

پیش‌بینی شاخص خودترمیمی مخلوط‌های آسفالتی با استفاده از شبکه عصبی

مصنوعی

مهسا روحی فریمان، دانشجوی کارشناسی ارشد راه و ترابری، دانشکده عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران

سید علی حسینی (مسئول مکاتبات)، استادیار، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران

E-mail: ahosseini@shahroodut.ac.ir

عباس محمدی، مربی، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران

پذیرش: ۱۴۰۰/۱۲/۲۱

دریافت: ۱۴۰۰/۰۶/۱۶

چکیده

جاده‌ها از سرمایه‌های مهم هر کشور محسوب می‌شوند و سالانه بخش زیادی از بودجه کشور صرف عملیات ترمیم و نگهداری برای رفع ترک خوردگی‌ها می‌شود. یکی از عواملی که می‌تواند در افزایش عمر مفید روسازی آسفالتی مؤثر باشد، پتانسیل خودترمیمی مخلوط‌های آسفالتی است. در این پژوهش با در نظر گرفتن عوامل مؤثر بر شاخص خودترمیمی (مانند نوع افزودنی، درصد افزودنی، دانه‌بندی مخلوط آسفالتی، نوع قیر، چرخه ترمیم ترک، نوع گرمایش و زمان گرمایش)، با استفاده از شبکه عصبی مدلی جهت پیش‌بینی این شاخص ارائه شده است. بدین منظور از شبکه عصبی چندلایه (MLP)، شبکه عصبی چندلایه بهینه‌سازی شده با الگوریتم ازدحام ذرات (PSO)، شبکه عصبی شعاعی پایه (RBF) و تجزیه و تحلیل آماری با نرم افزار SPSS استفاده شده و نتایج این روش‌ها با یکدیگر مقایسه شدند. به منظور صحت سنجی مدل، شاخص خود ترمیمی نمونه آسفالتی حاوی ۶۰ درصد سرباره در آزمایشگاه محاسبه شده و با نتایج بدست آمده از مدل مقایسه و ارزیابی شده است. نتایج نشان داد، شبکه عصبی چندلایه (MLP) با ضریب همبستگی برابر با ۰٫۹۶ نسبت به دیگر روش‌ها عملکرد بهتری در زمینه پیش‌بینی شاخص خودترمیمی دارد و برای بررسی قدرت تعمیم شبکه عصبی با استفاده از داده‌هایی که در طول مدلسازی بکار گرفته نشدند، شبکه‌های عصبی چندلایه (MLP) و شعاعی پایه (RBF) بهترین عملکرد را دارند.

واژه‌های کلیدی: خود ترمیمی، شبکه عصبی مصنوعی، ضایعات فلزی، گرمایش میکروویو، گرمایش القایی

۱. مقدمه

آسفالتی با شاخص خود ترمیمی (درصد مقاومت اولیه بازیابی

شده) تعیین می‌شود.

در این مقاله، پس از بررسی تحقیقات گذشته پارامترهایی که بر شاخص خودترمیمی اثر دارند، مشخص شدند و این پارامترها به عنوان متغیر برای ایجاد مدل شبکه عصبی در نظر گرفته شدند. پارامترهایی که به عنوان ورودی مدل در نظر گرفته شدند، عبارتند از: ابعاد نمونه آزمایش، روش تراکم نمونه، دانه بندی مخلوط آسفالتی، درصد افزودنی‌ها (براده آهن، RAP^1 ، سرباره فولاد و الیاف فولادی)، نوع قیر، چرخه ترمیم ترک، نوع گرمایش و زمان گرمایش. سپس ساخت مدل با استفاده از داده‌های آزمایشگاهی موجود در مقالات مطالعه شده انجام شد. پیش بینی شاخص خودترمیمی با استفاده از شبکه عصبی چندلایه (MLP^2)، شبکه عصبی چندلایه با الگوریتم بهینه ساز ازدحام ذرات (PSO^3)، شبکه عصبی شعاعی پایه (RBF^4) و تجزیه و تحلیل آماری با نرم افزار $SPSS^5$ انجام شد و نتایج این روش‌ها با یکدیگر مقایسه شدند. همچنین نمونه‌هایی با جایگزینی ۶۰ درصد سرباره فولاد به جای سنگدانه‌های درشت در آزمایشگاه ساخته شدند و نتایج خودترمیمی بدست آمده در آزمایشگاه با نتایج پیش‌بینی شده توسط شبکه‌های عصبی مقایسه گردید.

۲. شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی با الهام از شبکه نورون‌های مغز انسان، سعی در توسعه پردازش اطلاعات دارد. فرآیند یادگیری شبکه عصبی درست مثل مغز انسان است [Taherkhani et al.2012]. شبکه عصبی (ANN^6) از تعداد زیادی عناصر پردازشی به نام نورون تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کنند و توسط سیناپس‌ها (ارتباطات الکترومغناطیسی) اطلاعات را منتقل می‌کنند. نورون یک واحد اساسی سیستم عصبی و یک واحد پردازشگر ساده است که سیگنال را از دیگر نورون‌ها دریافت کرده و پردازش می‌کند،

روسازی‌های آسفالتی (انعطاف‌پذیر) یکی از پرکاربردترین روسازی‌های مورد استفاده در جهان هستند. به عنوان مثال، از ۴,۳ میلیون کیلومتر راه در ایالات متحده، ۹۴ درصد از آن‌ها روسازی آسفالتی دارند [Huang.2004]، در حالی که در اتحادیه اروپا بیش از ۹۰ درصد از شبکه راه‌ها آسفالتی هستند [EAPA.2017]. به دلیل شرایط آب و هوایی، عدم انتخاب مصالح مناسب و بارهای ترافیکی، مقاومت و دوام روسازی‌های آسفالتی با گذشت زمان کاهش می‌یابد و منجر به ترک خوردگی آن‌ها می‌شود [Fakhri et al.2019]. یکی از شایع‌ترین خرابی‌های روسازی آسفالتی، ترک خوردگی است و در اثر عوامل مختلفی مانند خستگی، تغییر دما و پیرشدگی قیر ایجاد می‌شود [Norambuena-Contreras et al.2019]. قیر یک ماده بسیار ویسکوز در دمای محیط است، در دمای بالا ویسکوزیته آن کاهش یافته، در بین ریزترک‌ها حرکت کرده و آن‌ها را پر می‌کند [Kavousi et al.2019]؛ بنابراین اگر در زمان استراحت، دمای قیر به ۳۰ تا ۷۰ درجه سانتی‌گراد برسد، ترک‌ها خود به خود ترمیم می‌شوند؛ زیرا با افزایش دما، ویسکوزیته قیر کاهش یافته و در ریز ترک‌های باز جریان می‌یابد [González et al.2018].

