح خودترمیمی مخلوط‌های آسفالتی نیمه‌گرم تأثیر بگذارد. همچنین استفاده از شبکه عصبی مصنوعی به منظور پیش‌بینی رفتار نمونه‌های آسفالتی نیمه‌گرم شامل مقادیر مختلف نانو مواد، نتایج قابل قبولی ارائه می‌دهد به طوری که مقایسه آن‌ها با نتایج آزمایشگاهی دقت بالای مدل را در سطح ۹۵ درصد را نشان داد. میرعبدالعظیمی و همکاران [15] به پیش‌بینی عمق شیارشدگی مخلوط‌های گرم اصلاح‌شده با الیاف فورتا با استفاده از شبکه‌های عصبی مصنوعی و تکنیک برنامه‌نویسی ژنتیکی پرداخته است. برای ارزیابی عملکرد شیارشدگی نمونه‌های آسفالتی آزمایش خزش دینامیکی تحت دماهای ۴۰، ۵۰ و ۶۰ درجه سانتی‌گراد و تنش‌های ۱۵۰، ۲۵۰ و ۳۵۰ کیلوپاسکال انجام شد. نتایج نشان داد مدل شبکه‌های عصبی مصنوعی برای عمق شیارشدگی هماهنگی خوبی با نتایج تجربی دارد. علاوه بر این، مدل برنامه‌نویسی ژنتیکی نسبت به مدل برگر خطای کمتری در پیش‌بینی عمق شیارشدگی مخلوط آسفالتی گرم از خود نشان می‌دهد. حمید و همکاران [16] از شبکه عصبی مصنوعی برای تخمین رفتار بازبازی<sup>۲</sup> و انطباق غیرقابل‌بازبازی<sup>۳</sup> استفاده کردند. این پژوهشگران از افزودنی‌های مختلفی مانند پودر شیشه، خاکستر بادی<sup>۴</sup>، خاکسترهای بر پایه ژئوپلیمر و استایرن- بوتادین- استایرن<sup>۵</sup> استفاده کردند. آن‌ها یک پایگاه داده تجربی جامع متشکل از نتایج بررسی فرکانس و آزمایش بازگشت خزشی در چند سطح تنش  $^{(1)}$  MSCR با استفاده از رئومتر برشی دینامیکی  $^{(7)}$  DSR در پنج دمای آزمایش (۴۶، ۵۲، ۵۸، ۶۴ و ۷۰ درجه سانتی‌گراد) ایجاد کردند. متغیرهای ورودی این پژوهشگران برخی از ویژگی‌های رئولوژیکی و مکانیکی قیر بود. نتایج نشان داد که پارامتر بازبازی و هماهنگی غیرقابل‌بازبازی با  $R^2$  خوبی تخمین زده

- 2 Recovery
- 3 Nonrecoverable compliance
- 4 Fly ash
- 5 Styrene-butadiene styrene
- 6 Multiple Stress Creep Recovery
- 7 Dynamic Shear Rheometer

در این مطالعه از دو ماده افزودنی زایکوترم و ساسوبیت در جدول (۱) مشخصات ساسوبیت و زایکوترم مورد استفاده نشان داده شده است.

### ۲-۲-۲ قیر

انتخاب نوع قیر مصرفی به عوامل زیادی از جمله میزان ترافیک، شرایط جوی منطقه، جنس مصالح روسازی، نوع روسازی و ... وابسته می‌باشد. در این تحقیق برای ساخت نمونه‌های آسفالتی از قیر با درجه نفوذ ۶۰-۷۰ مربوط به پالایشگاه نفت جی اصفهان استفاده شده است. مشخصات قیر مصرفی در جدول (۲) قابل مشاهده است.

جدول ۲. مشخصات قیر

Type of test	Unit	Test result	Test Method
Density at 25°C	kg/m <sup>3</sup>	1018	ASTM D3289
Penetration grade at 25°C	0.1mm	66	ASTM D5
Softening point	°C	50.4	ASTM D36
Flash point	°C	316	ASTM D92
Ductility at 25°C	cm	140	ASTM D113

Table 2. Bitumen Specifications

شکل ۱. مواد استفاده شده در این تحقیق



Fig. 1. Materials used in this research

جدول ۱. مشخصات زایکوترم و ساسوبیت

Property	Sasobit	Zycotherm
Components	Polyethylene hydrocarbon	Liquid Sulfamide
Physical state	Alphanic	Liquid
Color	Pastille and Prill	Dark
Odor	Odorless	Odorless
Bulk density (Kg/m <sup>3</sup> )	590-622	900
Solubility in water	Unsolvable	Unsolvable
Consumption amount	1-3 percent bitumen	0.2-0.4 percent of new bitumen

Table 1. Characteristics of zycotherm and sasobit

شکل ۲. برنامه آزمایشگاهی و مشخصات متغیرها




Fig. 2. Laboratory program and specification of variables



جدول ۳. مشخصات مخلوط آسفالتی ساخته شده

Specifications	warm mix asphalt with sasobit additive	warm mix asphalt with zycotherm additive
aggregate	siliceous	siliceous
Filler	Iron powder, Activated carbon, cement	Iron powder Activated carbon, cement
Optimum bitumen (%)	5/5	5/8
Additive content (%)	3	0.1
Mixing temperature (°C)	135	120
Compaction temperature (°C)	110	100

Table 3. Specifications of the manufactured asphalt mixture

شکل ۳. نمونه‌های ساخته شده و نیم دایره‌ای



Fig 3. Made and semi-circular samples

## ۲-۵- آزمایش خمش سه نقطه‌ای

در این مرحله نمونه‌های نیم دایره‌ای ترک‌دار تهیه شده در مرحله قبل تحت آزمایش خمش سه نقطه‌ای در دو دمای مختلف ۱۶- و ۲۵ درجه سانتی‌گراد و با دو طول ترک ۱۰ و ۲۰ میلی‌متر و با عرض ترک ۳ میلی‌متری قرار گرفتند. برای انجام آزمایش خمش سه نقطه‌ای و تعیین منحنی نیرو-جابجایی از دستگاه خمش سه نقطه‌ای موجود در آزمایشگاه دانشگاه گیلان استفاده شد. بارگذاری نمونه‌ها به شکلی انجام شد که بار در مرکز نمونه‌ها و دقیقاً در بالای ترک مصنوعی موجود در نمونه‌ها اعمال شد. برای انجام آزمایش ابتدا نمونه‌های آسفالتی در دمای ۱۶-، به مدت ۴ ساعت قرار گرفته تا دمای همه قسمت‌های نمونه به این دما برسند. هدف از ایجاد این کار جلوگیری از تغییر شکل خزشی زیاد و ایجاد شکست ترد و یکنواخت در سطح نمونه‌ها بود. سپس نمونه‌ها بلافاصله در دستگاه خمش سه نقطه‌ای مطابق شکل (۴) قرار داده شد و

## ۲-۳- برنامه آزمایشگاهی

در شکل (۲) برنامه آزمایشگاهی و مشخصات متغیرهای این تحقیق ارائه شده است. از آزمایش خمش سه نقطه‌ای برای تعیین خواص خودترمیمی دو نوع مخلوط آسفالتی نیمه گرم استفاده شد. برای ترک‌های خستگی، دمای ۲۵ و برای ترک‌های دما پایین، دمای ۱۶- در نظر گرفته شده است. ۲ ناچ با طول‌های متفاوت در نظر گرفته شد تا تأثیر طول ناچ بر خودترمیمی بررسی شود. فرکانس‌های ۸۸ و ۸۹ کیلوهرتز با توجه به محدوده تغییرات فرکانس دستگاه گرمایش القایی و تأثیر فرکانس بر خودترمیمی انتخاب شد. زمان القا براساس مطالعات پیشین انتخاب شد و همچنین زمان القای منتخب در محدوده‌ای باشد که قیر نرم شود و ترمیم صورت بگیرد.

