

توسعه مدل شبکه عصبی مصنوعی پیش‌بینی دمای لایه‌های آسفالتی با استفاده از داده‌های LTPP

محمد صدیقیان فرد^۱، نادر صولتی فر^{۲*}

۱- دانشجوی کارشناسی ارشد، گروه مهندسی عمران، دانشگاه ارومیه

۲- استادیار، گروه مهندسی عمران، دانشگاه ارومیه

n.solatifar@urmia.ac.ir

تاریخ پذیرش: ۹۹/۱۱/۴

تاریخ دریافت: ۹۹/۳/۷

چکیده

دمای عمق لایه‌های آسفالتی یکی از پارامترهای مهم و اساسی در فرآیند تحلیل، طراحی و مطالعات بهسازی (روکش) روسازی‌های آسفالتی است. مدل‌های پیش‌بینی به عنوان جایگزین اندازه‌گیری میدانی و آزمایشگاهی این دما، از روش‌های کم‌هزینه و سریع تعیین دمای عمق لایه‌های آسفالتی هستند. این در حالی است که این مدل‌ها بر اساس داده‌های میدانی و آزمایشگاهی محدود ساخته شده‌اند و نیاز به توسعه مدل‌هایی برای تعیین دمای لایه‌های آسفالتی در شرایط مختلف ترافیکی و آب و هوایی وجود دارد. هدف اصلی این پژوهش توسعه مدلی برای پیش‌بینی دمای عمق لایه‌های آسفالتی بر اساس داده‌های آب و هوایی است. در سال‌های اخیر، شبکه‌های عصبی مصنوعی به عنوان ابزاری مفید برای مدل‌سازی پدیده‌های تجربی، عملکرد مناسبی از خود نشان داده‌اند. روش مدل‌سازی استفاده شده در این پژوهش، مدل شبکه عصبی مصنوعی پس‌انتشار می‌باشد که میانگین ساعتی دمای عمق لایه‌های آسفالتی را بر اساس سایر متغیرها شامل زمان روز، عمق مورد نظر از سطح رو سازی، میانگین ساعتی دمای هوای میانگین سرعت و جهت باد، کمینه رطوبت هوا و کل تابش آفتاب پیش‌بینی می‌کند. داده‌ها از پایگاه داده برنامه عملکرد بلندمدت (LTPP) استخراج شده است. برای مدل‌سازی از داده‌های چندین ساله مربوط به ایالت اوهايو آمريكا استفاده شده است. بعد از آموزش شبکه، عملکرد مدل توسعه یافته ارزیابی شد و با نتایج مدل رگرسیونی غیرخطی درجه دوم مقایسه شده است. این مقایسه نشان می‌دهد مدل شبکه عصبی دقت بالاتری نسبت به مدل رگرسیونی دارد. نتایج پژوهش قابلیت پیش‌بینی دمای عمق لایه‌های آسفالتی را بر اساس داده‌های آب و هوایی موجود توسط مدل توسعه یافته با دقت پیش‌بینی بسیار خوب (ضریب تعیین برابر ۰/۹۶)، بیانس و خطای پیش‌بینی کم نشان می‌دهد.

واژه‌های کلیدی: دمای عمق لایه‌های آسفالتی، مدل پیش‌بینی دما، شبکه‌های عصبی مصنوعی (ANN)، برنامه عملکرد بلندمدت روسازی (LTPP)

بزرگراه‌های تحت مدیریت خود را می‌دهد. برای بررسی تاثیر دما بر رفتار لایه‌های آسفالتی، تعیین چگونگی توزیع دما در عمق‌های مختلف لایه در طول شباهنگی روز ضروری است. با داشتن این توزیع دمانی، محاسبه آثار دما بر روسازی به ویژه در طراحی روکش و مطالعات بهسازی راه انجام می‌شود. با توجه به اهمیت آگاهی از دمای عمق لایه‌های آسفالتی در تحلیل، طراحی، اجرا، ارزیابی و بهسازی روسازی، هدف این مقاله توسعه مدلی برای پیش‌بینی دمای عمق لایه‌های آسفالتی است. مدل توسعه داده شده بر اساس متغیرهایی شامل زمان روز، عمق مورد نظر از سطح روسازی، دما و رطوبت هوای جهت و سرعت باد، و کل تابش آفتاب عمل می‌کند.

۲. تاریخچه مدل‌های پیش‌بینی دمای عمق لایه‌های آسفالتی

مدل‌ها و روش‌های مختلفی برای پیش‌بینی دمای عمق لایه‌های آسفالتی توسط پژوهشگران ارائه شده است. این مدل‌ها را می‌توان به سه دسته کلی تقسیم کرد: دسته‌های اول، مدل‌هایی هستند که رویکرد تحلیلی^۱ دارند و بر اساس تئوری انتقال حرارت و مشخصات حرارتی روسازی آسفالتی توسعه یافته‌اند. دسته دوم، مدل‌هایی بر پایه محا سیمات نرم^۲ هستند که شامل شبکه‌های عصبی مصنوعی^۳ (ANN)، سیستم بهره‌وری عصبی^۴ (GMDH)، روش کترول گروهی داده‌ها^۵ (ANFIS)، بر نامه‌نویسی عبارتی^۶ (GEP) و ... می‌شود. دسته سوم، روش‌های آماری هستند که از مدل‌های رگرسیونی برای به دست آوردن رابطه بین دمای عمق لایه‌های آسفالتی و داده‌های آب و هوایی استفاده می‌کنند.

محاسبات نرم بر اساس رویکردهایی به طور موثر برای مدل سازی و پیش‌بینی رفتار مکانیکی و مقاومت مصالح مورد استفاده قرار می‌گیرد [۷-۹] در این میان شبکه‌های عصبی مصنوعی قابلیت و توانایی بیشتر و همچنین خطای کمتری نسبت به مدل‌های ریاضی دارند [۱۰]. این مدل‌ها به طور گسترده در حوزه‌های مختلف مهندسی عمران موردن استفاده قرار می‌گیرد که به دلیل درستی و دقت بالا، کاربردهای آنها با نتایج خوب همراه بوده است [۱۱]. پژوهش‌های اخیر، تحمل بیشتر در

در سال‌های اخیر افزایش توجه به حوادث طبیعی و آب و هوایی که زیرساخت‌های حمل و نقل را تحت تاثیر قرار می‌دهد، به یکی از مهم‌ترین موضوعات پژوهشی تبدیل شده و مورد توجه پژوهشگران مختلف قرار گرفته است [۱-۲]. افزایش حجم ترافیک و بارهای وسایل تقلیل سنجنگی منجر به فرایش شدید سازه روسازی راه‌ها شده است. این امر به طور مستقیم باعث افزایش هزینه‌های تعمیر و نگهداری سازمان‌های متولی بهره‌برداری از راه‌ها شده است. این روند پیش رو، به همراه خواسته‌های معمول برای زیرساخت‌های حمل و نقل بادام و ... منجر به نیاز به افزایش عمر روسازی‌های آسفالتی از ۲۰ سال به ۵۰ سال یا بیشتر شده است [۳-۵]. مخلوط آسفالتی، ماده‌ای ویسکوالاستیک^۱ است و ویژگی‌های هر دو مصالح ویسکوز و الاستیک را دارد. یکی از فاکتورهای مهم محیطی که تغییر شکل روسازی‌های آسفالتی را تحت تاثیر قرار می‌دهد، دمای عمق لایه‌های آسفالتی است؛ که این تاثیر به دلیل همین رفتار ویسکوالاستیک مخلوط آسفالتی است [۳-۵].

در تحلیل، طراحی و ارزیابی روسازی، پیش‌بینی دما در سطح و عمق لایه‌های آسفالتی ضروری است. دمای عمق لایه‌های آسفالتی بیشتر متأثر از ویژگی‌های جذب و انعکاس انرژی خور شیدی لایه‌ها و مشخصات حرارتی مخلوط آسفالتی است [۶]. از طرف دیگر تغییرات دمایی روزانه و فصلی در شکل‌گیری تشکیلات حرارتی نقش به سازنده دارند. این تغییرات می‌تواند باعث ترک خوردن^۲ لایه روسازی آسفالتی شود که این امر در پیش‌بینی دوره عمر لایه‌های آسفالتی تأثیرگذار است. در مناطقی که تغییرات دمایی زیادی را تجربه می‌کنند، شرایط حرارتی لایه‌ها نقشی مهم در ترک خوردن^۳ سیستم روسازی چنلاجیهای دارد. مشخصات مخلوط آسفالتی اعم از سختی، پیر شدگی و ... نسبت به تغییرات دمایی حساس است. تغییرات دمایی روزانه هوا تأثیر چشمگیری بر وضعیت حرارتی لایه آسفالتی در عمق‌های نزدیک به سطح روسازی دارد [۷].