یکی از روش‌های مؤثر جهت تسریع در روند خودترمیمی مخلوط‌های آسفالتی، استفاده از افزودنی‌های فلزی است. ضایعات فلزی (به طور معمول الیاف فولادی و براده آهن) با جذب انرژی حرارتی بیشتر نسبت به قیر و سنگدانه‌ها، باعث افزایش هدایت الکتریکی مخلوط‌ها می‌شوند. برای گرم کردن مصنوعی و ترمیم این نوع مخلوط‌های آسفالتی، از یک میدان الکترومغناطیسی خارجی، مانند القای الکترومغناطیسی یا مایکروویوها برای افزایش دمای ضایعات فلزی استفاده می‌شود. گرمای ضایعات فلزی به قیر و سنگدانه‌ها منتقل و باعث کاهش ویسکوزیته قیر و ترمیم ترک‌های باز می‌شود [González et al.2018]. میزان ترمیم ترک در مخلوط‌های

پیش‌بینی شاخص خودترمیمی مخلوط‌های آسفالتی با استفاده از شبکه عصبی مصنوعی

۴,۷۵ و ۰,۰۷۵ میلی‌متر)، درصد افزودنی‌ها (الیاف فولادی، براده آهن، RAP و سرباره فولاد^(۸)، نوع قیر (قیر با درجه نفوذ ۶۰/۷۰ و ۸۰/۱۰۰^(۹))، چرخه ترمیم ترک، نوع گرمایش (گرمایش القایی و میکروویو^(۱۱)) و زمان گرمایش بودند. در مجموع ۷۱۵ داده برای هر ورودی برداشت شد. علت انتخاب افزودنی‌هایی مانند الیاف فولادی، براده آهن، RAP و سرباره فولاد این بود که این مواد ضایعات صنعت‌های مختلف و برای ارتقاء توسعه پایدار، قابل بازیافت هستند و می‌توان از آن‌ها در ساخت مخلوط‌های آسفالتی استفاده کرد [Fakhri et al. 2020]. همچنین به علت استفاده زیاد از این مواد در تحقیقات محققین در زمینه خودترمیمی مخلوط‌های آسفالتی، داده‌های بیشتری در دسترس بود.

شبکه‌ای بین نورون‌ها ایجاد می‌شود و توسط الگوریتم آموزشی، شبکه آموزش می‌بیند.

۳. داده‌ها

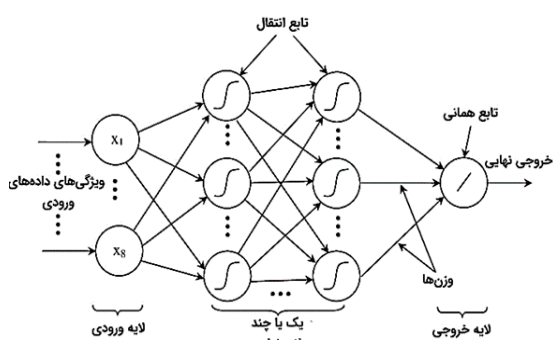
در این مقاله پیش‌بینی شاخص خودترمیمی با استفاده از شبکه‌های عصبی مصنوعی براساس داده‌های برداشت شده از مقالات معتبر آزمایشگاهی انجام شده است. در مجموع از ۱۰ مقاله در زمینه خودترمیمی مخلوط‌های آسفالتی برای برداشت داده‌ها استفاده شد که اطلاعات این مقالات در جدول ۱ ارائه شده است. داده‌های برداشت شده شامل ابعاد نمونه (نمونه‌هایی به قطر ۱۰۰ میلی‌متر و ضخامت‌های ۶۰، ۳۰ و ۲۵ میلی‌متر^(۷))، روش تراکم نمونه (دو نوع روش تراکم ژیراتوری و مارشال^(۸))، دانه‌بندی مخلوط آسفالتی (درصد عبوری از الک‌های ۱۲,۵،

جدول ۱. اطلاعات مقالات مورد استفاده جهت برداشت داده‌ها

نام مقالات	نویسندگان	سال انتشار	ژورنال چاپ
Self-healing of asphalt mixture by microwave and induction heating [Norambuena-Contreras et al.2016]	J. Norambuena-Contreras, A. Garcia	2016	Materials and Design
Influence of the Microwave Heating Time on the Self-Healing Properties of Asphalt Mixture [Norambuena-Contreras et al.2017]	Jose Norambuena-Contreras and Irene Gonzalez-Torre	2017	Applied Sciences
Self-healing properties of recycled asphalt waste: An approach mixtures containing metal through microwave radiation heating [Gonzalez et al.2018]	A. Gonzalez et al.	2018	Journal of Environmental Management
Crack healing performance of hot mix asphalt containing steel slag by microwaves heating [Phan et al.2018]	Tam Minh Phan et al.	2018	Construction and Building Materials
Effect of RAP and fibers addition on asphalt mixtures with self-healing properties gained by microwave radiation heating [Gonzalez et al.2018]	A. Gonzalez et al.	2018	Construction and Building Materials
Effect of metallic waste addition on the electrical, thermophysical and microwave crack-healing properties of asphalt mixtures [Norambuena-Contreras et al.2018]	J. Norambuena-Contreras et al.	2018	Construction and Building Materials
Microwave crack healing on conventional and modified asphalt mixtures with different additives: an experimental approach [Gonzalez et al.2019]	A. Gonzalez et al.	2019	Taylor & Francis
Induction Heating and Fatigue-Damage	Ziming Liu et al.	2019	J. Mater. Civ.

نام مقالات	نویسندگان	سال انتشار	ژورنال چاپ
Induction Healing of Steel Fiber-Reinforced Asphalt Mixture [Liu et al.2019]			Eng.
Effect of metallic-waste aggregates on microwave self-healing performances of asphalt mixtures [Lou et al.2020]	Baowen Lou et al.	2020	Construction and Building Materials
An Evaluation of the Mechanical and Self-healing Properties of Warm Mix Asphalt Containing Scrap Metal Additives [Fakhri et al.2020]	Mansour Fakhri et al.	2020	Journal of Cleaner Production

تعداد عنصرهای موجود در لایه ورودی در حقیقت همان تعداد متغیرهای ورودی معرفی شده به شبکه هستند. لایه پنهان حاوی تعدادی نورون (سلول عصبی) است که بر رفتار شبکه اثر می‌گذارد. تعیین تعداد لایه‌های پنهان و نورون‌ها به عهده‌ی کاربر است که با سعی و خطا تعداد بهینه لایه‌ها و نورون‌ها را مشخص کند. لایه خروجی شبکه عصبی نیز بیانگر خروجی مسئله است که شبکه باید آن را پیش‌بینی کند [Suzuki.2011].



شکل ۱. شبکه عصبی پرسپترون چندلایه

۴-۳ شبکه عصبی چندلایه (MLP) بهینه سازی

شده با الگوریتم ازدحام ذرات (PSO)

یکی از الگوریتم‌هایی که برای آموزش شبکه‌های MLP بکار می‌رود، الگوریتم ازدحام ذرات است، که از رفتار دسته‌جمعی حیواناتی مانند پرندگان و ماهی‌ها الهام گرفته شده است [Mondal et al.2019]. روش کار این الگوریتم اینگونه است که ابتدا تعدادی ذره با موقعیت و سرعت تصادفی ایجاد شده، سپس در هر تکرار، ذرات بر حسب بهترین موقعیت گذشته خود و ذرات دیگر، حرکت به سوی هدف را اصلاح

فصلنامه مهندسی حمل‌ونقل / سال چهاردهم / شماره سوم (۵۶) / بهار ۱۴۰۲

۴. معرفی روش‌های مدلسازی

در این مقاله، جهت پیش بینی شاخص خودترمیمی از روش‌های، تجزیه و تحلیل آماری با نرم افزار SPSS، شبکه عصبی چندلایه (MLP)، شبکه عصبی چندلایه با الگوریتم بهینه ساز ازدحام ذرات (PSO) و شبکه عصبی شعاعی پایه (RBF) استفاده شده است و در انتها نتایج این روش‌ها با یکدیگر مقایسه گردیده است. برای بررسی معتبر بودن شبکه عصبی نیز سه نمونه حاوی ۶۰ درصد سرباره فولاد در آزمایشگاه ساخته و نتایج خودترمیمی آن‌ها با شبکه‌های عصبی مقایسه شد. در ادامه مروری بر این روش‌ها انجام خواهد شد.