## ۲-۴- ساخت نمونه‌های آسفالتی

برای ساخت مخلوط‌های آسفالتی نیمه گرم، مصالح سنگی به مدت ۱۶ ساعت در دمای ۱۳۵ درجه سانتی‌گراد در آون گرم شد. برای اختلاط قیر و افزودنی‌ها، افزودنی ساسوبیت به قیر با دمای ۱۳۰ درجه سانتی‌گراد اضافه شد و با تعداد دوران ۱۲۰۰ دور بر دقیقه به مدت ۲۰ دقیقه مخلوط شد.

دستورالعمل شرکت سازنده زایکوترم قطره قطره به قیر مذاب اضافه شد و هم‌زدن قیر و زایکوترم به مدت ۱۰ دقیقه پس از اضافه کردن آخرین قطره زایکوترم ادامه داشت. به منظور ساخت دو نوع مخلوط آسفالتی نیمه گرم، مصالح سنگی و قیر بهینه حاوی افزودنی ساسوبیت و زایکوترم و فیلر مخلوط شدند. سپس، مخلوط آماده شده در داخل استوانه‌هایی با قطر استاندارد ۱۰ سانتی‌متر و ارتفاع ۶/۲۵ سانتی‌متر قرار گرفت و قالب استوانه‌ای در دستگاه چکش مارشال قرار گرفت. به منظور تراکم و طراحی برای شرایط ترافیک سنگین، به هر طرف نمونه ۷۵ ضربه اعمال شد در جدول ۳ مشخصات مخلوط آسفالتی ساخته شده ارائه شده است. همچنین در شکل (۳) نمایی از نمونه‌های ساخته شده و نمونه‌های نیم دایره‌ای مشاهده می‌شود.

شدند، بعد از ترمیم با دستگاه گرمایش القایی، تحت آزمایش خمش نیم‌دایره‌ای دچار شکست ثانویه شدند. نسبت بار بحرانی ثانویه به بار بحرانی اولیه، میزان خودترمیمی مخلوط‌های آسفالتی را نشان می‌دهد.

بار بحرانی که با  $F_{Cr}$  نشان داده می‌شود، حداکثر باری است که یک نمونه می‌تواند تحمل کند. نسبت خودترمیمی برحسب بار بحرانی از معادله ۱ به دست آمد [5]:

$$(1) \quad \text{درصد خودترمیمی} = \frac{\text{بار بحرانی بعد از القا}}{\text{بار بحرانی قبل از القا}} \times 100$$

## ۲-۸- درصد خودترمیمی برحسب انرژی شکست

نرخ آزادسازی انرژی بحرانی که با  $G_f$  نشان داده می‌شود، انرژی خارجی مورد نیاز برای رشد ترک را نشان می‌دهد که با در نظر گرفتن مساحت زیر منحنی نیرو - جابه‌جایی محاسبه می‌شود. با استفاده از نسبت مقدار کار انجام‌شده بر مساحت لیگامنت نمونه، مقدار انرژی شکست محاسبه می‌شود (معادله ۲).

$$(2) \quad G_f = \frac{W_f}{A_{lig}} \times 10^6$$

که در آن  $G_f$  انرژی شکست برحسب ژول بر مترمربع،  $W_f$  میزان کار انجام شده برحسب ژول و  $A_{lig}$  مساحت لیگامنت و برحسب میلی‌مترمربع است.

به منظور دستیابی به درصد خودترمیمی مخلوط‌های آسفالتی، انرژی شکست قبل و بعد از القا را محاسبه کرده و با استفاده از معادله ۳ مقدار خودترمیمی محاسبه شد [19].

$$(3) \quad \text{درصد خودترمیمی} = \frac{\text{انرژی شکست بعد از القا}}{\text{انرژی شکست قبل از القا}} \times 100$$

## ۲-۹- چقرمگی شکست

چقرمگی شکست به عنوان معیار مقاومت در برابر شکست مخلوط‌های آسفالتی تعریف می‌شود. این پارامتر با استفاده از معادله (۴) برای نمونه‌هایی با عمق بریدگی ۱۰ و ۲۰ میلی‌متری

بارگذاری روی نمونه‌ها با سرعت ثابت  $20 \text{ mm/min}$  تا لحظه شکست انجام گرفت.

شکل ۴. دستگاه خمش سه نقطه‌ای




Fig 4. Three point bending machine

## ۲-۶- ترمیم نمونه‌های گسیخته شده به وسیله گرمایش

### القایی

نمونه‌های گسیخته شده پس از خارج شدن از دستگاه خمش سه نقطه‌ای با استفاده از نوار چسب در کنار هم بدون هیچ نیرویی قرار گرفتند. در مرحله بعد نمونه‌ها تحت گرمایش القایی با دو فرکانس ۸۸ و ۸۹ کیلوهرتز و سه زمان مختلف ۶۰، ۹۰ و ۱۲۰ ثانیه مطابق شکل (۵) قرار گرفتند. مطالعات نشان داده است که عوامل مختلفی بر سرعت گرمادهی تأثیرگذار است به طوری که فاصله بین سیم پیچ و سطح نمونه تأثیر قابل-توجهی بر میزان سرعت گرمادهی می‌گذارد [18].

شکل ۵. دستگاه گرمایش القایی



Fig 5. Induction heating device

## ۲-۷- درصد خودترمیمی برحسب بار بحرانی

به منظور محاسبه خودترمیمی مخلوط‌های آسفالتی، ابتدا نمونه‌ها با استفاده از خمش نیم‌دایره‌ای دچار شکست اولیه

## ۲-۱۰- مشخصات آماری متغیرهای ورودی

در جدول (۴) مشخصات پارامترهای مورد آزمایش دو نوع مخلوط آسفالتی نیمه گرم آمده است. در جدول (۵) مشخصات آماری چهار پارامتر چقرمگی شکست، انرژی شکست قبل از القا، انرژی شکست بعد از القا و قابلیت خودترمیمی در دو نوع آسفالت نمایش داده شده است. جدول (۶) مشخصات هشت نمونه از کل نمونه‌های مورد بررسی در دو افزودنی ساسوبیت و زایکوثرم نمایش داده شده است.

که در دمای ۲۵ و ۱۶- درجه سانتی گراد آزمایش شده بودند. محاسبه شد.

$$K_{IC} = \frac{F_{cr}}{2Rt} Y_{IV} \sqrt{\pi a} \quad (۴)$$

که در آن  $F_{cr}$  بار بحرانی برحسب (kN) است.  $R$  و  $t$  به ترتیب شعاع و ضخامت نمونه (m)،  $a$  عمق بریدگی (m) و  $Y$  ضریب شکل است که برای نمونه‌های مختلف SCB با استفاده از تحلیل اجزا محدود توسط آیت‌اللهی و علیها تعیین شد [20].