توسعه مدل‌های پیش‌بینی به سازمان‌های حمل و نقل امکان برنامه‌ریزی و زمان‌بندی دقیق فعالیت‌های نگهداری و بهسازی روسازی

۱. Adaptive Neuro-Fuzzy Inference System

۲. Group Method of Data Handling

۳. Genetic Expression Programming

۱. Viscoelastic

۲. Analytical

۳. Soft Computing

۴. Artificial Neural Networks

۱. مقدمه

پیش‌بینی دمای عمق لایه‌های آسفالتی با مدل شبکه عصبی پرسپترون چندلایه^۲ (MLP) توسط گودوی و همکاران [15] نشان می‌دهد که شبکه عصبی MLP دمای عمق لایه‌های آسفالتی را با دقت خوبی پیش‌بینی می‌کند و کارایی بهتری نسبت به مدل رگرسیونی BELLS [16] دارد. همچنین برای مطالعه عمق‌های زیاد، نیاز به وارد کردن پارامترهای مانند مشخصات مصالح به عنوان ورودی مدل هست. در برنامه پژوهش‌های راهبردی بزرگراه‌ها؛ (شارپ - SHRP) مدل‌ها و روش‌های متعددی برای پیش‌بینی رفتار حرارتی لایه‌های آسفالتی ارائه شده است. این برنامه و نیز برنامه عملکرد بلندمدت رو سازی‌ه (LTPP) از سال ۱۹۸۷ در ایالات متحده آمریکا برای تعیین رفتار دقیق رو سازی‌ها اجرا شده است. لوکان و همکاران [17] مدل‌هایی بر اساس داده‌های بسط‌یافته برنامه پایش فصلی^۶ (SMP) برای پیش‌بینی کمینه و بیشینه دمای رو سازی، ارائه کرده‌اند. مطالعات حدود ۲۵۸۱ قطعه رو سازی تشکیل شده است. از این تعداد حدود ۸۲ قطعه در ایالات متحده آمریکا و کانادا (همه قطعات رو سازی) برای برنامه پایش فصلی (از قطعات SPS) در نظر گرفته شده است. در جدول (۱) مدل‌های مختلف توسعه یافته قبلی (رگرسیونی، شبکه‌های عصبی مصنوعی و ...) به همراه مشخصات و جزئیات آنها (متغیرهای ورودی، تعداد داده‌ها، دقت مدل و ...) ارائه شده است. با توجه به این که پژوهشگران مختلف اطلاعات متفاوتی (مشخصات محدود یا کامل) را در پژوهش خود ارائه کرده‌اند، در این خصوص سعی شده است که تمامی مشخصات مختلف هر مدل ارائه شود. مدل توسعه یافته توسط طباطبائی و همکاران [18] با هفت متغیر مستقل دارای بیشترین پارامتر ورودی و مدل‌های حسن و همکاران [19] و متیچ و همکاران [14] با دو متغیر ورودی دارای کمترین پارامتر ورودی هستند. دینلرفر و همکاران [20] عرض جغرافیایی را به عنوان یکی از پارامترهای مهم برای پیش‌بینی دمای عمق لایه‌های آسفالتی در مناطق دیگر معرفی کرده‌اند. در نظر گرفتن مشخصات مصالح لایه مانند تراکم مخلوط، نوع قیر و درصد آن، در مدل ارائه شده توسط طباطبائی و همکاران [18] از نقاط قوت آن است، در حالی که محدودیت دسترسی

برابر خطای مدل‌های شبکه عصبی در مقایسه با مدل‌های بر پایه رگرسیون را نشان می‌دهد. به عنوان نمونه، مقایسه بین مدل‌های شبکه عصبی و پیش‌روندۀ خودکار سری زمانی برای پیش‌بینی سرعت آزادراه نشان می‌دهد که این شبکه‌ها پیش‌بینی‌های دقیق‌تری نسبت به رویکردهای آماری کلاسیک ارائه می‌دهند [11]. همچنین مقایسه‌ای بین قابلیت‌های مدل‌های رگرسیونی و شبکه عصبی توسط گلشنی و همکاران [12] انجام شده است.

مدل شبکه عصبی پس اتشار ۱ تو سط شو و همکاران [13] برای پیش‌بینی دمای روسازی در مناطق سرد ارائه شده است. در این پژوهش روش‌های پیش‌بینی استاتیکی و دینامیکی جدیدی به وسیله توسعه الگوریتم‌هایی برای چیرگی بر پیش‌بینی نادرست در زمان تغییر دمای روزانه ارائه شده است. نتایج این پژوهش نشان می‌دهد زمانی که نوسان یا تغییرات دمای روسازی کم است، مقادیر دمای پیش‌بینی شده با مقادیر دمای واقعی دارای همبستگی خوب و با خطای کمی همراه بوده است. همچنین زمان وقفه بیشترین تاثیر را بر دقت پیش‌بینی دما دارد و با افزایش این زمان، نوسانات دمای روسازی و خطاهای به تدریج کاهش می‌یابد و در نتیجه دقت مدل افزایش می‌یابد. مدل ارائه شده می‌تواند برای پیش‌بینی دمای رو سازی و توسعه سیستم‌های هشداردهنده برای روسازی‌ها در مناطق سرد مورد استفاده قرار گیرد.

نتیج و همکاران [14] مدلی را برای پیش‌بینی دمای عمق روسازی با استفاده از شبکه‌های عصبی ارائه کرده‌اند. در این پژوهش کمینه و بیشینه دمای رو سازی در عمق مشخصی از رو سازی بر اساس دمای سطح و عمق رو سازی پیش‌بینی شده است. نتایج این پژوهش نشان می‌دهد که دمای رو سازی وابسته به دمای سطح، زمان روز و عمق مورد نظر در روسازی است. همچنین بر اساس خطای قدر مطلق میانگین^۲ (MAE) و انحراف معیار، مدل برای پیش‌بینی دمای روسازی در عمق دارای دقت بالایی هست. در پیش‌بینی کمینه دمای رو سازی دقت بیشتری دارد و در مجموع مدل توسعه یافته نسبت به مدل‌های رگرسیونی دارای خطای پایین و دقت بالایی است.

۵. Long-Term Pavement Performance

۶. Seasonal Monitoring Program

۷. Specific Pavement Studies

۱. Back-Propagation

۲. Mean Absolute Error

۳. Multi-Layer Perceptron

۴. Strategic Highway Research Program

آسفالتی، دمای هوا، سرعت و جهت باد، رطوبت هوا و تابش آفتاب)، از پایگاه داده برنامه LTPP برای استخراج داده‌های مورد نیاز در این پژوهش استفاده شده است. نوع رو سازی خاصی مد نظر پژوهشگران ۳۹-۰۹۰۱ با کد قطعه ۱۰۹۰-۳۹ نبوده و داده‌های رو سازی واقع در ایالت اوهایو با کد قطعه که دارای داده‌های مورد نیاز بوده‌اند، استخراج شده است. از آن جایی که پژوهش حاضر به دنبال توسعه مدلی عمومی بوده است، تفکیک خاصی در استخراج داده‌ها صورت نگرفته و صرفاً با توجه به مدل سازی دمای عمق لایه‌های آسفالتی، تنها فیلتر اعمال شده رو سازی‌های بتی (صلب) بوده‌اند. برای استخراج داده‌های میانگین ساعتی دمای عمق لایه‌های آسفالتی و همچنین داده‌های آب و هوایی (میانگین ساعتی دمای هوا و ...) از دو مازول^۲ برنامه نظارت فصلی (SMP) و ایستگاه آب و هوایی خودکار^۳ (AWS) در بخش آب و هوایی پایگاه داده LTPP استفاده شده است. این دو مازول در بخش طبقبندی پیشرفته داده‌ها هستند. در مازول SMP داده‌های دمای عمق و بارش باران به صورت میانگین ساعتی و روزانه بوده و در مازول AWS نیز به صورت میانگین، بیشترین و کمترین ماهانه، روزانه و ساعتی است. با توجه به این که هدف این پژوهش پیش‌بینی دمای عمق در هر ساعتی از شبانه روز است، همه داده‌ها به صورت میانگین ساعتی جمع‌آوری و استفاده شده است. داده‌های استفاده شده شامل کد شارپ^۴، کد ایالت^۵، شماره ساخت، عرض، طول و تراز ارتفاعی جغرافیایی، نوع قطعه رو سازی، ضخامت کل و مجزای هر یک از لایه‌های آسفالتی، عمق دما سنج مدفعون در لایه‌ها است. همچنین داده‌های آب و هوایی مورد نیاز نیز شامل میانگین ساعتی دمای عمق لایه‌های آسفالتی، میانگین ساعتی دمای هوا، میانگین سرعت و جهت باد، کمینه رطوبت هوا و کل تابش آفتاب می‌شود. با توجه به این که هدف این پژوهش پیش‌بینی میانگین ساعتی دمای عمق لایه‌های آسفالتی است، استخراج سایر داده‌ها بر اساس در دسترس بودن داده‌های آسفالتی است، دمای عمق مرتبط با آنها انجام شده است

به داده‌ها و عدم کاربرد مدل در مناطق مختلف از نقاط ضعف این مدل است. نتایج بررسی مدل BELLS [16] نیز نشان می‌دهد که این مدل قابلیت بالایی برای پیش‌بینی دمای عمق لایه‌های آسفالتی قدیمی (روکش شده) دارد، در حالی که این مدل در پیش‌بینی دمای عمق رو سازی‌های تازه ساخت در مناطق با آب و هوای گرم دارای ضعف بوده و از دقت کمتری برخوردار است [21]. برای حل این مشکل، مدل BELLs توسط صولتی فر و همکاران [21] کالیبره و اصلاح شده است.