۴-۱ تجزیه و تحلیل آماری داده‌ها در SPSS

تجزیه و تحلیل آماری برای کشف الگوها و روند موجود در اطلاعات استفاده می‌شود. تحلیل آماری باعث می‌شود که بتوان بصورت علمی در مورد پدیده‌ها، رویدادها و یا تحقیقات تصمیم‌گیری نمود. اگر تعداد داده‌ها زیاد باشد، استفاده از روش‌های تجزیه و تحلیل آماری زمان‌بر و مشکل است، به همین دلیل نرم افزارهای آماری مختلفی وجود دارند که تجزیه و تحلیل داده‌ها را به سرعت انجام می‌دهند. در این مقاله از نرم افزار SPSS استفاده شده است.

۴-۲ شبکه عصبی چندلایه (MLP)

یک شبکه عصبی پرسپترون چند لایه، حداقل سه لایه (Layer) دارد (شکل ۱)، که عبارتند از: لایه ورودی، لایه پنهان و لایه خروجی. شبکه‌های چند لایه، دارای مجموعه‌ای از وزن‌ها و بایاس هستند که برای آموزش شبکه عصبی تنظیم می‌شوند.

پیش‌بینی شاخص خودترمیمی مخلوط‌های آسفالتی با استفاده از شبکه عصبی مصنوعی

آن نقاط است. مقدار ضریب همبستگی مطابق رابطه زیر محاسبه می‌شود [Hecht-Neilsen.1990]:

$$R = \frac{\sum(D_i - \bar{D})(Y_i - \bar{Y})}{\left[\sum(D_i - \bar{D})^2 \sum(Y_i - \bar{Y})^2\right]^{0.5}} \quad (1)$$

که در آن D_i خروجی هدف برای داده i ام از دسته آزمایش، Y_i خروجی پیش‌بینی شده توسط شبکه برای داده i ام از دسته آزمایش، \bar{D}, \bar{Y} به ترتیب میانگین خروجی‌های پیش‌بینی شده توسط شبکه و خروجی‌های هدف و R ضریب همبستگی خطی است.

مقدار این ضریب بین -1 تا $+1$ تغییر می‌کند. اگر این مقدار برابر با 1 باشد، به معنای همبستگی مثبت کامل، 0 به معنای عدم همبستگی و -1 به معنی همبستگی منفی کامل است. استفاده از این ضریب در شبکه عصبی بین خروجی‌های پیش‌بینی شده توسط شبکه و خروجی هدف از دسته آزمایش می‌تواند به عنوان معیاری برای سنجش میزان یادگیری و عملکرد شبکه باشد. هر چه این مقدار به 1 یا -1 نزدیکتر باشد، میزان یادگیری و عملکرد شبکه بهتر است [Taherkhani et al.2012].

میانگین مربعات خطا (MSE) در یک شبکه، اختلاف میانگین مربع بین مقادیر هدف و آنچه تخمین زده شده است [Gupta et al.2004]. MSE اندازه‌گیری کیفیت یک برآوردگر است که همیشه غیرمنفی و هرچه به صفر نزدیکتر باشد بهتر است. هرچه مقدار MSE کمتر باشد، باعث می‌شود شبکه، ورودی‌ها را بهتر آموزش ببیند و خروجی دقیق‌تری ارائه دهد. مقدار MSE مطابق رابطه زیر محاسبه می‌شود [Gupta et al.2004]:

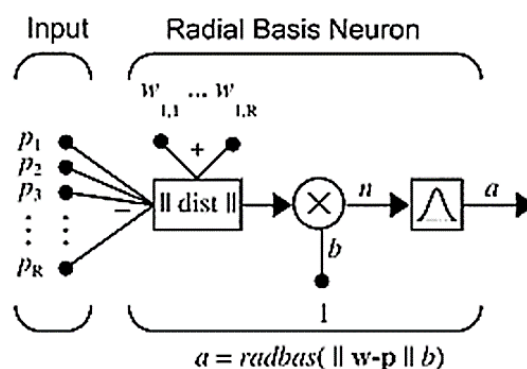
$$MSE = \frac{\sum_{i=0}^n (Y_i - \hat{Y}_i)^2}{n} \quad (2)$$

که در آن Y_i خروجی مطلوب برای مثال i ام از دسته آزمایش، \hat{Y}_i خروجی شبکه برای مثال i ام از دسته آزمایش و n تعداد مثال‌های موجود در دسته آموزش یا آزمایش است.

می‌کنند، پس از تکرارهای متوالی، مسئله به جواب بهینه همگرا می‌شود.

۴-۴ شبکه عصبی شعاعی پایه (RBF)

این شبکه‌ها دارای سه لایه (لایه‌ی ورودی، لایه‌ی پنهان با تابع فعالساز گوسی و لایه‌ی خروجی) هستند و تابع فعالسازی آن‌ها، تابع شعاعی پایه (Radial Basis Function) است. شکل ۲، یک شبکه عصبی RBF را نشان می‌دهد [Suzuki.2011].



شکل ۲. شبکه عصبی شعاعی پایه [Suzuki.2011]

شبکه‌های عصبی RBF و شبکه‌های MLP از نظر ساختاری تفاوت زیادی با یکدیگر ندارند و فقط نوع پردازشی که نورون‌ها روی ورودی‌هایشان انجام می‌دهند، متفاوت است. با وجود اینکه، این شبکه‌ها نیازمند نورون‌های بیش‌تری نسبت به شبکه‌های MLP هستند، ولی می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز برای شبکه‌های MLP، آن‌ها را آموزش داد.

۴-۵ سنجش میزان یادگیری و عملکرد شبکه‌های عصبی

برای اینکه میزان یادگیری شبکه سنجیده شود، از فاکتورهای مختلفی مانند ضریب همبستگی، میانگین مربعات خطا و ریشه میانگین مربعات خطا استفاده می‌شود که در ادامه توضیح داده شده است: ضریب همبستگی نمونه (R) اندازه‌گیری نزدیکی ارتباط نقاط در یک نمودار پراکنندگی به یک خط رگرسیون خطی بر اساس

به منظور صحت سنجی مدل ارائه شده با شبکه عصبی، نمونه-های آسفالتی SCB شامل ۶۰ درصد سرباره جهت تعیین نرخ خودترمیمی در آزمایشگاه ساخته شده و آزمایش خمش سه نقطه‌ای جهت تعیین مقاومت خمشی نمونه‌ها مورد استفاده قرار گرفته است. دانه بندی مصالح سنگی و سرباره استفاده شده در این تحقیق به ترتیب مطابق دانه‌بندی ارائه شده در جدول ۲ و جدول ۳ هستند. قیر مورد استفاده برای ساخت نمونه‌ها قیر ۶۰/۷۰ شرکت نفت پاسارگاد تهران است. به منظور تعیین درصد قیر بهینه از روش مارشال استفاده شده و درصد قیر بهینه ۵٫۴ درصد محاسبه شده است.