جدول ۴. مشخصات پارامترهای مورد بررسی در دو نوع آسفالت حاوی ساسوبیت و زایکوثرم

Treatment	Additive %	Optimum bitumen %	Average area (mm <sup>2</sup> )	Notch length (mm)	Test temperature (°C)	Frequency (kHz)	Induction time (s)
Asphalt / Sasobite	3	5.5	1079.17	10 and 20	-16 and 25	88 and 89	60, 90 and 120
Asphalt / Zycotherm	0.1	5.8	1078.64	10 and 20	-16 and 25	88 and 89	60, 90 and 120

Table 4. Characteristics of the investigated parameters in two cases of asphalt containing sasobite and zycotherm

جدول ۵. مشخصات آماری پارامترهای مورد بررسی در دو آسفالت مورد مطالعه

Treatment	Parameter	Unit	MIN	Mean	MAX	STD
Asphalt / Sasobite	Fracture toughness	MPa m <sup>1/2</sup>	0.05	0.23	0.65	0.17
	Fracture energy before induction	J/m <sup>2</sup>	4.27	140.75	779.14	159.49
	Fracture energy after induction	J/m <sup>2</sup>	4.59	40.32	102.08	27.93
	HI	%	5.00	32.52	75.00	19.53
Asphalt / Zycotherm	Fracture toughness	MPa m <sup>1/2</sup>	0.08	0.14	0.19	0.03
	Fracture energy before induction	J/m <sup>2</sup>	15.34	187.83	470.99	135.60
	Fracture energy after induction	J/m <sup>2</sup>	5.14	33.29	132.47	36.41
	HI	%	12.50	27.52	60.00	14.24

Table 5. Statistical characteristics of the investigated parameters in the two studied asphalts

جدول ۶. مشخصات برخی از نمونه‌های مورد مطالعه

No.	Treatment	Additive %	Notch length (mm)	Test temperature (°C)	Frequency (kHz)	Induction time (s)	Loading speed	Distance of coil from sample (mm)
1	Sasobite	3	10	25	89	60	20	10
2	Sasobite	3	20	25	89	90	20	10
3	Sasobite	3	10	-16	88	120	20	10
4	Sasobite	3	20	-16	88	120	20	10
5	Zycotherm	0.1	10	25	89	60	20	10
6	Zycotherm	0.1	20	25	89	90	20	10
7	Zycotherm	0.1	10	-16	88	120	20	10
8	Zycotherm	0.1	20	-16	88	120	20	10

Table 6. Characteristics of some studied sample



## ۱۱-۲- شبکه عصبی مصنوعی

استاندارد شدند. خروجی مدل ساخته شده، قابلیت خودترمیمی مخلوط آسفالتی نیمه گرم خواهد بود.

جدول ۷. گروه‌های مختلف متغیرهای ورودی در دو روش شبکه عصبی مصنوعی

Model	Input variables
First group	additive type + fracture toughness + fracture energy before induction
Second group	First model + fracture energy after induction + length + frequency + induction time + temperature + area

Table 7. Different groups of input variables in two artificial neural network methods

## ۱۲-۲- معیارهای ارزیابی دقت و قابلیت اعتماد مدل

برای بررسی دقت و قابلیت اعتماد مدل‌های ساخته شده از معیارهای زیر بهره‌گیری شد [21].

$$R^2 = \frac{n(\sum(HI_{obs} \cdot HI_{model})) - (\sum HI_{obs})(\sum HI_{model})}{\sqrt{[n \sum HI_{obs}^2 - (\sum HI_{obs})^2][n \sum HI_{model}^2 - (\sum HI_{model})^2]}} \quad (5)$$

$$ME = \frac{\sum(HI_{obs} - HI_{model})}{N} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum(HI_{obs} - HI_{model})^2}{N}} \quad (7)$$

$$NS = 1 - \frac{\sum_{i=1}^n (HI_{obs} - HI_{model})^2}{\sum_{i=1}^n (HI_{obs} - HI_{mean})^2} \quad (8)$$

$R^2$ : ضریب تعیین؛  $RMSE$ <sup>۱۴</sup>: مجذور میانگین مربعات خطا؛  $ME$ : میانگین خطا؛  $NS$ <sup>۱۵</sup>: ضریب کارایی نش ساتکلیف  $HI_{obs}$ ،  $HI_{mean}$  و  $HI_{model}$  به ترتیب قابلیت خودترمیمی متوسط اندازه‌گیری‌ها، اندازه‌گیری و تخمینی و  $N$  تعداد نقاط اندازه‌گیری هستند برای اجرای شبکه عصبی مصنوعی و تحلیل حساسیت از نرم افزار Statistica 13 استفاده شد. همچنین برای رسم نمودارها از نرم افزار Excel 2016 و برای انجام مقایسه میانگین‌ها در سطح پنج درصد از نرم افزار SPSS 22 استفاده شد.

برای مدل‌سازی شبکه عصبی مصنوعی از دو روش MLP و RBF استفاده شد. لایه ورودی ۹ نرون دارد و لایه خروجی دارای ۱ نرون است و تعداد لایه میانی دو عدد در نظر گرفته شد. در شبکه RBF، عدد گسترش<sup>۱۱</sup> برابر با یک در نظر گرفته شد. برای مدل‌سازی به صورت تصادفی ۷۰ درصد داده‌ها در بخش آموزش<sup>۱۱</sup>، ۱۵ درصد در بخش آزمون<sup>۱۲</sup> و ۱۵ درصد نیز در بخش اعتبارسنجی<sup>۱۳</sup> مورد استفاده قرار گرفتند. تعداد لایه در خروجی برابر یک در نظر گرفته شد. برای بهینه کردن تعداد لایه‌های مخفی نیز مدل در لایه‌های مختلف (از ۱ تا ۵) در نظر گرفته شد، با توجه به قابلیت نرم‌افزار Statistica می‌توان حالت بهینه لایه‌های مخفی را انتخاب کرد. در هر دو مدل شبکه عصبی مصنوعی تعداد نرون‌ها معادل ۱۰ در نظر گرفته شد. تابع انتقال در هر دو مدل (با توجه به نتایج دقیق‌تر) تانژانت هائپربولیک در نظر گرفته شد. روش آموزش هر دو مدل شبکه عصبی مصنوعی ساخته شده، از نوع لونیبرگ-مارکواردت می‌باشد. همچنین برای بررسی بازدهی شبکه از خطای مربع میانگین استفاده شده است. تابع هدف در این الگوریتم، مقدار خطای مربع میانگین است و هدف، کمینه‌سازی این مقدار است.