مدل شبکه عصبی توسعه یافته توسط شو و همکاران [13] دارای دقت بسیار خوبی بوده و خطای پیش‌بینی آن کمتر از ۰/۳ درجه سلسیوس است. مدل متیچ و همکاران [14] در پیش‌بینی کمترین دمای رو سازی و دمای عمق دارای دقت بالایی بوده، در حالی که این مدل دقت کمتری در پیش‌بینی بیشترین دما دارد. صدیقیان فرد و صولتی فر [22] پژوهش مروری جامعی در خصوص انواع مدل‌های معمول پیش‌بینی دمای عمق لایه‌های آسفالتی را انجام داده‌اند. در این پژوهش روابط ریاضی و مشخصات متغیرهای مدل‌های رگرسیونی ارائه شده در جدول (۱) به صورت جامع تحلیل و بررسی شده است که برای اطلاعات بیشتر می‌توان به این مرجع [22] مراجعه کرد.

در هر یک مدل‌های مختلف توسعه یافته، دمای عمق لایه‌های آسفالتی بر اساس پارامترهای مختلف پیش‌بینی شده و متغیرهای ورودی آنها با مدل توسعه یافته در این پژوهش در برخی موارد مانند دمای هوا، تابش آفتاب و ... مشترک هستند. از نقاط قوت مدل توسعه یافته در این پژوهش با مقایسه مدل‌های بررسی شده، استفاده از داده‌های بسیار زیاد، در نظر گرفتن اغلب پارامترهای مهم و تاثیرگذار بر دمای عمق لایه‌های آسفالتی (دمای هوا، سرعت و جهت باد، رطوبت هوا، زمان روز و ...) بوده که در بیشتر موارد این داده‌ها در دسترس و گردآوری آنها راحت (بدون نیاز به تجهیزات خاص) است.

۳. استخراج داده‌ها از پایگاه داده LTPP

با توجه به نیاز به یک پایگاه داده جامع و عدم وجود اطلاعات و مشخصات کافی رو سازی راههای ایران (داده‌های دمای عمق لایه‌های

۵. State_Code

۶. Construction_No

۱. Ohio

۲. Module

۳. Automated Weather Station

۴. SHRP_ID

جدول ۱. مدل‌های پیش‌بینی دمای عمق لایه‌های آسفالتی به همراه مشخصات آنها

Model	Model type	Input variables	Output variables	No. of used data, Source (if applicable)	Model accuracy
Diefenderfer et al. [20]	Regression-based	$T_{a\max}, T_{a\min}, R_s, P_d$	$T_{p\max}, T_{p\min}$	2028, Virginia Smart Road, Virginia, USA	$R^2 = 0.77$ (Max temp. model), 0.80 (Min temp. model)
Hassan et al. [19]	Regression-based	$T_{air}, Solar$	T_{20mm}	445, Sultan Qaboos University, Oman	$R^2 = 0.85$
Tabatabaei et al. [18]	Regression-based	$Sur, t, d, comp, Air, BP, BT$	T	9 months data, Shahid Chamran University, Ahwaz, Iran	$R^2 = 0.95$
Gedafa et al. [23]	Regression-based	T_{sur}, T_{ave}, t_d, D	T_{pave}	65, Kansas, USA	$R^2 = 0.94$
Li et al. [24]	Regression-based	$d, \bar{T}_{aN}, Q_n, T_m$	T_d	91081, China	$R^2 = 0.97$
Asefzadeh et al. [25]	Regression-based	$T_{air-min}, T_{air-max}, SR, D$	$T_{daily-minimum}, T_{daily-maximum}$	Two-year temperature data, Alberta, Canada	$R^2 = 0.92$ (Max temp. model), 0.91 (Min temp. model)
BELLS [16]	Regression-based	$IR, d, T_{(1-day)}, hr_{18}$	T_d	10304, LTPP (SMP) data, USA.	$R^2 = 0.98$
Xu et al. [13]	BP neural network	$Air, H, W, Dir., Rain, T_{Sur}, Condition$	T	144, Lianshao tunnel, China	Prediction error = 0.3~0.8 °C
Matic et al. [14]	ANN (MLP)	T_{sur}, D	$T_{p\max}, T_{p\min}$	Two-year data, Serbia	MAE = 0.64~0.68 °C
Godoy et al [15]	ANN (MLP)	$t, T_{(1-day)}, T_{sur}$	T_d	One-year data (August 2016 – August 2017), Spain	Prediction error > 5, 35% on summer and winter days, respectively

Table 1. Depth temperature predictive models for asphalt layers and their specifications

بعد از استخراج و تهیه داده‌های خام، سایر داده‌ها اعم از زمان روز، میانگین ساعتی دمای هوای میانگین سرعت و جهت باد و ... با داده‌های میانگین ساعتی دمای عمق از نظر هماهنگی کد سایت، زمان ثبت داده و سایر موارد (شماره ساخت، شماره محل و نمونه و ...) کنترل شده و با استفاده از نرمافزار اکسل ۱ مرتب شده‌اند. در فرآیند هماهنگی داده‌ها، گپ‌های زمانی موجود در داده‌های دمای عمق تعیین شده است. این گپ‌ها در تمامی داده‌های مستخرج غیر از داده‌های دمای عمق، شناسایی و حذف شده‌اند. در حالت کلی داده‌های دمای عمق با توجه به ضخامت کل لایه‌های آسفالتی، در سه عمق استفاده شده قرار گرفته‌اند. لازم است ذکر شود که داده‌های دمای عمق لایه‌های آسفالتی برنامه SMP از اوت ۱۹۹۴ تا اکبر ۲۰۰۴ و داده‌های آب و هوایی AWS از اوت ۱۹۹۴ تا دسامبر ۲۰۰۸ در پایگاه داده LTPP در دسترس هستند. در نهایت برای توسعه مدل پیش‌بینی دمای عمق لایه‌های آسفالتی این پژوهش از تعداد ۳۴۶۷۶ مجموعه داده استفاده شده است.

داده‌های میانگین ساعتی دمای عمق و میانگین ساعتی دمای هوای مازول SMP و داده‌های میانگین و بیشینه سرعت و جهت باد، بیشینه و کمینه رطوبت هوا و کل تابش آفتاب از مازول AWS استخراج شده‌اند. خاطرنشان می‌شود منظور از بیشینه جهت باد، جهت جغرافیایی است که بیشینه باد در آن جهت می‌وزد. در شکل (۱) محل قطعه رو سازی مورد مطالعه در این پژوهش در ایالت اوهايو آمریکا نشان شده است. همچنین در جدول (۲) نمونه‌ای از داده‌های مستخرج شامل هفت متغیر مستقل (میانگین ساعتی دمای هوای و ...)، متغیر وابسته (میانگین ساعتی دمای عمق لایه‌های آسفالتی) و محدوده تغییرات متغیرها به همراه عمق دما سنج از سطح رو سازی ارائه شده است. همان‌گونه که در این جدول دیده می‌شود میانگین ساعتی دمای عمق لایه‌های آسفالتی از $13.2/4.6$ درجه سلسیوس متغیر است. خاطرنشان می‌شود که محدوده تغییرات ارائه شده برای هر یک از پارامترها در جدول برای کل داده‌ها است. همچنین دمای عمق لایه‌های آسفالتی در ساعتی مشخص با ثابت بودن پارامترهای آب و هوایی، در سه عمق مختلف از سطح رو سازی آسفالتی اندازه‌گیری شده است.

شکل ۱. محل و شرایط آب و هوایی سایت روسازی در ایالت اوهایو، ایالت متحده آمریکا با کد قطعه روسازی ۳۹-۰۹۰۱



Fig. 1. Location and general climatic conditions of the pavement site in Ohio, USA - Section ID: 39-0901

جدول ۲. نمونه‌ای از داده‌های استفاده شده برای توسعه مدل شبکه عصبی پس انتشار در پژوهش حاضر