ریشه میانگین مربعات خطا (RMSE) معیاری است که اغلب از تفاوت بین مقادیر مطلوب و مقادیر مشاهده شده استفاده می‌شود و از رابطه ۷ بدست می‌آید [Gupta et al.2004]. همیشه غیر منفی است و مقدار ۰ (تقریباً هرگز در عمل به دست نیامده است) نشان دهنده تناسب کامل با داده‌ها است. باید به این نکته توجه داشت که مقایسه بین انواع مختلف داده نامعتبر است زیرا اندازه‌گیری به مقیاس اعداد استفاده شده بستگی دارد.

$$RMSE = \sqrt{\frac{\sum_{i=0}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (3)$$

۶-۴ ساخت نمونه‌های آزمایشگاهی

جدول ۲. دانه‌بندی مصالح سنگی

۰/۰۷۵	۰/۱۵	۰/۳	۰/۶	۲/۳۶	۴/۷۵	۹/۵	۱۲/۵	۱۹	سایز الک (میلیمتر)
۳	۸	۱۴	۲۳	۴۵	۶۰	۸۶	۹۶	۱۰۰	درصد عبوری (%)

جدول ۳. دانه‌بندی سرباره فولاد

۰/۰۷۵	۰/۱۵	۰/۳	۰/۶	۲/۳۶	۴/۷۵	۹/۵	۱۲/۵	۱۹	سایز الک (میلیمتر)
۰	۰	۰	۱	۱	۵	۷۸	۱۰۰	۱۰۰	درصد عبوری (%)

قرار گرفته است (شکل ۳). نرخ بارگذاری ۰٫۵ میلی‌متر در دقیقه جهت اعمال بار مورد استفاده قرار گرفت. پس از اتمام آزمایش خمش، نمونه‌های آسفالتی ترک خورده به مدت ۳ ساعت در دمای اتاق قرار گرفتند تا زمانی که به ۲۰ درجه سانتی‌گراد برسند، برای اینکه اطمینان حاصل شود که رطوبت سطح ناشی از انجماد کاملاً تبخیر شود. دو سطح ترک خورده نمونه آزمایشی در کنار هم گذاشته شدند و در مایکروویو با قدرت ۷۰۰ وات و فرکانس ۲٫۴۵ گیگاهرتز قرار گرفتند. زمان گرمایش، ۱۵ ثانیه انتخاب شد.

مقاومت خمشی سه نقطه‌ای نمونه‌های مخلوط آسفالتی با استفاده از آزمایش خمش نیم دایره‌ای برای اندازه‌گیری خودترمیمی انجام شده است. به منظور ساخت نمونه‌های SCB، نمونه‌های مارشال در درصد قیر بهینه ساخته شده و با برش زدن به ۴ نمونه SCB تبدیل شدند. پس از ساخت نمونه‌های SCB، نمونه‌ها، ۲۴ ساعت قبل از آزمایش در دمای ۲۰- درجه سانتی‌گراد نگهداری شدند. نمونه‌های نیم دایره‌ای بر روی دو غلتک به فاصله ۸۰ میلی‌متر از هم قرار گرفتند و یک غلتک بارگذاری سوم نیز در قسمت میانی بالای نمونه‌ها



شکل ۳. نمونه نیم‌دایره‌ای: (الف) قبل از بارگذاری؛ (ب) بعد از بارگذاری

۵-۱ نتایج حاصل از رگرسیون چندگانه در SPSS

در روش رگرسیون خطی چندگانه رابطه خطی بین متغیرهای مستقل (Independent Variable) و متغیر وابسته (Dependent Variable) به صورت زیر است:

$$y = B_0 + B_1x_1 + \dots + B_nx_n + e \quad (5)$$

که در آن، x_1 تا x_n متغیرهای مستقل، y متغیر وابسته، B_1 تا B_n ضرایب مدل رگرسیونی، B_0 مقدار ثابت و e جمله خطای مدل رگرسیونی است. نتایج برازش مدل و برآورد ضرایب و خصوصیات مربوط به آزمون آن‌ها به ترتیب در جداول ۴ و ۵ آورده شده است.

پس از خنک شدن، نمونه اولین چرخه ترمیم را کامل می‌کند و آماده شروع یک چرخه جدید می‌شود که در آن نمونه دوباره آزمایش خواهد شد و بار اوج، (F_i) ثبت می‌شود. نرخ ترمیم برای هر نمونه آسفالتی، HR، به عنوان رابطه بین حداکثر نیروی نمونه آزمایش که ابتدا آزمایش شده است، (F_0) و حداکثر نیروی اندازه‌گیری شده در نمونه آزمایش پس از چرخه ترمیم i ام، (F_i) تعریف می‌شود:

$$HL = \frac{F_i}{F_0} \quad (4)$$

۵. نتایج و بحث

جدول ۴. خلاصه برازش مدل

مدل	ضریب تعیین (R Square)	ضریب تعیین تعدیل شده (Adjusted R Square)	دوربین-واتسون
۱	۰/۷۲۱	۰/۵۲	۱/۲۲۲

ضریب تعیین، همان مربع ضریب همبستگی است. اگر این مقدار نزدیک به یک باشد، برازش بهتر را نشان می‌دهد. در جدول بالا، ۵۲ درصد تغییرات (پراکندگی) که برای متغیر وابسته (شاخص خودترمیمی) در نظر داریم توسط مدل رگرسیونی پوشش داده می‌شود، به عبارتی می‌توان گفت در ۵۲ درصد مواقع پیش‌بینی نزدیک به واقعیت انجام شده است.

ضریب همبستگی پیرسون نشانگر همبستگی خطی بین متغیرهای وابسته و مقدار پیش‌بینی شده توسط مدل است. هر چه این ضریب به ۱ (یا -۱) نزدیکتر باشد، مدل توانسته سهم بیشتری از تغییرات متغیر وابسته را نشان دهد. در جدول بالا این مقدار برابر ۰,۷۲۱ است که قابل قبول است.

فرض استقلال خطاها رد می‌شود و امکان استفاده از رگرسیون وجود ندارد. آماره دورین-واتسون بین ۰ تا ۴ است. اگر بین باقیمانده‌ها همبستگی متوالی وجود نداشته باشد، مقدار این آماره باید به ۲ نزدیک باشد. اگر به صفر نزدیک باشد نشان دهنده همبستگی مثبت و اگر به ۴ نزدیک باشد نشان دهنده همبستگی منفی می‌باشد.

ضریب تعیین تعدیل شده، پیش‌بینی می‌کند، اگر نمونه‌های دیگری نیز گرفته شود، ضریب تعیین اصلاح شده، ۵۱٫۱ درصد خواهد بود.

به منظور بررسی استقلال خطاها (تفاوت بین مقادیر واقعی و مقادیر پیش‌بینی شده) از یکدیگر از آزمون دورین واتسون استفاده می‌شود. اگر خطاها با یکدیگر همبستگی داشته باشند،

جدول ۵. برآورد ضرایب و خصوصیات مربوط به آزمون آن‌ها

مدل	پارامترهای مستقل	ضریب هر پارامتر مستقل	انحراف از معیار	پارامتر t	پارامتر Sig.
	(Constant)	-۰/۱۲۵	۰/۱۸۶	-۰/۶۷۱	۰/۵۰۲
	ابعاد نمونه	۰/۱۵۹	۰/۰۲۵	۶/۴۲۶	۰/۰۰۰
	روش تراکم نمونه	۰/۶۸۳	۰/۰۸۴	۸/۱۶۱	۰/۰۰۰
	عبوری از الک ۱۲٫۵ میلیمتر	-۴/۶۱۸	۰/۳۹۲	-۱۱/۷۷۵	۰/۰۰۰
	عبوری از الک ۴٫۷۵ میلیمتر	۵/۲۴۸	۰/۴۴۸	۱۱/۷۲	۰/۰۰۰
	عبوری از الک ۰٫۰۷۵ میلیمتر	-۲۴/۰۱۵	۲/۴۴	-۹/۸۴۱	۰/۰۰۰
	درصد براده آهن	-۱/۴۹۱	۰/۳۷۳	-۳/۹۹۶	۰/۰۰۰
	درصد RAP	-۰/۰۲۱	۰/۰۸۱	-۰/۲۶۷	۰/۷۹۲
	درصد سرباره فولاد	۰/۲۰۲	۰/۰۴۲	۴/۷۸۹	۰/۰۰۰
	درصد لیاف فولادی	-۱/۲۵۷	۰/۲۴	-۵/۲۳۹	۰/۰۰۰
	نوع قیر	۰/۲۹۶	۰/۰۲۲	۱۳/۳۴۳	۰/۰۰۰
	چرخه ترمیم ترک	-۰/۰۳	۰/۰۰۲	-۱۴/۹۹۱	۰/۰۰۰
	نوع گرمایش	۰/۴۵۳	۰/۰۳۶	۱۲/۵۷۴	۰/۰۰۰
	زمان گرمایش (S)	۰/۰۰۸	۰/۰۰۱	۱۳/۷۷۴	۰/۰۰۰

جز مقدار ثابت و درصد RAP کمتر از ۰٫۰۵ می‌باشد و فرض صفر برای این متغیرها رد می‌شود، یعنی در مدل باقی می‌مانند، ولی با اطمینان ۹۵ درصد می‌توان گفت ضرورتی برای وجود مقدار ثابت و درصد RAP در مدل وجود ندارد.