با توجه به رفتار پیچیده مواد روسازی آسفالت در شرایط بارگیری مختلف، ساختار روسازی و شرایط محیطی، پیش‌بینی دقیق تغییر شکل دائمی روسازی آسفالت دشوار است. دو مدل شبکه عصبی مصنوعی با استفاده از نه پارامتر ورودی مختلف ایجاد شد. این نه پارامتر در الگوهای مختلف به عنوان ورودی به مدل در نظر گرفته شدند (جدول ۷). این نه پارامتر در دو گروه مختلف تقسیم شدند تا اثر تغییر پارامترها نیز مشاهده شود. قبل از اجرای شبکه در ابتدا به بررسی داده‌های پرت پرداخته شد که هیچ داده‌ای در این مرحله حذف نشد. برای اجرای شبکه عصبی مصنوعی ابتدا داده‌ها نرمال و سپس

10 Number Spread

11 Train

12 Test

13 Validation

14 Root Mean Square Error

15 Nash Sutcliffe

جدول ۸. داده‌های آزمایشگاهی استفاده شده در این مدل

Row	additive	Notch length (mm)	Test temperature (°C)	Frequency (KHz)	Induction time (s)	Fracture energy before induction (J/m <sup>2</sup> )	Fracture energy after induction (J/m <sup>2</sup> )	fracture toughness (Mpa.m <sup>0.5</sup> )
1	sasobit	10	25	88	60	119.793	16.800	0.113
2	sasobit	10	25	88	90	76.940	32.724	0.099
3	sasobit	10	-16	88	120	132.95	59.341	0.286
4	sasobit	10	-16	89	60	479.538	63.147	0.646
5	sasobit	10	25	89	90	271.726	65.740	0.132
6	sasobit	20	25	88	90	21.017	7.755	0.076
7	sasobit	20	25	89	120	14.401	12.371	0.101
8	sasobit	20	-16	88	60	117.941	10.634	0.460
9	sasobit	20	-16	89	90	119.625	31.652	0.357
10	sasobit	20	-16	88	120	46.327	13.834	0.388

Table 8. Experimental data used in the model

### ۳- نتایج و بحث

#### ۳-۱- بانک داده‌های آزمایشگاهی

بخشی از نتایج آزمایشگاهی در جدول (۸) ارائه شده است.

#### ۳-۲- مشخصات آماری شبکه MLP

در جدول (۹) مشخصات آماری دقت پیش‌بینی شاخص خودترمیمی در مدل‌های مختلف شبکه MLP نمایش داده شده است. همان‌گونه که در جدول (۹) مشخص است نتایج سه بخش آموزش، آزمون و اعتبارسنجی نزدیک به هم بوده و یادگیری شبکه طراحی شده نسبتاً پایدار بوده است. برای بررسی دقت و درستی مدل‌های طراحی شده از چهار آماره  $R^2$ ، ME، RMSE و NS استفاده شده است که هر کدام از این آماره‌های دارای مفهوم ویژه و کاربرد متفاوتی دارند. آماره  $R^2$  نشان‌دهنده میزان هم‌راستایی اطلاعات تخمین زده شده و اندازه‌گیری شده را نشان می‌دهد، اما با استفاده از این آماره به وضوح نمی‌توان به میزان خطای رخ داده در مدل پی برد؛ بنابراین برای تعیین و تشخیص دقت میزان خطا از دیگر آماره استفاده شده است. از آماره ME برای تعیین کم تخمینی و بیش تخمینی مدل استفاده می‌شود، به این صورت که اگر مقادیر ME مثبت باشد نشان‌دهنده بیش تخمینی در مدل بوده است و بالعکس اگر مقادیر ME منفی باشد نشان کم تخمینی در مدل بوده است که بسته به اندازه ME این پدیده رخ داده است. دو آماره RMSE و NS از

بهترین آماره‌های برای شناسایی و تعیین خطا در مدل هستند که در تحقیقات بسیار زیادی از آن‌ها استفاده شده است. این دو آماره به وضوح بیشتری نسبت به دیگر آماره‌ها به میزان اختلاف بین مقادیر تخمین زده شده و اندازه‌گیری شده می‌پردازند. در بسیار از مطالعات پیشنهاد شده است که آماره NS به دلیل اثر تعداد پارامترهای در مقادیر نهایی نسبت به RMSE برتری دارد. مقدار  $R^2$  هر چقدر به سمت یک نزدیک‌تر باشد نشان دهنده هم‌راستایی بهتر نتایج تخمین و اندازه‌گیری است، همچنین آماره NS نیز هر چقدر به سمت یک نزدیک باشد نشان از دقت خود در تخمین است. RMSE چون بیان‌کننده میزان خطا در مدل است، مقدار آن هرچقدر کمتر باشد نشان دهنده عملکرد بهتر مدل است و در خصوص ME نیز هر چقدر از هر دو سمت مثبت و منفی به صفر نزدیک‌تر باشد نشان دهنده تخمین با دقت بیشتر است. رضای منش و صادقیان [22] با استفاده از شبکه MLP با یک لایه پنهان و متغیرهای ورودی دانه‌بندی مصالح، درصد قیر و وزن مخصوص مصالح اقدام به پیش‌بینی مخلوط‌های آسفالتی کردند. این پژوهشگران بیان کردند که استفاده از شبکه MLP برای تعیین مخلوط‌های آسفالتی ابزار بسیار مفیدی است. نتایج جدول (۹) نشان می‌دهد که با افزایش تعداد پارامترهای ورودی به مدل مقدار  $R^2$  افزایش چشمگیری داشته است.

جدول ۹. مشخصات دقت آماری شبکه MLP طراحی شده در گروه مختلف ورودی

Model	Train				Test				Validation			
	R <sup>2</sup>	ME	RMSE	NS	R <sup>2</sup>	ME	RMSE	NS	R <sup>2</sup>	ME	RMSE	NS
First group	0.57	0.02	12.24	0.75	0.72	-7.42	10.46	0.45	0.47	-3.82	12.61	0.36
Second group	0.94	-1.74	4.86	0.93	0.94	0.57	4.27	0.90	0.95	-0.72	3.41	0.95

Table 9. Statistical accuracy characteristics of the designed MLP network in different input groups

### ۳-۳- نمودار یک به یک مدل MLP

در شکل (۶) نمودارهای یک به یک مربوط به شبکه MLP در حالت‌های مختلف نمایش داده شده است. علاوه بر آماره ME و دیگر آماره‌ها، از شکل (۶) نیز می‌توان به صورت عینی برای تشخیص دقت مدل و کم تخمینی و بیش تخمینی استفاده کرد. به این صورت که اگر پراکنش نقاط بالاتر از خط یک به یک باشد نشانگر بیش تخمینی و اگر این پراکنش پایین خط یک به یک باشد نشان دهنده کم تخمینی است. همان‌گونه در شکل (۶) و جدول (۹) نشان داده شده است کم و بیش تخمینی به مقدار کمی رخ داده است و پراکنش عمده نقاط حول محور خط یک به یک است. این موضوع نشان دهنده تخمین نسبتاً خوب از خاصیت خودترمیمی آسفالت است.

### ۳-۴- مشخصات آماری شبکه RBF

در جدول (۱۰) نتایج چهار آماره مورد بررسی در لایه‌های پنهان مختلف مربوط به شبکه RBF آمده است. همان‌گونه که مشاهده می‌شود در شبکه طراحی شده با دو لایه پنهان با افزایش تعداد متغیرهای ورودی میزان خطا (RMSE) کاهش یافته است و به همان نسبت میزان هم‌راستایی (R<sup>2</sup>) افزایش پیدا کرده است. کمترین مقدار RMSE در بخش آزمون گروه دوم برابر با ۴/۳۵ به دست آمده است (جدول ۱۰). از نظر آماره NS نیز مشاهده می‌شود که در گروه دوم دارای بیشترین مقدار خود یعنی ۰/۹۳ بود. بررسی آماره ME نیز نشان می‌دهد که بیش کم تخمینی در اجرای شبکه به صورت زیادی رخ نداده است. عامری و همکاران [29] با استفاده از شبکه BPNN<sup>16</sup> برای تحلیل روسازی‌های انعطاف‌پذیر استفاده کردند. این پژوهشگران با استفاده از سه متغیر ورودی مقدار R<sup>2</sup> را برابر