Date (m/d/yyyy)	Independent variable								Dependent variable	
	Thickness of asphalt layer (m)	Time of the day (Decimal)	Depth from pavement surface (m)	Air temperature (°C)	Average wind speed (m/s)	Average wind direction (Degree)	Minimum air humidity (%)	Solar radiation (W/m²)	Depth temperature of asphalt layer (°C)	
Sample 01 12/16/1999	0.1067	16	0.025	-0.1	6.2	270	76.9	75	2	
Sample 02 12/16/1999	0.1067	16	0.055	-0.1	6.2	270	76.9	75	3	
Sample 03 12/16/1999	0.1067	16	0.084	-0.1	6.2	270	76.9	75	3.5	
Sample 04 1/2/2000	0.1067	17	0.025	14.8	9	221	80.4	91.8	13.3	
Sample 05 1/2/2000	0.1067	17	0.055	14.8	9	221	80.4	91.8	11.7	
Sample 06 1/2/2000	0.1067	17	0.084	14.8	9	221	80.4	91.8	10.3	
Sample 07 1/26/2000	0.1067	9	0.025	-13.3	3	338	77.8	62.1	-8	
Sample 08 1/26/2000	0.1067	9	0.055	-13.3	3	338	77.8	62.1	-8	
Sample 09 1/26/2000	0.1067	9	0.084	-13.3	3	338	77.8	62.1	-8	
Sample 10 3/5/2000	0.1067	14	0.025	12.6	2.3	323	29.1	721	21.4	
Sample 11 3/5/2000	0.1067	14	0.055	12.6	2.3	323	29.1	721	16.7	
Sample 12 3/5/2000	0.1067	14	0.084	12.6	2.3	323	29.1	721	13.3	
Sample 13 6/13/2000	0.1067	19	0.025	24.6	3.8	351	60.3	76.1	36.2	
Sample 14 6/13/2000	0.1067	19	0.055	24.6	3.8	351	60.3	76.1	35.9	
Sample 15 6/13/2000	0.1067	19	0.084	24.6	3.8	351	60.3	76.1	35.2	
Sample 16 8/10/2000	0.1067	13	0.025	25	2.7	328	64.6	757	36.7	
Sample 17 8/10/2000	0.1067	13	0.055	25	2.7	328	64.6	757	31	
Sample 18 8/10/2000	0.1067	13	0.084	25	2.7	328	64.6	757	27.9	
Sample 19 2/10/2001	0.1067	15	0.055	-2.7	4.7	321	58.9	263.9	6.6	
Sample 20 2/10/2001	0.1067	15	0.084	-2.7	4.7	321	58.9	263.9	5.9	
Sample 21 11/16/2002	0.1067	23	0.025	0.1	4.8	10	96.9	0	3.2	
Sample 22 11/16/2002	0.1067	23	0.055	0.1	4.8	10	96.9	0	3.8	
Sample 23 11/16/2002	0.1067	23	0.084	0.1	4.8	10	96.9	0	5	
Sample 24 1/29/2000	0.1067	11	0.084	-7.8	4.3	105	72.4	413.5	-9.4	
Sample 25 12/23/2000	0.1067	10	0.084	-13.2	2.1	178	77.4	150.4	-9.4	
Sample 26 12/28/2000	0.1067	5	0.055	-16.2	1.5	340	86.9	0	-9.4	
Sample 27 1/2/2001	0.1067	9	0.055	-13.8	0.2	286	86.4	37.2	-9.4	
Sample 28 3/24/2003	0.1067	10	0.025	12.5	2.9	197	56.1	512.2	13.8	
Sample 29 3/24/2003	0.1067	10	0.055	12.5	2.9	197	56.1	512.2	10.1	
Sample 30 3/24/2003	0.1067	10	0.084	12.5	2.9	197	56.1	512.2	8.9	

Table 2. 30 samples of the data points employed to develop a Back-Propagation neural network model

بودن در مدل، بیشینه سرعت باد با همبستگی -1 درصد، بیشینه جهت باد با همبستگی $-11/9$ - درصد و نیز بیشینه میزان رطوبت هوا با همبستگی -24 - درصد با دمای عمق لایه‌های آسفالتی از بانک داده حذف شده است. در نهایت هفت متغیر مستقل برای مدل سازی پژوهش حاضر عبارتند از: زمان روز (x_1)، عمق از سطح روسازی (x_2)، میانگین ساعتی دمای هوا (x_3)، میانگین سرعت باد (x_4)، میانگین جهت باد (x_5)، کمینه میزان رطوبت هوا (x_6) و کل تابش آفتاب (x_7). مدل استفاده شده در این پژوهش شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) است. مدل سازی با استفاده از نرم‌افزار MATLAB نسخه 2018b R2018b انجام شده است. سه مولفه اصلی استفاده شده برای توسعه مدل‌های شبکه عصبی مصنوعی عبارتند از ساختار^۲ یا معماری^۳ ارتباط بین لایه ورودی و خروجی، روش بهینه‌سازی و تنظیم وزن ارتباط (روش یادگیری) و تابع فعال‌سازی؛ نورون. معماری یا ساختار شبکه عصبی در توسعه مدلی بهینه نقش مهمی ایفا می‌کند. ساختار مدل استفاده شده در این پژوهش شامل سه لایه ورودی، لایه پنهان و لایه خروجی است که در شکل (۲) ارائه شده است. لایه ورودی شامل هفت متغیر مستقل بوده که پیشتر تعریف شده‌اند. این متغیرها به وزن‌هایی ضرب شده و جمع می‌شوند. همچنین مولفه بایاسه نیز به آنها اضافه می‌شود. واحد پایه مدل شبکه عصبی نورون می‌باشد که ورودی را ترکیب می‌کند و خروجی را همان‌گونه که در شکل (۲) ارائه شده، تولید می‌کند. در لایه ورودی، متغیرهای مستقل وارد شده و به نورونی مجزا تخصیص داده می‌شود. چالش اصلی، تصمیم‌گیری در مورد تعداد نورون‌ها در لایه پنهان است؛ به دلیل این که این موضوع تاثیر زیادی در عملکرد مدل دارد. به عنوان نمونه، استفاده از تعداد زیادی از نورون‌ها در لایه پنهان می‌تواند باعث پیچیده‌تر شدن مدل شود [26].

۴. مدل‌سازی

در این بخش روش استفاده شده برای مدل‌سازی و فرآیند تحلیل داده‌ها بررسی شده است. ابتدا آزمون همبستگی پیرسون بین متغیرها برای تشخیص وجود یا عدم وجود چندخطی^۱ بودن متغیرها با استفاده از نرم‌افزار SPSS نسخه ۲۵ انجام شده است. در این آزمون محدوده تغییرات همبستگی بین متغیرها با توجه به منظور رابطه بین آنها از صفر تا یک یا منفی یک است. هر چه مقدار همبستگی به یک یا منفی یک نزدیک‌تر باشد رابطه بین دو متغیر قوی و زیاد بوده و بر عکس هر چه به صفر نزدیک‌تر باشد، رابطه‌ای بین آن دو نیست. با مقایسه و بررسی مقدار همبستگی می‌توان تشخیص داد که کدام یک از متغیرهای مستقل تاثیر زیادی بر متغیر وابسته یا پاسخ دارند [21]. سپس، متغیرهایی که همبستگی زیادی با یکدیگر داشته تعیین شده و از بین آنها متغیری که تاثیر بیشتری بر پیش‌بینی پاسخ دارد در مدل سازی در نظر گرفته شده و متغیر دیگر برای جلوگیری از چندخطی بودن در مدل، حذف شده است. در ادامه داده‌ها به صورت تصادفی مرتب شده و بانک داده نهایی تهیه شده است. بانک داده شامل ۱۰ متغیر مستقل (ورودی) و یک متغیر وابسته (پاسخ) است. متغیرهای ورودی عبارتند از: زمان روز، عمق از سطح روسازی، میانگین ساعتی دمای هوا، میانگین ساعتی و بیشینه سرعت و جهت باد، بیشینه و کمینه میزان رطوبت هوا و کل تابش آفتاب.

متغیر وابسته میانگین ساعتی دمای عمق لایه آسفالتی است. نتایج آزمون همبستگی برای این داده‌ها در جدول (۳) ارائه شده است. همان‌گونه که در این جدول مشاهده می‌شود، میانگین و بیشینه سرعت باد با همبستگی $96/8$ درصد، میانگین و بیشینه جهت باد با همبستگی $82/6$ درصد و همچنین کمینه و بیشینه میزان رطوبت هوا با همبستگی $96/9$ درصد همبستگی بالایی با یکدیگر دارند (زیر آنها خط کشیده شده است). بنابراین برای جلوگیری از چندخطی

۴. Activation Function

۵. Bias

1. Multicollinearity

2. Structure

3. Architecture

جدول ۳. نتایج آزمون همبستگی پیرسون با سطح اطمینان ۹۵ درصد روی داده‌های پژوهش

Variables	Time of day	Depth from pavement surface	Air temperature	Average wind speed	Average wind direction	Maximum wind speed	Maximum wind direction	Maximum air humidity	Minimum air humidity	Solar radiation	Depth temperature of asphalt layer
Time of day	1	-0.001	0.119	0.123	0.008	0.138	-0.000	-0.292	-0.303	0.112	0.138
Depth from pavement surface	-0.001	1	-0.035	0.005	0.014	0.006	0.013	0.002	0.005	-0.012	-0.057
Air temperature	0.119	-0.035	1	-0.026	-0.131	0.046	-0.124	-0.186	-0.231	0.375	0.952
Average wind speed	0.123	0.005	-0.026	1	0.195	0.968	0.182	-0.277	-0.255	0.219	-0.090
Average wind direction	0.008	0.014	-0.131	0.195	1	0.193	0.826	-0.088	-0.079	0.035	-0.126
Maximum wind speed	0.138	0.006	0.046	0.968	0.193	1	0.184	-0.306	-0.302	0.276	-0.010
Maximum wind direction	-0.000	0.013	-0.124	0.182	0.826	0.184	1	-0.072	-0.067	0.024	-0.119
Maximum air humidity	-0.292	0.002	-0.186	-0.277	-0.088	-0.306	-0.072	1	0.969	-0.542	-0.240
Minimum air humidity	-0.303	0.005	-0.231	-0.255	-0.079	-0.302	-0.067	0.969	1	-0.602	-0.289
Solar radiation	0.112	-0.012	0.375	0.219	0.035	0.276	0.024	-0.542	-0.602	1	0.416
Depth temperature of asphalt layer	0.138	-0.057	0.952	-0.090	-0.126	-0.010	-0.119	-0.240	-0.289	0.416	1