مدل ارائه شده توسط این برازش رگرسیونی به صورت زیر خواهد بود:

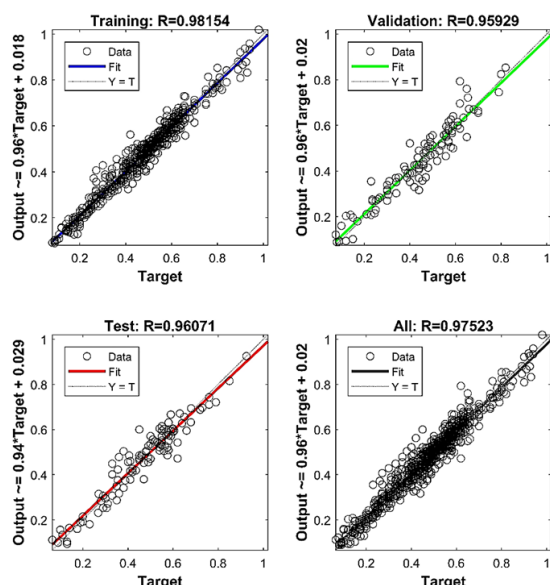
$$\text{Healing ratio} = -0.125 + 0.159 \times D + 0.683 \times CT - 4.618 \times S_{12.5} + 4.938 \times S_{4.75} - 24.015 \times S_{0.075} - 1.491 \times M - 0.021 \times R + 0.202 \times S - 1.257 \times F \quad (6)$$

که در آن، D ابعاد نمونه، CT روش تراکم نمونه، S_{12.5} درصد عبوری از الک ۱۲٫۵ میلیمتر، S_{4.75} درصد عبوری از

ضرایب رگرسیون در ستون B و انحراف معیار برآوردگرهای هر یک از ضرایب رگرسیونی در ستون Std. Error، نشان داده شده است. به کمک این دو معیار می‌توان به کمک یک آزمون t، فرض صفر بودن این ضرایب را اجرا کرد.

ستون‌های t و Sig به آزمون فرض ضرایب پرداخته‌اند. هر چه مقدار t بزرگ باشد، فرض صفر بودن ضریب، ضعیف‌تر شده و نقش آن متغیر در مدل‌سازی، بیشتر است. این بزرگی را به کمک مقدار Sig نیز مشخص می‌کنند. اگر مقدار Sig کوچکتر از ۰٫۰۵ باشد، فرض صفر که بیانگر بی‌اثر بودن متغیر در مدل است، رد می‌شود. در این مثال Sig مربوط به همه متغیرها به

پیش‌بینی شاخص خودترمیمی مخلوط‌های آسفالتی با استفاده از شبکه عصبی مصنوعی



شکل ۴. همبستگی داده‌های آموزش، صحت سنجی، آزمایش و

تمام داده‌های شبکه عصبی MLP

محور افقی، مقادیر هدف (شاخص خود ترمیمی) و محور عمودی، مقادیر خروجی که توسط شبکه عصبی پیش‌بینی شده را نشان می‌دهد. خط برازش شده هرچه بر خط مبنا، منطبق‌تر باشد، دقت شبکه بیشتر است. ضریب همبستگی بین خروجی-های هدف و شبکه عصبی برای داده‌های آموزش برابر ۰/۹۸۱، صحت سنجی برابر ۰/۹۵۹، آزمایش برابر ۰/۹۶۰ و برای همه داده‌ها ۰/۹۷۵ است، که نتایج خوبی را نشان می‌دهد. میزان یادگیری و عملکرد شبکه عصبی زمانی بهتر است که ضریب همبستگی به یک نزدیک‌تر باشد.

جدول ۶. MSE و RMSE بین مقادیر واقعی و پیش‌بینی شده

شبکه عصبی MLP

	MSE	RMSE
آموزش	۰/۰۰۱۱۰	۰/۰۳۳
اعتبارسنجی	۰/۰۰۲۴۴	۰/۰۴۹
آزمایش	۰/۰۰۲۲۲	۰/۰۴۷
تمام داده‌ها	۰/۰۰۱۴۷	۰/۰۳۸

هر چه مقدار MSE کمتر باشد، باعث می‌شود در شبکه، ورودی‌ها بهتر آموزش ببینند و خروجی دقیق‌تری ارائه دهد و هرچقدر مقدار آن به صفر نزدیک‌تر باشد، نشان دهنده میزان

الک ۴,۷۵ میلیمتر، S0.075 درصد عبوری از الک ۰,۰۷۵ میلیمتر، M درصد براده آهن، R درصد آسفالت بازیافتی، S درصد سرباره فولاد، F درصد الیاف فولادی، BT نوع قیر، C چرخه ترمیم ترک، HT نوع گرمایش و T زمان گرمایش است.

۲-۵ نتایج حاصل از آنالیز مدل با شبکه عصبی

چندلایه (MLP)