به این صورت که در شبکه با دو لایه در بخش آزمون و اعتبارسنجی به ترتیب R<sup>2</sup> از ۰/۵۷ به ۰/۹۴ و ۰/۴۷ به ۰/۹۵ رسیده است (جدول ۹). مشاهده می‌شود که در جدول (۹) کمترین مقدار RMSE بخش آزمون در متغیرهای گروه‌های دوم برابر با ۴/۲۷ به دست آمده است. همچنین بیشترین مقدار آماره NS نیز معادل ۰/۹۵ به دست آمده است. بررسی آماره ME نشان می‌دهد که کم تخمینی و بیش تخمینی زیادی در اجرای شبکه‌های مختلف رخ نداده است. نتایج نشان می‌دهد که اضافه شدن متغیرهای فرکانس، دما، مساحت و غیره به مدل دقت مدل افزایش چشمگیری پیدا می‌کند. به عبارتی اضافه شدن تعداد متغیرهای ورودی سبب انعطاف‌پذیری بیشتر مدل می‌شود و تخمین مناسب‌تری از قابلیت خودترمیمی می‌دهد. اضافه شدن پارامترهای مانند دما سبب افزایش دقت شده است، چراکه این پارامترهای از عوامل مؤثر بر خودترمیمی هستند. از این رو لینگ و همکاران [23] بیان کردند که دما و زمان از عوامل بسیار مهم در قابلیت خودترمیمی آسفالت است. لئو و همکاران [24] و منوزی و همکاران [25] نیز به اهمیت موضوع دما و زمان در قابلیت خودترمیمی پرداختند. نوع افزودنی تأثیر بسیار زیادی بر چقرمگی شکست آسفالت دارد [26, 27]. علیها و همکاران [28] بیان کردند که چقرمگی شکست یکی از مهم‌ترین عوامل مؤثر بر شکست در مخلوط آسفالتی است. از این رو این دو ویژگی به عنوان پایه قابلیت خودترمیمی در نظر گرفته شدند و در تمام مدل‌های مورد بررسی حضور دارند. پودولسکی و همکاران [27] بیان کردند که دما تأثیر بسیار زیادی روی چقرمگی شکست آسفالت دارد. وجود رابطه فیزیکی و مفهومی بین متغیرها باعث می‌شود ارتباط قوی‌تری ایجاد شده و این ارتباط مفهومی سبب کارایی بهتر برآورد می‌شود.

پنهان در شبکه طراحی شده پرداختند. نتایج این پژوهشگران نشان داد که روند مشخصی در افزایش  $R^2$  ناشی از افزایش تعداد لایه‌های پنهان وجود ندارد و دامنه تغییر  $R^2$  به دست آمده توسط این پژوهشگران بین ۰/۹۷ تا ۰/۹۹ برای تعداد لایه‌های پنهان از ۵ تا ۲۴ بود.

به دست آوردند. این پژوهشگران بیان کردند که تحلیل سازه‌های مقاطع روسازی با روش شبکه‌های عصبی علاوه بر سرعت بالای پردازش، می‌تواند از قابلیت بهینه‌یابی نیز برخوردار می‌باشد. شفافیت و همکاران [30] در یک مطالعه با عنوان انتخاب الگوریتم بهینه شبکه عصبی در تحلیل روسازی‌های انعطاف‌پذیر راه‌ها، به بررسی اثر تعداد لایه‌های

شکل ۶. نمودار یک به یک شبکه عصبی MLP در گروه‌های مختلف به منظور تخمین قابلیت خودترمیمی

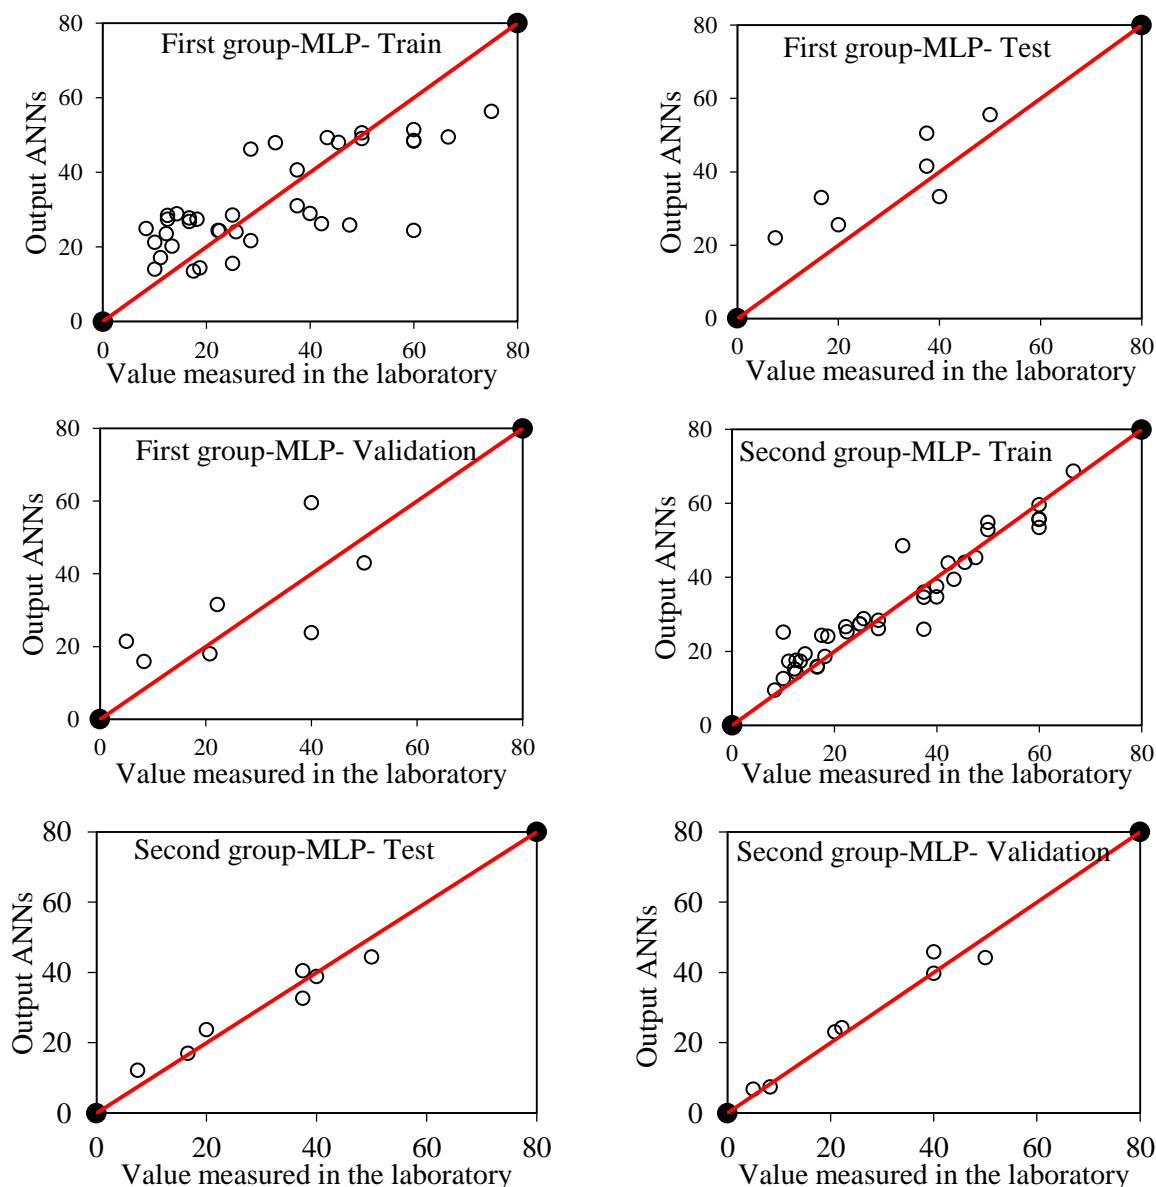


Fig 6. One-to-one diagram of MLP neural network in different groups in order to estimate the self-healing capability