Table 3. Results of the Pearson correlation test with a 95% significant level on the collected data

شکل ۲. ساختار مدل شبکه عصبی پس انتشار [10]

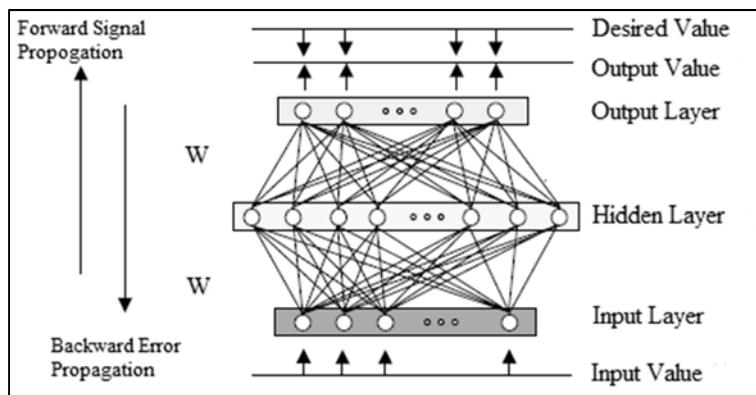


Fig. 2. Structure of the BP neural network model [10]

به کمترین می‌رساند [27]. برای محاسبه خطای مقادیر خروجی پیش‌بینی شده با مقادیر اندازه‌گیری مقایسه می‌شود و بدین ترتیب وزن‌های ارتباطی بین ورودی‌ها و خروجی مدل با پس انتشار بروزرسانی می‌شود [28].

جدول ۴. تعداد نورون‌ها و مقایسه مقدار

Number of neurons	RMSE	Coefficient of determination (R^2)
5	2.93	0.96
10	2.46	0.96
15	2.42	0.96
17	2.38	0.96
20	2.33	0.96

Table 4. The RMSE associated with the number of neurons

هر نورون در لایه پنهان با توجه به مقادیر ورودی و خروجی، توابع جمع و انتقال خود را دارد (شکل ۲). تابع فعال‌سازی رابطه بین لایه‌های ورودی‌ها و خروجی را تعیین

معیار انتخاب تعداد مناسب و بهینه نورون‌ها و یا به عبارتی دیگر معیار آموزش شبکه عصبی، دستیابی به کمترین MSE تا جایی که آموزش بیش از حد اتفاق نیفتاد، است. در این راستا الگوریتم Validation برای جلوگیری از Overfitting در سیستم آموزش شبکه عصبی MATLAB تعبیه شده است. در جدول (۴) تعداد نورون‌های انتخاب شده و مقدار RMSE مدل در هر یک از آنها ارائه شده است. همان‌گونه که مشاهده می‌شود کمترین مقدار RMSE در تعداد ۲۰ نورون در لایه پنهان به دست آمده است. فرآیند آموزش، ماتریس‌های وزن را تولید و مشخص می‌کند که در رابطه‌های بین لایه‌ها ذخیره می‌شود (شکل ۲). در این فرآیند، وزن‌های ارتباط بین لایه‌ها تنظیم می‌شود و در پیان میانگین خطای کلی را با استفاده از الگوریتم پس انتشار

۵۔ نتایج و بحث

پس از تعیین ساختار مدل شبکه عصبی و انجام آزمون همبستگی پیرسون و انتخاب متغیرهای نهایی برای مدل سازی، مجموعه داده‌های موجود به سه بخش تقسیم شده است. ۷۰ درصد داده‌ها برای آموزش، ۱۵ درصد برای آزمایش و ۱۵ درصد باقی مانده برای اعتبارسنجی مدل توسعه یافته تخصیص یافته است. بنابراین از کل ۳۴۶۷۶ مجموعه داده، ۲۴۲۷۳ مجموعه برای ساخت مدل شبکه عصبی در نظر گرفته شده است. در جدول (۵) خلاصه اطلاعات مدل توسعه یافته در این پژوهش ارائه شده است. همچنین جدول (۶) متغیرهای ورودی و خروجی مدل، واحد هر یک و نیز مقدار کمینه و پیشنه آنها را ارائه می‌کند.

جدول ۵. خلاصه مشخصات مدل شبکه عصبی توسعه یافته در این پژوهش

Parameter	Value/Description
Network type	MLP
Error correction algorithm	Back-Propagation (BP)
Training function	Levenberg-Marquart
Number of hidden layers	1
Number of neurons in each layer	20
Learning rate	0.001
Activation function	Tangent-Sigmoid
Iteration	1000
Validation check	10
Goal error	1×10^{-7}
Train data points	24273
Test data points	5201
Validation data points	5201

Table 5. Summary of the details of the developed neural network model in this study

جدول ۶. متغیرهای ورودی و خروجی مدل توسعه یافته به همراه محدوده دادهای ملائمه‌شونده

Variable	Unit	Minimum	Maximum
Input			
Thickness of asphalt layer	m	0.1067	0.1067
Time of the day	Decimal	1	24
Depth from pavement surface	m	0.025	0.840
Air temperature	°C	-23.5	30.8
Average wind speed	m/s	0	13.5
Average wind direction	Degree	0	360
Minimum air humidity	%	8.7	110
Solar radiation	W/m ²	0	1064
Output			
Depth temperature of asphalt layer	°C	-13.3	46.6

Table 6. Input and output variables of the developed model with the range of modelling data

در شکل (۴)، نمودار دمای عمق لا یه های آسفلاتی اندازه‌گیری شده و مقادیر پیش‌بینی متناظر با آن که توسط مدل

می‌شود [10, 28]. محاسبه از رابطه ۱ با استفاده از خروجی تابع می‌کند.

$$y = O_j = f(b + \sum_{i=1}^n x_i w_i) \quad (1)$$

که در این رابطه O_0 خروجی نورون لایه پنهان زام، f تابع انتقال، x_i ورودی زام، w_i وزن ارتباط بین ورودی زام و خروجی زام، و b بایاس است.

تابع انتقال تانژانت سیگموید۱ به دلیل پوشش غیرخطی آن و نیز توانایی اجتناب از مقادیر خیلی بزرگ، در این پژوهش استفاده شده است. رابطه ۲ این تابع را رائمه می‌کند [10, 28].

$$f(y) = \frac{2}{1+e^{-2(y)}} - 1 \quad (\textcircled{y})$$

که در این رابطه y خروجی برای تابع انتقال و a ضریب یا شیب تابع سیگموید است. لایه نهایی در ساختار شبکه عصبی، لایه خروجی است که نتیجه پردازش ارائه شده توسط لایه پنهان را تولید می‌کند. نمودار کلی چگونگی کار مدل شبکه عصبی، بس انتشار، در شبکا (۳) ارائه شده است.

شکل ۳. نمودار کلی نحوه کار مدل شبکه عصبی پس از شار [13]

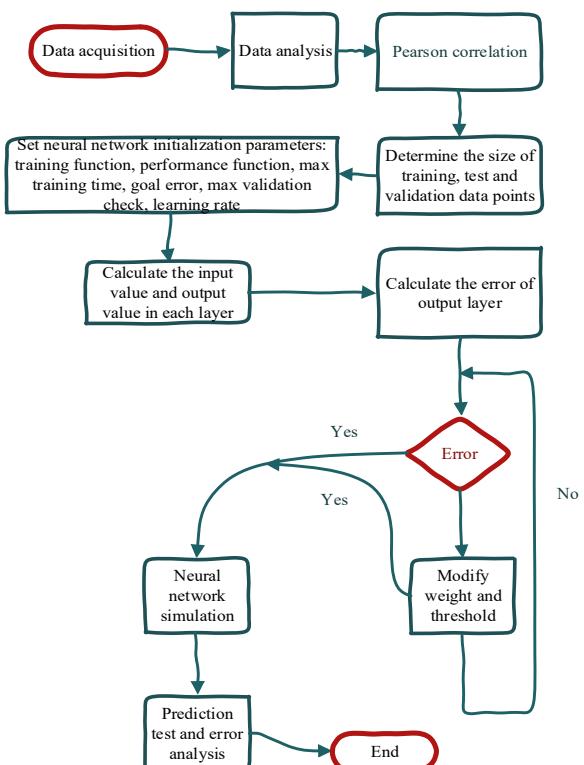


Fig. 3. Flow diagram of Back-Propagation Neural Network model [13]