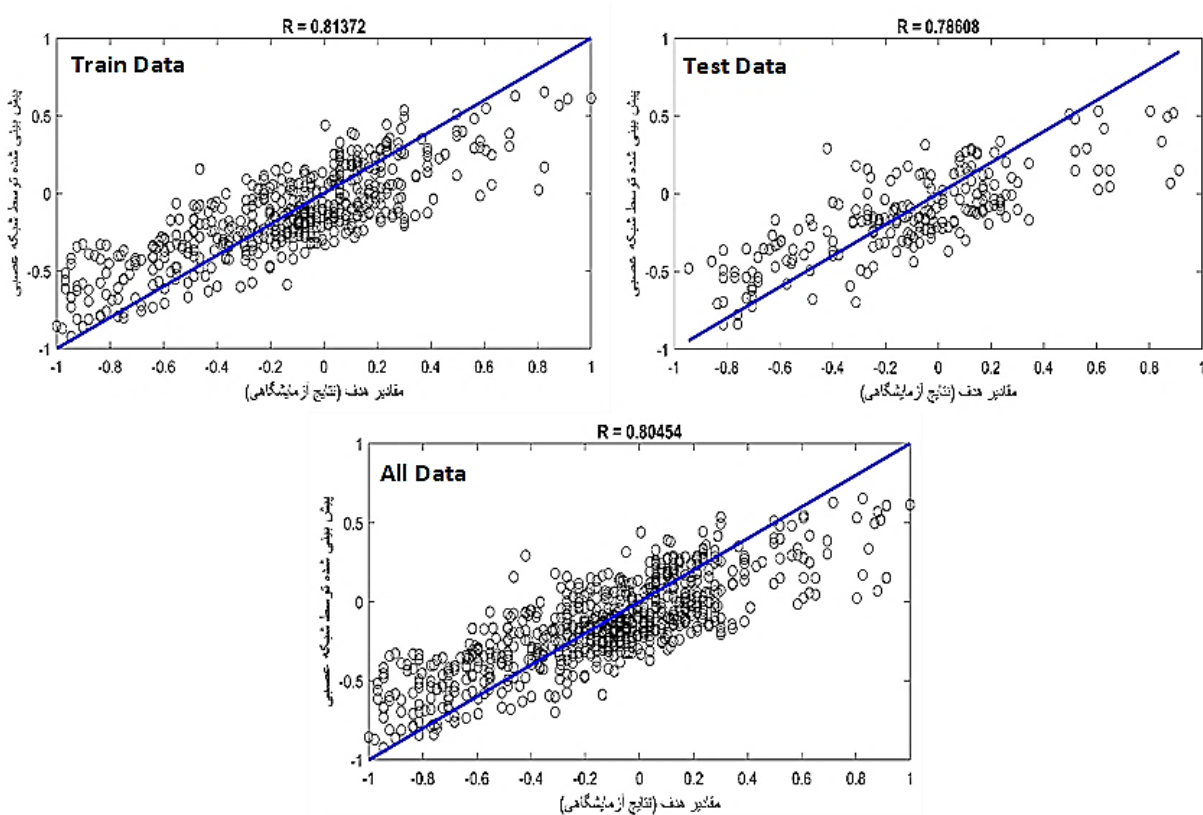
در این مطالعه تعداد مختلفی شبکه عصبی با یک، دو و سه لایه پنهان و تعداد نورون‌های مختلف در لایه(ها)ی پنهان آموزش داده شد و شبکه عصبی بهینه با یک لایه پنهان و ۱۲ نورون در لایه پنهان تعیین شد. تابع فعالسازی لایه‌ی پنهان، از نوع تابع سیگموئید (tansig) و تابع فعالساز لایه خروجی از نوع، تابع انتقال خطی (purelin) است. همچنین ۷۰ درصد داده‌ها برای آموزش (مجموعه داده‌های مورد استفاده برای یادگیری یا تعیین وزن‌ها و بایاس‌های شبکه)، ۱۵ درصد داده‌ها برای صحت سنجی (مجموعه داده‌های مورد استفاده برای تأیید عملکرد شبکه و بهینه سازی روش آموزش و ۱۵ درصد دیگر برای آزمایش (مجموعه داده‌های مورد استفاده برای تنظیم ساختار شبکه و ارزیابی عملکرد شبکه) در نظر گرفته شد. پس از ساخت هر مدل، ضریب همبستگی برای داده‌های آموزش، صحت سنجی، آزمایش و کل داده‌ها در شکل ۴ و میانگین مربعات خطاها (MSE) و ریشه میانگین مربعات خطا (RMSE) در جدول ۶ ارائه داده شده است.

نورون‌های لایه‌های پنهان است. تابع انتقال لایه‌های پنهان از نوع سیگموئید و تابع انتقال لایه خروجی از نوع انتقال خطی است. برای بهینه کردن وزن‌ها و بایاس‌های شبکه عصبی از الگوریتم بهینه‌سازی ازدحام ذرات استفاده شد. ضریب همبستگی برای داده‌های آموزش، آزمایش و کل داده‌ها در شکل ۵ و میانگین مربعات خطاها (MSE) و ریشه میانگین مربعات خطا (RMSE) در جدول ۷ ارائه شده است.

کمتر خطاست. ریشه میانگین مربعات خطا (RMSE) همیشه غیر منفی است و مقدار ۰ (تقریباً هرگز در عمل به دست نیامده است) نشان‌دهنده تناسب کامل با داده‌ها است.

۳-۵ نتایج حاصل از آنالیز مدل با شبکه عصبی چندلایه (MLP) بهینه سازی شده با الگوریتم ازدحام ذرات (PSO)

از شبکه عصبی با معماری ۱-۱۲-۱۳ استفاده شد، که ۱۳ و ۱ به ترتیب تعداد متغیرهای ورودی و خروجی و ۱۲ تعداد



شکل ۵. همبستگی داده‌های آموزش، آزمایش و تمام داده‌های شبکه عصبی MLP بهینه سازی شده با PSO

پیش‌بینی شاخص خودترمیمی مخلوط‌های آسفالتی با استفاده از شبکه عصبی مصنوعی

۴-۵ نتایج حاصل از آنالیز مدل با شبکه عصبی

شعاعی پایه (RBF)




معماری شبکه عصبی RBF استفاده شده در این مقاله شامل سه لایه است (لایه ورودی، لایه پنهان و لایه خروجی). تعداد نورون‌های لایه پنهان نیز براساس سعی و خطا، ۱۰۰ نورون انتخاب شد. ضریب همبستگی برای داده‌های آموزش، آزمایش و کل داده‌ها در شکل ۶ و میانگین مربعات خطاها (MSE) و ریشه میانگین مربعات خطا (RMSE) در جدول ۸ ارائه داده شده است.

ضریب همبستگی بین خروجی‌های هدف و شبکه عصبی برای داده‌های آموزش برابر ۰/۸۱۳، آزمایش برابر ۰/۷۸۶ و برای همه داده‌ها ۰/۸۰۴ است، که نتایج متوسطی را نشان می‌دهد.

جدول ۷. MSE و RMSE بین مقادیر واقعی و پیش‌بینی شده

شبکه عصبی MLP بهینه سازی شده با PSO

	MSE	RMSE
آموزش	۰/۰۴۸۴	۰/۲۲۰
آزمایش	۰/۰۵۸۰	۰/۲۴۱
تمام داده‌ها	۰/۰۵۱۳	۰/۲۲۶



شکل ۶. همبستگی داده‌های آموزش، آزمایش و تمام داده‌های شبکه عصبی RBF

جدول ۸. MSE و RMSE بین مقادیر واقعی و پیش‌بینی شده

شبکه عصبی RBF

	MSE	RMSE
آموزش	۰/۰۰۲۶۳	۰/۰۵۱
آزمایش	۰/۰۰۴۹۶	۰/۰۷۰
تمام داده‌ها	۰/۰۰۳۳۳	۰/۰۵۷

ضریب همبستگی بین خروجی‌های هدف و شبکه عصبی برای داده‌های آموزش برابر ۰/۹۴۷، آزمایش برابر ۰/۹۳۹ و برای همه داده‌ها ۰/۹۴۴ است، که نتایج خوبی را نشان می‌دهد. میزان یادگیری و عملکرد شبکه عصبی زمانی بهتر است که ضریب همبستگی به یک نزدیکتر باشد.

که در آن، B_0 بایاس لایه خروجی، W_k وزن نورون k لایه پنهان و نورون لایه خروجی، B_{Hk} بایاس نورون k در لایه پنهان، W_{ik} وزن بین ورودی i و نورون k لایه پنهان، P_i پارامتر ورودی و f_T تابع فعالساز (تابع فعالساز از نوع سیگموئید (tansig)) است.

$$HI = B_0 + \sum_{k=1}^n \left[W_k \cdot f_T \left(B_{Hk1} + \sum_{i=1}^m W_{ik1} \cdot f_T \left(B_{Hk2} + \sum_{i=1}^z W_{ik2} \cdot P_i \right) \right) \right] \quad (8)$$

که در آن، B_0 بایاس لایه خروجی، W_k وزن نورون k لایه پنهان و نورون لایه خروجی، B_{Hk1} بایاس نورون k در لایه پنهان اول، B_{Hk2} بایاس نورون k در لایه پنهان دوم، W_{ik1} وزن بین ورودی i و نورون k لایه پنهان اول، W_{ik2} وزن بین نورون k لایه پنهان اول و دوم، P_i پارامتر ورودی و f_T تابع فعالساز (تابع فعالساز از نوع سیگموئید (tansig)) است.

$$HI = B_0 + \sum_{k=1}^n \left[W_k \cdot f_T \left(B_{Hk} + \sum_{i=1}^m W_{ik} P_i \right) \right] \quad (9)$$

که در آن، B_0 بایاس لایه خروجی، W_k وزن نورون k لایه پنهان و نورون لایه خروجی، B_{Hk} بایاس نورون k در لایه پنهان، W_{ik} وزن بین ورودی i و نورون k لایه پنهان، P_i پارامتر ورودی و f_T تابع فعالساز (تابع فعالساز از نوع گوسی (radbas)) است.