جدول ۱۰. مشخصات دقت آماری شبکه RBF طراحی شده در دو گروه مختلف ورودی

Model	Train				Test				Validation			
	$R^2$	ME	RMSE	NS	$R^2$	ME	RMSE	NS	$R^2$	ME	RMSE	NS
First group	0.51	0.00	13.03	0.51	0.54	-3.46	10.56	0.44	0.51	-3.62	11.73	0.45
Second group	0.95	-1.11	4.76	0.93	0.90	0.58	4.35	0.90	0.92	-2.01	5.02	0.89

Table 10. Statistical accuracy characteristics of the designed RBF network in different input groups


بخش‌های بالا در بخش نمودارهای یک به یک شبکه MLP بیان شد اگر پراکنش نقاط بالاتر از خط یک به یک باشد نشان دهنده بیش تخمینی و اگر این پراکنش پایین این خط باشد نشان دهنده کم تخمینی است. همان‌گونه که در شکل (۷) مشخص است پراکندگی نقاط در گروه اول پراکندگی نقاط مناسب نیست و نزدیکی کمتری به خط یک به یک نسبت به گروه دوم دارد. در تحقیق حاضر، از سازوکاری مبتنی بر شبکه‌های عصبی مصنوعی استفاده شد. مدل پیشنهادی با قابلیت یادگیری از نتایج آزمایش‌ها موجود و تحلیل روابط پیچیده بین متغیرهای ورودی با قابلیت تخمین و پیش‌بینی می‌تواند روشی کارا و مناسب به‌منظور تعیین عملکرد خودترمیمی آسفالت باشد.

طاهرخانی و ابراهیمی مقدم [31] با استفاده از نه متغیر ورودی (ویسکوزیته قیر، درصد قیر، درصد فضای خالی، سطح کرنش و درصد‌های عبوری از الک‌های ۳/۴ اینچ، ۳/۸ اینچ، شماره ۴ و شماره ۲۰۰۰) اقدام به پیش‌بینی و مدل‌سازی عمر خستگی آسفالت کردند. این پژوهشگران تعداد ۱ تا ۳ لایه پنهان، تابع بهینه‌سازی لوببرگ-ماکواردت و تابع فعال‌سازی تانزانت سیگموئید استفاده کردند. این پژوهشگران در طراحی‌های مختلف شبکه دامنه ۲/۹۲۰ تا ۰/۹۴۴ برای  $R^2$  به دست آوردند.

### ۳-۵- نمودار یک به یک مدل RBF

در شکل (۷) نتایج گرافیکی تخمین خاصیت خودترمیمی در برابر مقادیر اندازه‌گیری شده آن توسط شبکه RBF تحت عنوان نمودارهای یک به یک نمایش داده شده است. همان‌گونه در

شکل ۷. نمودار یک به یک شبکه RBF در گروه‌های مختلف








Fig 7. One-to-one diagram of RBF network in different groups

### ۳-۶- تحلیل حساسیت

در جدول (۱۱) نتایج تحلیل حساسیت متغیرهای ورودی نسبت به خروجی در دو شبکه MLP و RBF نمایش داده شد. همان‌گونه که مشخص است شاخص خودترمیمی بیشترین حساسیت را به پارامتر چقرمگی شکست در شبکه MLP داشته است. همچنین مشاهده می‌شود که بعد از چقرمگی شکست، پارامتر انرژی شکست قبل از القا نیز شبکه MLP بیشترین حساسیت را داشته است. در شبکه RBF نیز چقرمگی شکست و دمای آزمایش بیشترین حساسیت را داشته‌اند. نتایج تحلیل حساسیت نشان می‌دهد که دو پارامتر چقرمگی شکست و انرژی شکست قبل و بعد از القا و همچنین دما از مهم‌ترین عوامل مؤثر بر شاخص خود ترمیمی است؛ بنابراین استفاده از این پارامترها به عنوان ورودی در مدل‌های مختلف می‌تواند بسیار مفید باشد و دقت پیش‌بینی را افزایش دهند. در بیشتر موارد حساسیت نسبتاً یکسانی بین دیگر متغیرهای شاخص خودترمیمی آسفالت مشاهده شده است.

### ۳-۷- مقایسه دو مدل MLP و RBF

در شکل (۸) نتایج مقایسه  $R^2$  و NS دو مدل MLP و RBF نمایش داده شده است. به‌طور کلی مشاهده می‌شود که میانگین  $R^2$  در مدل MLP نسبت به مدل RBF بیشتر است. همچنین نتایج نشان می‌دهد که مقدار NS نیز در مدل MLP بیشتر از RBF است.

نتایج این مطالعه نشان داد که استفاده از پارامترهای چقرمگی شکست، انرژی شکست بعد از القا، نوع افزودنی، دمای آزمایش، زمان القا، انرژی شکست قبل از القا، طول ناچ، مساحت و فرکانس تأثیر معنی‌داری بر دقت تخمین قابلیت خودترمیمی آسفالت نیمه گرم دارند. ثابت شده است که افزودنی‌ها و دماها آثار قابل توجهی بر قابلیت خودترمیمی آسفالت دارند [14]. اضافه شدن پارامترهای ورودی در شبکه عصبی سبب انعطاف‌پذیری بیشتر مدل طراحی شده می‌شود و به طبع آن دقت مدل افزایش می‌یابد. این موضوع در مطالعات مختلفی در علوم مختلف به اثبات رسیده است [16, 21, 32]. همچنین ارتباط فیزیکی بین پارامترهای ورودی و قابلیت خودترمیمی آسفالت نیز اهمیت بسیار زیادی بر دقت تخمین‌ها دارد.

جدول ۱۱. تحلیل حساسیت متغیرهای ورودی نسبت به قابلیت خودترمیمی

در شبکه MLP و RBF

Parameter	Unit	MLP	RBF
Fracture toughness	MPa m <sup>1/2</sup>	1.51	1.05
Fracture energy before induction	J/m <sup>2</sup>	1.32	0.96
Additive type	-	1.30	1.09
Test temperature	°C	1.27	1.13
Induction time	s	1.10	0.99
Fracture energy after induction	J/m <sup>2</sup>	1.34	1.00
Notch length	mm	1.03	1.00
Area	mm <sup>2</sup>	0.98	0.99
Frequency	kHz	0.94	0.96

Table 11. Sensitivity analysis of input variables towards self-healing capability in MLP and RBF networks

مدل‌های مختلف می‌تواند بسیار مفید باشد و دقت پیش‌بینی را افزایش دهند

- دقت تخمین قابلیت خودترمیمی آسفالت با استفاده از شبکه عصبی MLP نسبت به RBF بیشتر بوده است و این روش توصیه می‌شود.
- مشاهده شد که اضافه شدن پارامترهای مانند فرکانس، دما، زمان القا و انرژی شکست بعد از القا به دلیل اثری که این متغیرها بر قابلیت خودترمیمی دارند سبب افزایش دقت تخمین شده است. در واقع استفاده از مدل پیشنهادی می‌تواند با تقریب مناسبی خودترمیمی مخلوط‌های آسفالتی را تحت شرایط مختلف پیش‌بینی نماید و مزایای زیست محیطی و اقتصادی زیادی را به همراه خواهد داشت.