پارامترهای ورودی (زمان روز، میانگین ساعتی دمای هوا و ...) و خروجی (میانگین ساعتی دمای عمق لایه‌های آسفالتی) برای مدل سازی رگرسیون دقیقاً همان پارامترهای استفاده شده برای توسعه مدل شبکه عصبی پس انتشار هستند. مدل سازی رگرسیونی غیرخطی انجام شده و همه عبارت‌های مدل توسعه یافته- P -value کمتر از 0.05 دارند که نشان می‌دهد سطح معنی‌داری با احتمال بالای 95 درصد با متغیر وابسته دارند. P -value بیانگر این است که آیا هر یک از عبارت‌های مدل در پیش‌بینی متغیر وابسته (دمای عمق لایه‌های آسفالتی) تاثیرگذار هستند یا خیر. اگر P -value کمتر از 0.05 باشد، مقدار آن عبارت تاثیرگذار در نظر گرفته می‌شود. اعتبارسنجی و مقایسه مدل‌ها، توسط سه معیار دقت با محاسبه ضریب تعیین (R^2) نسبت به خط برابری، بایاس پیش‌بینی با محاسبه شیب و عرض از مبدأ خط روند و نیز خطای مدل با محاسبه RMSE انجام شده است. هر چه مقدار ضریب تعیین به یک نزدیک باشد، مدل دقت بالاتری دارد. از سوی دیگر هر چه شیب خط روند به یک و همچنین عرض از مبدأ این خط به صفر نزدیک باشد، مدل دارای بایاس پیش‌بینی کمتری خواهد بود. همچنین هر چه مقدار RMSE به صفر نزدیک‌تر باشد، مدل خطای کمتری دارد [۲۹]. مدل رگرسیونی نهایی توسعه یافته برای پیش‌بینی میانگین ساعتی دمای عمق لایه‌های آسفالتی به صورت رابطه ۳ است.

در این رابطه T_d میانگین ساعتی دمای عمق لایه آسفالتی، درجه سلسیوس؛ x_1 زمان روز، اعشار زمان؛ x_2 عمق مورد نظر از سطح روسازی، متر؛ x_3 میانگین ساعتی دمای هوا، درجه سلسیوس؛ x_4 میانگین سرعت باد، متر بر ثانیه؛ x_5 میانگین جهت باد، درجه؛ x_6 کمینه رطوبت هوا، درصد؛ و x_7 کل تابش آفتاب، وات بر متر مربع است. بر اساس مدل توسعه یافته، میانگین ساعتی دمای عمق لایه‌های آسفالتی می‌تواند پیش‌بینی شود.

شبکه عصبی توسعه یافته ارائه شده است. همان‌گونه که در این شکل مشاهده می‌شود، نمودار مقادیر پیش‌بینی و مقادیر اندازه‌گیری هماهنگی و همپوشانی بسیار خوبی با یکدیگر دارند. همچنین در شکل (۵)، نمودار عملکرد مدل و روند کاهش خطای عملکرد در طی فرآیند آموزش شبکه عصبی ارائه شده است. همان‌گونه که مشاهده می‌شود، با افزایش تکرار رفت و برگشت (پس انتشار) خطای شبکه کاهش می‌یابد. شبکه عصبی در ۱۱۲ تکرار کار خود را به اتمام رسانیده و بهترین عملکرد آن (خطای MSE برابر $4/90$) در ۱۰۲ین تکرار به دست آمده است. نمودار مقادیر میانگین ساعتی دمای عمق لایه‌های آسفالتی پیش‌بینی شده در برابر مقادیر اندازه‌گیری در شکل (۶ الف تا d) به ترتیب برای داده‌های آموزش، آزمایش، اعتبارسنجی و کل داده‌های شبکه ارائه شده است. همان‌گونه که انتظار می‌رود مدل مقادیر پیش‌بینی را در امتداد خط برابری $(Y=T)$ ارائه کرده است که این نشان دهنده عملکرد مناسب مدل شبکه عصبی توسعه یافته در این پژوهش برای تعیین دمای عمق لایه‌های آسفالتی است.

شکل ۵. نمودار عملکرد مدل شبکه عصبی

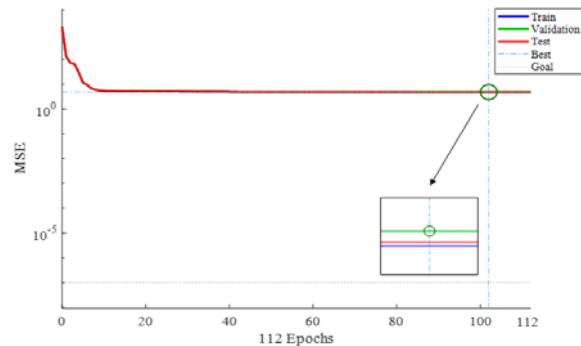


Fig. 5. Preformance of the developed neural network model

۶. اعتبارسنجی و مقایسه با مدل رگرسیونی غیرخطی

برای اعتبارسنجی، مقایسه‌ای بین نتایج مدل توسعه یافته و مدل رگرسیونی غیرخطی درجه دوم گام به گام در پیش‌بینی دمای عمق لایه‌های آسفالتی شده است. مدل رگرسیونی با استفاده از نرم‌افزار Minitab نسخه ۱۹ توسعه یافته است. داده‌ها و

شکل ۶. مقادیر پیش‌بینی در برابر مقادیر اندازه‌گیری دمای عمق لایه‌های آسفالتی: a) داده‌های آموزش شبکه، b) داده‌های آزمایش شبکه، c) داده‌های اعتبارسنجی شبکه، و d) کل داده‌های شبکه

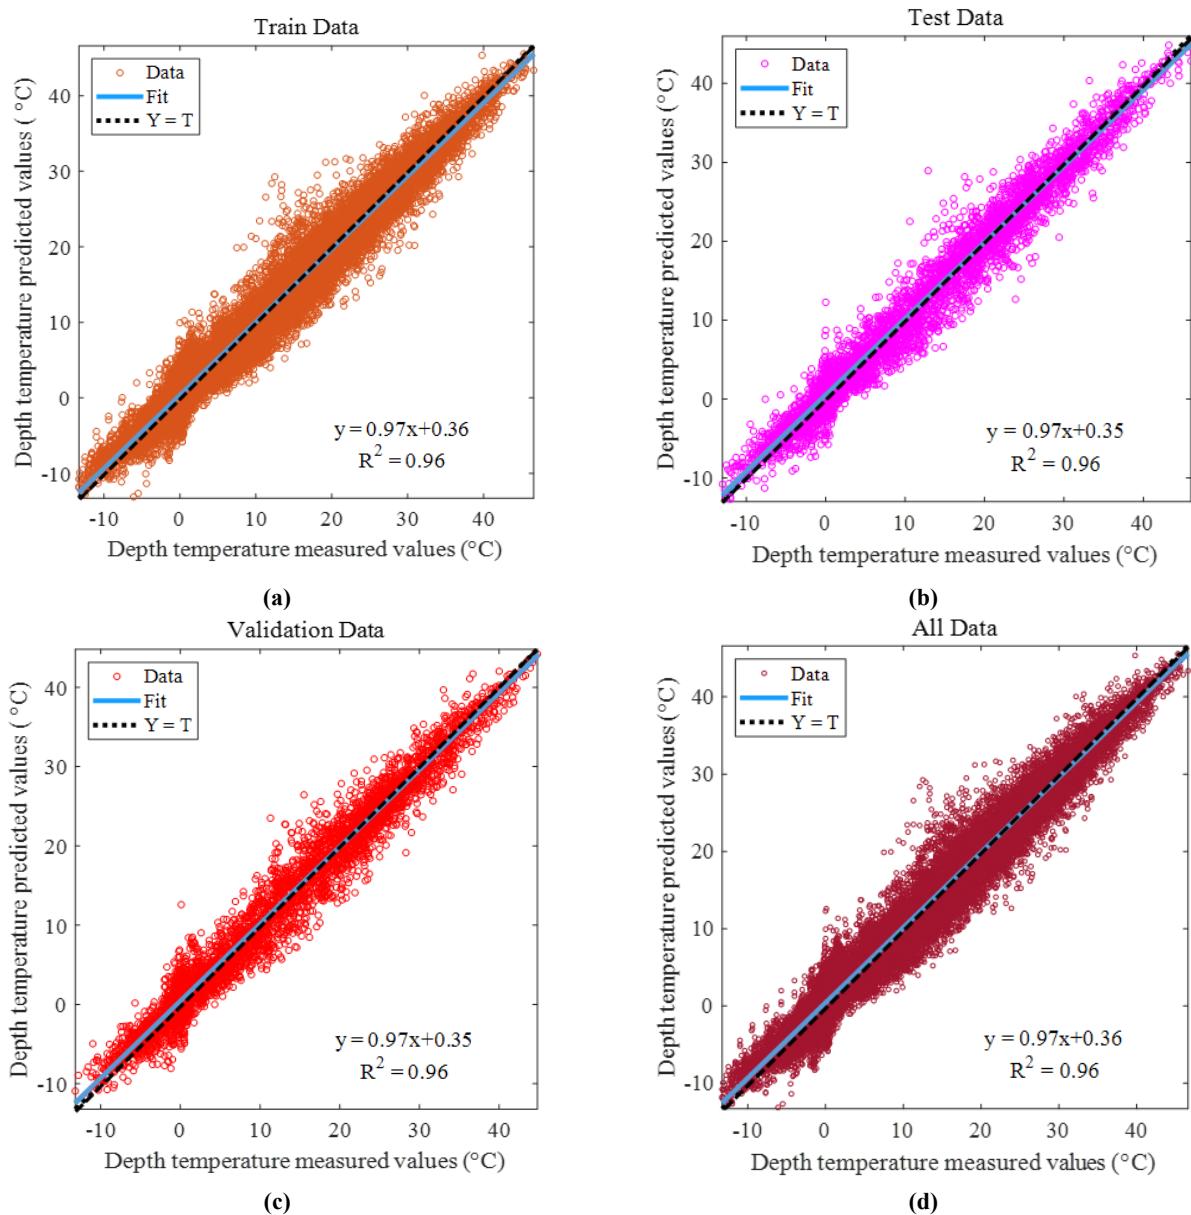


Fig. 6. Predicted versus measured values of depth temperature of asphalt layers: a) Train data, b) Test data, c) Validation data, and d) All data