برای بررسی قدرت تعمیم شبکه عصبی از داده‌های اضافی که در طول مدل‌سازی شبکه استفاده نشده‌اند، استفاده می‌کنیم و با توجه به مقادیر وزن‌ها و بایاس‌های بدست آمده از آموزش شبکه توسط نرم افزار متلب و روابط بالا، مقدار شاخص خود ترمیمی را با استفاده از کد نوشته شده در متلب برای داده‌های جدید آزمایشگاهی محاسبه می‌کنیم. نتایج در جدول ۱۰ ارائه شده است.

۵-۵ مقایسه نتایج شبکه عصبی MLP، شبکه

عصبی MLP بهینه سازی شده با الگوریتم PSO

و شبکه عصبی RBF

نتایج مدل‌سازی شبکه‌های عصبی برای داده‌های آزمایش (TEST) در جدول ۹ ارائه شده است.

جدول ۹. نتایج مدل‌سازی شبکه‌های عصبی برای داده‌های آزمایش

داده‌های آزمایش	شبکه‌های عصبی مورد مطالعه		
	MSE	RMSE	R
شبکه عصبی MLP	۰,۰۰۲۲۲	۰,۰۴۷	۰,۹۶۰
شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO	۰,۰۰۵۸۰	۰,۲۴۱	۰,۷۸۶
شبکه عصبی RBF	۰,۰۰۴۹۶	۰,۰۷۰	۰,۹۳۹

همانطور که از جدول ۹ مشاهده می‌شود، عملکرد شبکه عصبی MLP، نسبت به شبکه عصبی RBF و شبکه عصبی MLP بهینه‌سازی شده با الگوریتم PSO بهتر است و مقدار ضریب همبستگی ($R=0.960$) بیشتری نسبت به دو نوع شبکه عصبی دیگر دارد، همچنین مقدار MSE و RMSE کمتری نیز دارد که باعث می‌شود، شبکه، ورودی‌ها را بهتر آموزش ببیند و خروجی دقیق‌تری ارائه دهد.

۵-۶ مدل ریاضی شبکه عصبی MLP، شبکه

عصبی MLP بهینه سازی شده با الگوریتم PSO

و شبکه عصبی RBF

در این مقاله، خروجی شبکه (خودترمیمی)، برای شبکه عصبی MLP، شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO و شبکه عصبی RBF به ترتیب طبق روابط ۷، ۸ و ۹ محاسبه می‌شود.

$$HI = B_0 + \sum_{k=1}^n \left[W_k \cdot f_T \left(B_{Hk} + \sum_{i=1}^m W_{ik} P_i \right) \right] \quad (7)$$

پیش‌بینی شاخص خودترمیمی مخلوط‌های آسفالتی با استفاده از شبکه عصبی مصنوعی

جدول ۱۰. مقایسه شاخص خودترمیمی بدست آمده از فرمول با نتایج آزمایشگاهی مقالات

ورودی‌ها												خروجی	
رو	عبور	عبور	عبور	درصد	درصد	درصد	چرخ	نوع	زمان	HI	HI	بدس	درصد
ابعاد	ی از	ی از	ی از	الیاف	د	د	نو	نوع	گرما	آزمایشگاه	ت	خطا	
نمونه	تراک	الک	الک	فولاد	براده	RAP	ع	ترمیم	ش	ی	آمده	از	
۵	م	۱۲/۵	۴/۷۵	۰/۰۷۵	ی	آهن	قیر	ترک	(ثانیه)		فرمول		
شبکه عصبی MLP													
۳	۲	۸۴٪	۴۷٪	۵٪	۰٪	۲٪	۰٪	۱	۲	۲	۴۰	۶۹٪	۵/۳٪
												۷۲	
۳	۱	۹۸٪	۶۰٪	۳٪	۴٪	۰٪	۰٪	۲	۱	۲	۴۰	۸۷٪	۱/۷۷٪
												۸۵	
۳	۱	۹۸٪	۶۰٪	۳٪	۴٪	۰٪	۳۰٪	۲	۲	۲	۴۰	۶۱٪	۱۱/۳٪
												۶۷	
۱	۲	۸۳٪	۵۸٪	۵٪	۰٪	۳٪	۰٪	۲	۲	۱	۱۲۰	۸۲٪	۲/۵۴٪
												۷۹	
۲	۲	۸۴٪	۴۷٪	۵٪	۲٪	۰٪	۰٪	۲	۱	۲	۴۰	۹۵٪	۱/۷۷٪
												۹۳	
شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO													
۳	۲	۸۴٪	۴۷٪	۵٪	۰٪	۲٪	۰٪	۱	۲	۲	۴۰	۶۹٪	۱۲/۲٪
												۶۱	
۳	۱	۹۸٪	۶۰٪	۳٪	۴٪	۰٪	۰٪	۲	۱	۲	۴۰	۸۷٪	۱۴/۵٪
												۹۹	
۳	۱	۹۸٪	۶۰٪	۳٪	۴٪	۰٪	۳۰٪	۲	۲	۲	۴۰	۶۱٪	۳۳/۱٪
												۸۱	
۱	۲	۸۳٪	۵۸٪	۵٪	۰٪	۳٪	۰٪	۲	۲	۱	۱۲۰	۸۲٪	۱۹/۱٪
												۹۷	
۲	۲	۸۴٪	۴۷٪	۵٪	۲٪	۰٪	۰٪	۲	۱	۲	۴۰	۹۵٪	۱۵
												۸۰	
شبکه عصبی RBF													
۳	۲	۸۴٪	۴۷٪	۵٪	۰٪	۲٪	۰٪	۱	۲	۲	۴۰	۶۹٪	۳/۷٪
												۶۶	
۳	۱	۹۸٪	۶۰٪	۳٪	۴٪	۰٪	۰٪	۲	۱	۲	۴۰	۸۷٪	۵/۰۵٪
												۶۶	

													۸۲
۳	۱	۹۸٪	۶۰٪	۳٪	۴٪	۰٪	۳۰٪	۲	۲	۲	۴۰	۶۱٪	۱۸/۸٪
													۷۲
۱	۲	۸۳٪	۵۸٪	۵٪	۰٪	۳٪	۰٪	۲	۲	۱	۱۲۰	۸۲٪	۲/۸٪
													۸۴
۲	۲	۸۴٪	۴۷٪	۵٪	۲٪	۰٪	۰٪	۲	۱	۲	۴۰	۹۵٪	۴/۳٪
													۹۰

۵-۷ عوامل مؤثر بر خودترمیمی با توجه به وزن-
 های شبکه عصبی MLP، شبکه عصبی MLP
 بهینه سازی شده با الگوریتم PSO و شبکه عصبی
 RBF
 با توجه به وزن‌های بدست آمده از نتایج آموزش شبکه عصبی
 MLP، شبکه عصبی MLP بهینه سازی شده با الگوریتم
 PSO و شبکه عصبی RBF ورودی‌هایی که بیشترین تأثیر را
 بر خودترمیمی داشتند، در جدول ۱۱ ارائه شدند.