### تعارض منافع

نویسندگان اعلام می‌کنند که هیچ نوع تعارض منافی وجود ندارد.

### ۵\_منابع

- 1) Cheraghian, G., Falchetto, A.C., You, Z., Chen, S., Kim, Y.S., Westerhoff, J., Moon, K.H. and Wistuba, M.P., 2020. Warm mix asphalt technology: An up to date review. *Journal of Cleaner Production*, 268, p.122128.
- 2) Kim Y. R., Little D. N., & Lytton R. L. (2001). Evaluation of microdamage, healing, and heat dissipation of asphalt mixtures, using a dynamic mechanical analyzer. *Transportation Research Record*, 1767(1), 60-66
- 3) Aliha, M.R.M., Bahmani, A. and Akhondi, S., 2015. Determination of mode III fracture toughness for different materials using a new designed test configuration. *Materials & Design*, 86, pp.863-871.
- 4) Griffith, A.A., 1921. VI. The phenomena of rupture and flow in solids. *Philosophical transactions of the royal society of london. Series A, containing papers of a mathematical or physical character*, 221(582-593), pp.163-198.
- 5) Gómez-Meijide B., Ajam H., Garcia A., & Vansteenkiste S. (2018). Effect of bitumen properties in the induction healing capacity of asphalt mixes. *Construction and Building Materials*, 190, 131-139
- 6) García, Á., Schlangen, E., van de Ven, M. and Liu, Q., 2012. A simple model to define induction heating in asphalt mastic. *Construction and Building Materials*, 31, pp.38-46.

شکل ۸ مقایسه دو روش MLP و RBF

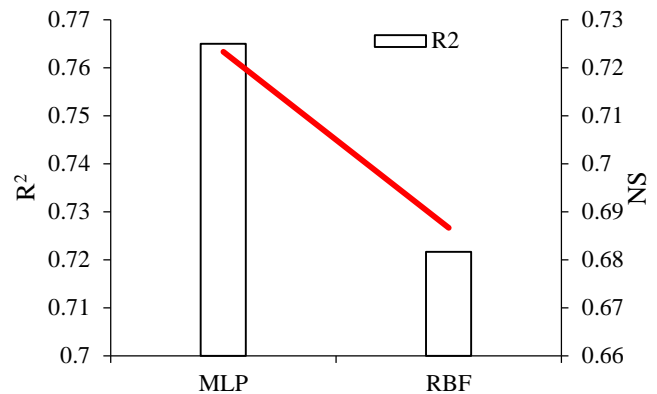


Fig 8. Comparison of MLP and RBF methods

### ۴\_ نتیجه گیری

یکی از مهم‌ترین عملکردهای مخلوط‌های آسفالتی، بهبود خودترمیمی مخلوط‌های آسفالتی است که امروزه نظر محققان را به خود جلب کرده است. در این تحقیق به منظور بررسی اثر متغیرهای مختلف بر دقت تخمین قابلیت خودترمیمی از دو مدل از هوش مصنوعی مبتنی بر یادگیری از آزمایش‌ها قبلی استفاده شد. با توجه به آزمایش‌های انجام‌گرفته روی مخلوط‌های آسفالتی نیمه گرم تحت شرایط مختلف در این پژوهش این گونه می‌توان نتیجه گرفت که:

- مخلوط‌های آسفالتی حاوی ساسویت به مقدار قیر بهینه کمتری نسبت به مخلوط‌های آسفالتی حاوی زایکوترم نیاز داشتند.
- نتایج حاصل از این مطالعه نشان داد که شبکه عصبی مصنوعی به دلیل ماهیت یادگیری و قابلیت آموزش از نتایج آزمایشگاهی پیشین در برآورد قابلیت خودترمیمی و مدل‌سازی ارتباط پیچیده متغیرهای تأثیرگذار ورودی دارای عملکرد و دقت مناسب می‌باشد و استفاده از مدل هوشمند پیشنهادی با کاهش تعداد آزمایش‌ها و هزینه می‌تواند در ارزیابی رفتار خودترمیم شونده‌گی روسازی آسفالتی نیمه‌گرم مؤثر باشد.
- نتایج تحلیل حساسیت نشان می‌دهد که دو پارامتر چقرمگی شکست و انرژی شکست قبل و بعد از القا و همچنین دما از مهم‌ترین عوامل مؤثر بر شاخص خود ترمیمی است. بنابراین استفاده از این پارامترها به عنوان ورودی در