$$\begin{aligned}
 T_d = & 2.792 - 0.0348 x_1 - 9.45 x_2 + 0.98732 x_3 - 1.2115 x_4 + 0.0642 x_6 - 0.000815 x_7 \\
 & + 0.010099 x_1^2 + 487.1 x_2^2 + 0.009742 x_3^2 + 0.03971 x_4^2 - 0.000339 x_6^2 \\
 & + 0.00004 x_7^2 - 0.530 x_1 x_2 + 0.001965 x_1 x_3 + 0.01689 x_1 x_4 - 0.003061 x_1 x_6 \\
 & + 0.001377 x_1 x_7 - 1.0485 x_2 x_3 - 1.468 x_2 x_4 - 1.1797 x_2 x_6 + 1.16049 x_2 x_7 \\
 & - 0.03137 x_3 x_4 - 0.000099 x_3 x_7 + 0.00451 x_4 x_6 + 0.001198 x_4 x_7 \\
 & - 0.000058 x_6 x_7
 \end{aligned} \quad (3)$$

۷. نتیجه‌گیری

در این پژوهش پیش‌بینی دمای عمق لایه‌های آسفالتی بر اساس داده‌های جمع‌آوری شده به وسیله ایستگاه‌های خودکار آب و هوایی (AWS) و برنامه پایش فصلی (SMP) که در پایگاه داده LTPP در دسترس هستند، انجام شده است. برای مدل سازی از مدل شبکه عصبی پر سپترون چندلایه استفاده شده است. همچنین برای اعتبارسنجی و ارزیابی دقت مدل توسعه یافته، نتایج آن با مدل رگرسیونی درجه دوم مقایسه شده است. مهم‌ترین نتایج به دست آمده شامل موارد زیر است:

- مدل توسعه یافته می‌تواند برای مناطقی که ویژگی‌های آب و هوایی آن در محدوده داده‌های استفاده شده در این پژوهش که در جدول (۶) ارائه شده است، مورد استفاده قرار گیرد. همچنین در صورت دستیابی به داده‌های بی‌شتر، مدل شبکه عصبی مصنوعی توسعه یافته می‌تواند با داده‌های بیشتر دوباره آموزش داده شود و استفاده از آن برای مناطق پیشتری توسعه یابد. با توجه به محدوده داده‌های استفاده شده، این مدل می‌تواند در مناطق مختلف کشور (مناطق شمالی و شمال غربی) که دارای شرایط آب و هوایی مشابه هستند با دقت خوبی مورد استفاده قرار گیرد؛
- دمای هوا با توجه به نتایج آزمون همبستگی پیرسون دارای بیشترین تاثیر روی دمای عمق لایه آسفالتی (همبستگی ۹۵/۲ درصد) است. به عبارتی دیگر این فاکتور رابطه مستقیم و نزدیکی با دمای عمق لایه آسفالتی دارد؛ متغیرهای بیشینه سرعت باد، بیشینه جهت باد و بیشینه میزان رطوبت هوا برای جلوگیری از چندخطی بودن در مدل، از بانک داده حذف شده‌اند؛
- ارزیابی عملکرد مدل توسعه یافته نشان می‌دهد که این مدل می‌تواند دمای عمق لایه‌های آسفالتی را با دقت بسیار خوب ($R^2 = ۰.۹۶$)، بایاس و خطای بسیار کم نسبت به مدل رگرسیونی درجه دوم پیش‌بینی نماید. بنابراین مدل از اعتبار بالایی برای پیش‌بینی دمای عمق لایه‌های آسفالتی در محل برخوردار است؛
- عملکرد مدل توسعه یافته برای پیش‌بینی دمای عمق لایه‌های آسفالتی دارای محدودیت‌هایی است. اگرچه برای انجام

پارامترهای ارزیابی عملکرد دو مدل شبکه عصبی و رگرسیونی درجه دوم در جدول (۷) ارائه شده است. همان طوری که در این جدول مشاهده می‌شود؛ هر دو مدل مقدار ضریب تعیین (R^2) به ترتیب برابر ۰/۹۵ و ۰/۹۶ را دارد. بنابراین می‌توان گفت هر دو مدل دارای دقت بسیار خوبی هستند و مدل شبکه عصبی دارای دقت بالاتری نسبت به مدل رگرسیونی است.

شیب و عرض از مبدأ خط روند مقادیر پیش‌بینی و مقادیر اندازه‌گیری برای مدل شبکه عصبی به ترتیب برابر ۰/۹۷ و ۰/۳۵ است؛ در حالی که این مقادیر برای مدل رگرسیونی به ترتیب برابر ۰/۹۴ و ۰/۶۳ است. این مقایسه نیز برتری مدل شبکه عصبی توسعه یافته در پژوهش حاضر را نسبت به مدل رگرسیونی درجه دوم در بایاس کم پیش‌بینی دمای عمق لایه‌های آسفالتی را نشان می‌دهد. همچنین مقایسه مقادیر خطای RMSE نیز نشان می‌دهد مدل شبکه عصبی با مقدار ۲/۱۸ نسبت به مدل رگرسیونی با مقدار ۲/۸۳ دارای خطای کمتری در پیش‌بینی دمای عمق لایه است. بنابراین با بررسی معیارهای ارزیابی هر دو مدل مطابق جدول (۷)، می‌توان نتیجه گرفت مدل شبکه عصبی توسعه یافته دارای دقت بسیار خوب، بایاس و خطای پیش‌بینی کمتری نسبت به مدل رگرسیونی درجه دوم است. از این رو می‌توان نتیجه گرفت این مدل می‌تواند با عملکرد مناسب برای پیش‌بینی دمای عمق لایه‌های آسفالتی به جای انجام آزمایش در محل در تحلیل و ارزیابی روسازی‌های آسفالتی استفاده شود.

جدول ۷. مقایسه پارامترهای ارزیابی عملکرد هر دو مدل

Evaluation parameter	BP neural network model	Non-Linear regression-based model
R^2 (Y=T)	0.96	0.95
Trend line	0.97	0.94
Slope	0.35	0.63
RMSE	2.18	2.83

Table 7. Comparison of model performance evaluation results

transportation research: differences, similarities and some insights. *Transportation Research Part C*, **19**(3), 387-399

- [12] Golshani N., Shabanzpour R., Mohammadifard S., Derriblir S. & Mohammadian A. 2017 comparison of artificial neural networks and statistical copula-Based joint models. *Transportation Research Board*, (17), 96th Annual Meeting, Washington, D.C., USA.

- [13] Xu B., Han-Cheng D. & Li L. 2017 Temperature prediction model of asphalt pavement in cold regions based on an improved BP neural network. *Applied Thermal Engineering*, **120**, 568-580.

- [14] Matic B., Matic D., Sremac S., Radovic N. & Vidikant P. 2014 A model for the pavement temperature prediction at specified depth using neural networks. *Metalurgija*, **53**(4), 665-667.

- [15] Godoy J., Haber R., Muñoz J.J., Matía F. & García Á. 2018 Smart sensing of pavement temperature based on low-cost sensors and V2I communications. *Sensors (Basel)*, **18**(7).

- [16] Stubstad R.N., Baltzer S., Lukinen E.O. & Ertman-Larsen H.J. 1994 Prediction of AC mat temperatures for routine load-deflection measurements. In *4th International Conference on the Bearing Capacity of Roads and Airfields*, Minneapolis, Minnesota, USA.

- [17] Lukinen E.O., Chunhua H. & Skok E.L. 1998 Probabilistic method of asphalt binder selection based on pavement temperature. *Journal of the Research Board*, **1609**(1), 12-20.

- [18] Tabatabaie S.A., Ziari H. & Khalili M. 2008 Modeling temperature and resilient modulus of asphalt pavements for tropic zones of Iran. *Asian Journal of Scientific Research*, **1**(6), 579-588.

- [19] Hassan H.F., Al-Nuaimi A.S., Taha R. & Jafar T.M.A. 2005 Development of asphalt pavement temperature models for Oman. *Journal of Engineering Research*, **2**(1), 32-42.

- [20] Diefenderfer B.K., Al-Qadi I.L. & Diefenderfer S.D. 2006 Model to predict pavement temperature profile: development and validation. *Journal of Transportation Engineering*, **132**(2).

- [21] Solatifar N., Abbasghorbani M., Kavussi A. & Sivilevičius H. 2018 Prediction of depth temperature of asphalt layers in hot climate areas. *Journal of Civil Engineering and Management*, **24**(7), 516-525.

- [22] Sedighian-Fard M. & Solatifar N. 2020 Analysis of regression-based models for

مدل‌سازی در این پژوهش از ۳۴۶۷۶ مجموعه داده استفاده شده است؛ با این حال برای افزایش گستره عملکرد و جامعیت مدل، می‌توان داده‌های بیشتر و همچنین فاکتورهای دیگری مانند مشخصات مصالح و ... را بررسی و تحلیل کرد.

۸. مراجع

- [1] Hen-Cheng D., Lin-Hua, H. & Xu, B. 2015 Experimental investigation on skid resistance of asphalt pavement under various slippery conditions. *Int. J. Pavement Eng.*, **18**(6), 485-499.
- [2] Zhang H. 2012 Study on grades of freeway meteorological disasters by risk matrix. *Appl. Mech. Mater.*, **178**, 2788-2792.
- [3] Shao L., Park S.W. & Kim Y.R. 1997 Simplified procedure for prediction of asphalt pavement subsurface temperatures based on heat transfer theories. *Transportation Research Record*, **1568**, 114-123.
- [4] Kim Y.R. & Lee Y.C. 1995 Interrelationships among stiffnesses of asphalt-aggregate mixtures. *Journal of the Association of Asphalt Paving Technologists*, **64**, 575-609.
- [5] Park H.M., Kim Y.R. & Park S. 2002 Temperature correction of multiload-level falling-weight deflectometer deflections. *Transportation Research Record*, **1806**, 3-8.
- [6] Petersen C. & Mahura A. 2012 Influence of the pavement type on the road surface temperature. In *16th Int. Road Weather Conf.*, May (23-25), Helsinki, Finland.
- [7] Irwin R.S. & Boston I. 2005 Rigid and flexible pavement design. *Journal of the Transportation Research Board*, (1919), Washington, D.C., USA.
- [8] Arifuzzaman M. 2017 Advanced ANN prediction of moisture damage in CNT modified asphalt binder. *Soft Computing in Civil Engineering*, **1**(1), 1-11.
- [9] Naderpour H., Nagai K., Fakharian P. & Haji M. 2019 Innovative models for prediction of compressive strength of FRP-confined circular reinforced concrete columns using soft computing methods. *Composite Structures*, **215**, 69-84.
- [10] Solatifar N. & Lavasani S.M. 2020 Development of an artificial neural network model for asphalt pavement deterioration using LTPP data. *Journal of Rehabilitation in Civil Engineering*, **8**(1), 121-132.
- [11] Karlaftis M.G. & Vlahogianni E.I. 2011 Statistical methods versus neural networks in

: تابش آفتاب $Solar, SR, N_0$
 : دمای سطح لایه آسفالتی Sur, T_{sur}, IR
 : زمان روز t, t_d
 : دمای عمق لایه آسفالتی T, T_d
 دما در عمق ۲۰ میلیمتری روسازی $T_{20\ mm}$
 : حداکثر دمای روزانه هوا $T_a\ (or\ air)\ max$
 : حداقل دمای روزانه هوا $T_a\ (or\ air)\ min$
 : حداکثر دمای هوا T_{air}
 میانگین دمای هوای روز قبل $T_{ave}, T_{(1-day)}$
 تاریخچه میانگین دمای ماهانه هوا T_m
 : حداکثر دمای روزانه روسازی $T_p\ (Daily)\ max$
 : حداقل دمای روزانه روسازی $T_p\ (Daily)\ min$
 دمای نیمه عمق لایه آسفالتی T_{pave}
 : میانگین دمای هوا \bar{T}_{aN}
 سرعت باد W

- prediction of depth temperature of asphalt layers – a review. *Amirkabir Journal of Civil Engineering*, In press. (In Persian)
- [23] Gedafa D.S., Hossain M. & Romanoschi S.A. 2014 Perpetual pavement temperature prediction model. *Journal of Road Materials and Pavement Design*, **15**(1), 55–65
- [24] Li Y., Liu L. & Sun L. 2018 Temperature predictions for asphalt pavement with thick asphalt layer. *Construction and Building Materials*, **160**, 802-809.
- [25] Asefzadeh A., Hashemian L. & Bayat A. 2017 Development of statistical temperature prediction models for a test road in Edmonton, Alberta, Canada. *Int. J. Pavement Research and Technology*, **10**(5), 369-382.
- [26] Rafiq M.Y., Bugmann G. & Easterbrook D.J. 2001 Neural network design for engineering applications. *Computers & Structures*, **79**(17), 1541-1552.
- [27] Zhang G., Patuwo B.E. & Hu M.Y. 1998 Forecasting with artificial neural networks: the state of the art. *Int. J. Forecasting*, **14**(1), 35-62.
- [28] Alharbi F. 2018 Predicting pavement performance utilizing artificial neural network (ANN) models. Ph.D. Thesis, Iowa State University, USA.
- [29] Solatifar N. & Abbasghorbani M. 2019 Calibration of regression models based on viscoelastic principles for prediction of dynamic modulus of in-service asphalt layers. *Journal of Transportation Engineering*, In press. (In Persian)

علامه و نمادهای اختصاری:

: دمای هوا Air
 : درصد قیر مخلوط آسفالتی BP
 : نوع قیر BT
 : سطح تراکم $comp$
 : شرایط روسازی (خیس، خشک و ...) $Condition$
 : جهت باد $Dir.$
 : رطوبت هوا H
 : زمان روز در سیستم ۱۸ ساعته hr_{18}
 : عمق از سطح روسازی آسفالتی P_d, d, D
 : تابش روزانه آفتاب R_s
 : میزان بارش باران $Rain$

Artificial Neural Network Model for Prediction of Depth Temperature of Asphalt Layers Using LTPP Data

Mohammad Sedighian-Fard¹, Nader Solatifar^{2,*}

1- M.Sc. Student, Department of Civil Engineering, Urmia University, Urmia, Iran

2- Assistant Professor, Department of Civil Engineering, Urmia University, Urmia, Iran

n.solatifar@urmia.ac.ir

Abstract

One of the critical environmental factors that affect the deformation of flexible pavements is the depth temperature of asphalt layers. This is due to the viscoelastic behavior of the asphalt mixtures. The stiffness of the asphalt layers has a significant effect on the structural capacity of flexible pavements. This property is a function of the asphalt layer temperature and changes daily and seasonally. As the temperature increases, the stiffness of the asphalt layer decreases, which increases the stress in the base and subbase layers of the pavement. Therefore, the pavement response to the applied loads is affected by the depth temperature. Hence, the depth temperature of asphalt layers is one of the most important and main factors in the analysis, design, and rehabilitation process of flexible pavements. Some predictive models have been developed to determine the depth temperature of asphalt layers in pavement maintenance and rehabilitation activities. These models, as an alternative to field and laboratory measurements of this factor, are low-cost, rapid, and simple methods to determine the depth temperature of asphalt layers. It should be noted that these models are based on the limited field and laboratory data, therefore, there is a need for developing new models for prediction of the depth temperature of asphalt layers in different traffic and climatic conditions. The objective of this study is to develop a model for predicting the depth temperature of asphalt layers based on climatic data. In recent years, Artificial Neural Networks (ANNs) have shown good performance as a useful tool for modeling physical events. The modeling method used in this study is a Back-Propagation Neural Network (BPNN) model that predicts the average hourly depth temperature of asphalt layers based on several variables, including the time of the day, desired depth from the pavement surface, average hourly air temperature, average speed and direction of the wind, minimum air humidity and total solar radiation. Data was extracted from the Long-Term Pavement Performance (LTPP) database. After extracting and preparing raw data, all the needed data were acquired from different data tables and linked to each other in a database. As a case study, data points collected from pavements in Ohio, USA, has been used for modeling. Also, to ascertain the presence or absence of multicollinearity between independent variables, the Pearson correlation test has been conducted. For this reason, the maximum speed and direction of the wind and maximum air humidity parameters were removed from the data set. According to the results of the Pearson correlation test, the average hourly air temperature has the most powerful impact on the average hourly temperature of the asphalt layer depth (correlation=95.2%). After training and testing the neural network, the performance of the developed model has been evaluated, and results were compared with a non-linear quadratic regression model. The results show that the developed model is more accurate than the regression-based model. In addition, the ability of the developed model in predicting the depth temperature of asphalt layers based on existing climatic data with a very good prediction accuracy ($R^2=0.96$) and very low bias and error has been shown. Furthermore, the performance of the developed model has some restrictions for the prediction of depth temperature of asphalt layers. Other factors such as material characteristics can be scrutinized and applied to enhance the performance and applicability of the model.

Keywords: Depth Temperature of Asphalt Layers, Temperature Prediction Model, Artificial Neural Networks (ANNs), Long-Term Pavement Performance (LTPP).