- 20) Ziari H., Aliha M., Moniri A., & Saghafi Y. (2020). Crack resistance of hot mix asphalt containing different percentages of reclaimed asphalt pavement and glass fiber. *Construction and Building Materials*, 230, 117015.
- 21) Bayat H., Ebrahimi E., & Fallah, M. (2018). Estimation of soil moisture using confined compression curve parameters. *Geoderma*, 318, 64-77.
- 22) Rezaki M., & Sadeghian M. (2022). Asphalt mixture design using artificial neural network and genetic algorithm. The 13th National Conference and Exhibition of Bitumen, Asphalt and Machinery. (In Persian)
- 23) Liang B., Lan F., Shi K., Qian G., Liu Z., & Zheng J. (2021). Review on the self-healing of asphalt materials: Mechanism, affecting factors, assessments and improvements. *Construction and Building Materials*, 266, 120453.
- 24) Liu Q., Schlangen E., & Ven M. (2013). Induction Healing of Porous Asphalt Concrete Beams on an Elastic Foundation. *Journal of Materials in Civil Engineering*, 25(7), 880-5.
- 25) Menozzi A., Garcia A., Partl M., Tebaldi G., & Schuetz P. (2015). Induction healing of fatigue damage in asphalt test samples. *Construction and Building Materials*, 74, 162-8.
- 26) Behbahani H., Mohammad Aliha M. R., Fazaeli H., & Aghajani S. (2013). Experimental fracture toughness study for some modified asphalt mixtures. In *Advanced Materials Research*. Trans Tech Publications Ltd, 723, 337-344.
- 27) Podolsky J. H., Buss A., Williams R. C., & Cochran E. (2016). Comparative performance of bio-derived/chemical additives in warm mix asphalt at low temperature. *Materials and Structures*, 49(1), 563-575.
- 28) Aliha M. R. M., Behbahani H., Fazaeli H., & Rezaifar M. H. (2015). Experimental study on mode I fracture toughness of different asphalt mixtures. *Scientia Iranica A*, 22(1), 120-130.
- 29) Ameri M., Molayam M. (2006). The use of artificial neural networks for the analysis of flexible pavements. *International Journal of Engineering Sciences*, 5(17), 53-60. (In Persian)
- 30) Shafabakhsh G. A., Naderpour H., & Fasihi F. (2010). Choosing the optimal neural network algorithm in the analysis of flexible road pavements. *Journal of Modeling in Engineering*, 8(21), 45-57. (In Persian)
- 31) Taherkhani H., & Posht-Panah A. (2013). Predicting the dynamic modulus of hot asphalt concrete using the neural network method. *Transportation research paper*, 10th year. 3, 281-290. (In Persian)
- 32) Bayat H., Ebrahimi E., Ersahin S., Hepper E. N., Singh D. N., Amer A. M. M., & Yukselen-Aksoy Y. (2015). Analyzing the effect of various soil properties on the estimation of soil specific surface area by different methods. *Applied Clay Science*, 116, 129-140.
- 7) Kargari, A., Arabani, M. and Mirabdolazimi, S.M., 2022. Effect of palm oil capsules on the self-healing properties of aged and unaged asphalt mixtures gained by resting period and microwave heating. *Construction and Building Materials*, 316, p.125901.
- 8) Adeli H. (2001). *Neural networks in civil engineering: 1989–2000*. Computer- Aided Civil and Infrastructure Engineering, 16(2), 126-142
- 9) Sezavar, R., Shafabakhsh, G. and Mirabdolazimi, S.M., 2019. New model of moisture susceptibility of nano silica-modified asphalt concrete using GMDH algorithm. *Construction and Building Materials*, 211, pp.528-538.
- 10) Ozturk H. I., & Kutay, M. E. (2014). An artificial neural network model for virtual Superpave asphalt mixture design. *International Journal of Pavement Engineering*, 15(2), 151-162.
- 11) Domitrović J., Dragovan H., Rukavina T., & Dimter S. (2018). Application of an artificial neural network in pavement management system. *Tehnički vjesnik*, 25 (Supplement 2), 466-473
- 12) Baldo N., Manthos E., & Pasetto M. (2018). Analysis of the mechanical behaviour of asphalt concretes using artificial neural networks. *Advances in Civil Engineering*.
- 13) Nguyen H. L., Le T. H., Pham C. T., Le T. T., Ho L. S., Le V. M., & Ly H. B. (2019). Development of hybrid artificial intelligence approaches and a support vector machine algorithm for predicting the marshall parameters of stone matrix asphalt. *Applied Sciences*, 9(15), 3172.
- 14) Kie Badroodi S., Keymanesh M. R., & Shafabakhsh G (2020). Laboratory Study and Investigation on Significance Level of Fatigue Phenomenon in Warm Mix Asphalt Modified with Nano-Silica. *Journal of Rehabilitation in Civil Engineering*, 8(2), 92-113.
- 15) Mirabdolazimi, S.M. and Shafabakhsh, G., 2017. Rutting depth prediction of hot mix asphalts modified with forta fiber using artificial neural networks and genetic programming technique. *Construction and Building Materials*, 148, pp.666-674.
- 16) Hamid A., Baaj H., & El-Hakim M. (2022). Predicting the Recovery and Nonrecoverable Compliance Behaviour of Asphalt Binders Using Artificial Neural Networks. *Processes*, 10(12), 2633.
- 17) Iran Highway Asphalt Paving Code No. 234, National Program and Budget Organization, 1390
- 18) Xu S., García A., Su J., Liu Q., Tabaković A., & Schlangen E. (2018). Self- Healing Asphalt Review: From Idea to Practice. *Advanced Materials Interfaces*, 5(17), 1800536
- 19) Qiu J., Van de Ven M. F. C., Wu S., Yu J., & Molenaar, A. A. A. (2009). Investigating the self-healing capability of bituminous binders. *Road Materials and Pavement Design*, 10(sup1), 81-94.

# Evaluation of the self-healing behavior of warm mix asphalt with the help of failure mechanism and in terms of induction characteristics using Artificial Neural Networks

Israa Omer Mohammed Salih<sup>1</sup>, Meysam Effati<sup>2\*</sup>, Mahrokh Jalali<sup>3</sup> and Seyyed Mohammad Mirabdolazimi<sup>4</sup>

1- Master's student, Department of Civil Engineering (Road and Transportation), Technical College, Guilan University

2- Associate Professor, Department of Civil Engineering (Road and Transportation), Technical College, Guilan University

3- Master's student, Department of Civil Engineering (Road and Transportation), Technical College, Guilan University

4- Assistant Professor, Department of Civil Engineering (Road and Transportation), Technical College, Guilan University

Email: Meysameffati@guilan.ac.ir

## Abstract

Technologies that produce and implement asphalt mixtures at temperatures lower than those of hot mix asphalt (HMA) are referred to as warm mix asphalt (WMA). Enhancing the self-healing capabilities of warm mix asphalt relies on several factors and parameters that are intricately interrelated and exhibit considerable complexity. Therefore, this study aims to investigate the self-healing performance of warm mix asphalt by leveraging the learning and prediction capabilities of multilayer and radial perceptron artificial neural networks. To execute this investigation, two additives, Sasobit and Zycoterm, were incorporated. The process of creating warm mix asphalt involved heating stone materials in an oven for 16 hours at a temperature of 135 degrees Celsius. The mixing of bitumen and additives was carried out by adding Sasobit to bitumen at 130°C and stirring at 1200 rpm for 20 minutes. A three-point bending test was conducted at temperatures of 25 and -16 °C, with crack lengths of 10 and 20 mm, enabling the determination of fracture toughness, fracture energy, and critical load indices for each state. Subsequently, asphalt samples underwent induction heating at frequencies of 88 and 89 kHz and three induction times of 60, 90, and 120 seconds. The input variables for the proposed intelligent model, as suggested by the research, encompassed fracture toughness, fracture energy after induction, additive type, test temperature, induction time, fracture energy before induction, notch length, area and frequency. Sensitivity analysis in two artificial neural network models revealed that, in the multilayer perceptron (MLP) network, the fracture toughness parameter had the most significant effect on the output. Similarly, in the radial basis function (RBF) network, the test temperature parameter exhibited the highest sensitivity coefficient. Results showcased that, in the perceptron neural network with two layers in the test section, root mean square error (RMSE) values decreased from 10.46 in the first model to 4.27 in the secondary model. Likewise, in the basic radial artificial neural network, the addition of input parameters reduced the RMSE value of the test section from 10.56 to 4.35. The estimation accuracy, assessed through the NS value, doubled in the MLP network, reaching from 0.45 to 0.90 in the test section. In the RBF network, with the addition of the NS parameter, the value of NS increased from 0.44 to 0.90. Additionally, in both types of MLP and RBF networks, the R<sup>2</sup> value in the second group was higher than the first group in all test, training, and validation sections. The self-healing index exhibited the highest sensitivity to the fracture toughness parameter in the MLP network. Furthermore, after fracture toughness, the fracture energy parameter before induction emerged as the second most sensitive parameter in the MLP network. In the RBF network, fracture toughness and test temperature were identified as the most sensitive parameters. Observations demonstrated that the inclusion of parameters such as frequency, temperature, induction time, and fracture energy after induction significantly increased the estimated accuracy, underscoring their pivotal role in influencing the self-healing capability. The proposed model exhibits the capability to predict the self-healing of asphalt mixtures under diverse conditions with a suitable approximation, promising numerous environmental and economic benefits. In conclusion, the study affirms the appropriate performance and accuracy of the artificial neural network, substantiated by its learning and training capabilities. The proposed intelligent model, with its ability to reduce the number of experiments and associated costs, emerges as a potent tool for evaluating the self-healing behavior of warm mix asphalt. Overall, the study contributes to the evolving landscape of asphalt material science, offering insights that can potentially reshape practices in asphalt engineering and sustainability.

**Keywords:** Self-healing, Sasobit, Zycoterm, Multilayer Perceptron Artificial Neural Network, Basis Radial Function