همانطور که از مقادیر درصد خطای شبکه‌ها طبق جدول ۱۰
 مشخص است، شبکه‌های عصبی MLP و RBF نسبت به
 شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO، در
 برابر داده‌های اضافی قدرت تعمیم خوب و درصد خطای
 پایینی داشته و قادر به پیش بینی مناسب برای داده‌هایی که در
 مدلسازی بکار گرفته نشده‌اند، هستند.

جدول ۱۱. متوسط وزن‌های بدست آمده از آموزش شبکه های عصبی

شبکه عصبی MLP		شبکه عصبی MLP بهینه سازی شده با الگوریتم PSO		شبکه عصبی RBF	
عوامل مؤثر بر خودترمیمی	وزن‌ها	عوامل مؤثر بر خودترمیمی	وزن‌ها	عوامل مؤثر بر خودترمیمی	وزن‌ها
زمان گرمایش	۱۲,۵۵۵۲	زمان گرمایش	۶,۳۹۸۵	الیاف فولادی	۹,۵۹۵۳
الیاف فولادی	۱۲,۲۵۸۹	سرباره فولاد	۵,۸۷۶۰	زمان گرمایش	۸,۷۴۸۹
براده آهن	۹,۳۰۳۶	دانه بندی	۵,۸۱۳۲	سرباره فولاد	۸,۱۸۲۴
نوع قیر	۸,۱۸۴۰	چرخه ترمیم ترک	۵,۵۵۴۸	چرخه ترمیم ترک	۷,۹۶۹۸
سرباره فولاد	۸,۰۰۴۶	نوع قیر	۵,۳۰۷۹	براده آهن	۷,۹۱۲۴
چرخه ترمیم ترک	۶,۱۷۲۲	نوع گرمایش	۵,۰۶۸۳	دانه بندی	۷,۷۷۶۸
دانه بندی	۵,۹۰۷۳	الیاف فولادی	۴,۷۴۵۹	نوع قیر	۷,۶۶۱۴
نوع گرمایش	۵,۷۳۹۶	براده آهن	۴,۵۶۰۸	نوع گرمایش	۶,۶۹۱۸
درصد رپ	۵,۶۳۳۷	درصد رپ	۴,۴۱۳۵	درصد رپ	۶,۶۶۱۰
ابعاد نمونه	۴,۹۲۹۵	روش تراکم نمونه	۴,۰۳۰۶	روش تراکم نمونه	۵,۲۴۴۶
روش تراکم نمونه	۳,۷۵۳۸	ابعاد نمونه	۳,۷۶۰۲	ابعاد نمونه	۴,۱۶۶۳

در جدول بالا وزن‌ها از مجموع وزن‌های هر نورون ورودی بدست آمده‌اند. هرچه وزن هر ورودی بیشتر باشد، میزان

پیش‌بینی شاخص خودترمیمی مخلوط‌های آسفالتی با استفاده از شبکه عصبی مصنوعی

عصبی مقایسه شدند.



شکل ۷. شاخص خودترمیمی مخلوط آسفالتی حاوی ۶۰ درصد سرباره فولاد

اثرگذاری آن بر خودترمیمی بیشتر خواهد بود. همانطور که مشاهده می‌شود، ضایعات فلزی، زمان گرمایش، چرخه ترمیم ترک و نوع قیر از مهم‌ترین عوامل مؤثر بر خودترمیمی هستند.

۵-۸ نتایج ترمیم حاصل از آزمایشگاه و مقایسه آن

با نتایج حاصل از آموزش شبکه‌های عصبی

شکل ۷ نتایج شاخص خودترمیمی نمونه‌های حاوی ۶۰ درصد سرباره فولاد را با روش گرمایش مایکروویو نشان می‌دهد. ۷ چرخه ترمیم ترک انجام شد و نتایج ارائه شده میانگین مقادیر شاخص خودترمیمی برای ۳ نمونه است. در جدول ۱۲ نتایج شاخص خودترمیمی آزمایشگاهی با نتایج حاصل از شبکه‌های

جدول ۱۲. مقایسه شاخص خودترمیمی پیش‌بینی شده توسط شبکه‌های عصبی با نتایج آزمایشگاهی

ابعاد نمونه	۲	۲	۲	۲	۲	۲	۲
روش تراکم نمونه	۲	۲	۲	۲	۲	۲	۲
درصد عبوری از الک ۱۲,۵	۹۶٪	۹۶٪	۹۶٪	۹۶٪	۹۶٪	۹۶٪	۹۶٪
درصد عبوری از الک ۴,۷۵	۶۰٪	۶۰٪	۶۰٪	۶۰٪	۶۰٪	۶۰٪	۶۰٪
درصد عبوری از الک ۰,۰۷۵	۳٪	۳٪	۳٪	۳٪	۳٪	۳٪	۳٪
درصد سرباره فولاد	۶۰٪	۶۰٪	۶۰٪	۶۰٪	۶۰٪	۶۰٪	۶۰٪
نوع قیر	۲	۲	۲	۲	۲	۲	۲
چرخه ترمیم ترک	۱	۲	۳	۴	۵	۶	۷
نوع گرمایش	۲	۲	۲	۲	۲	۲	۲
زمان گرمایش (ثانیه)	۱۵	۱۵	۱۵	۱۵	۱۵	۱۵	۱۵
پیش‌بینی شده توسط MLP	۶۰/۷۶٪	۵۷/۵۴٪	۵۴/۰۳٪	۵۳/۱۵٪	۵۱/۲۸٪	۴۵/۳۶٪	۴۱/۵٪
پیش‌بینی شده توسط RBF	۶۷/۲٪	۶۲/۳۶٪	۶۰/۴۱٪	۵۵/۷٪	۴۸/۸۶٪	۴۷/۷۴٪	۴۴/۱۳٪
پیش‌بینی شده توسط PSO	۶۹/۶۱٪	۶۳/۱۴٪	۵۹/۲۲٪	۵۸/۳۵٪	۵۶/۶۵٪	۵۱/۳۹٪	۵۰/۳۳٪
پیش‌بینی شده توسط SPSS	۷۸/۱٪	۷۵/۱٪	۷۲/۱٪	۶۹/۱٪	۶۶/۱٪	۶۳/۱٪	۶۰/۱٪
HI آزمایشگاهی	۶۱/۶۵٪	۵۵/۷۵٪	۵۴/۸۷٪	۵۳/۹۵٪	۵۰/۴۴٪	۴۸/۷۹٪	۴۳/۳۶٪
درصد خطای MLP	-۱/۴	۳/۲٪	-۱/۵٪	-۱/۵٪	۱/۷٪	-۷٪	-۴/۳٪
درصد خطای RBF	۹٪	۱۱/۹٪	۱۰/۱٪	۳/۲٪	-۳/۱٪	-۲/۲٪	۱/۸٪
درصد خطای PSO	۱۲/۹٪	۱۳/۳٪	۷/۹٪	۸/۲٪	۱۲/۳٪	۵/۳٪	۱۶/۱٪
درصد خطای SPSS	۲۶/۷٪	۳۴/۷٪	۳۱/۴٪	۲۸/۱٪	۳۱/۱٪	۲۹/۳٪	۲۸/۶٪

بهینه‌سازی شده با الگوریتم PSO در مقایسه با روش رگرسیون چندگانه در SPSS، درصد خطای پایینی داشته و

همانطور که از درصد خطاهای ارائه شده در جدول بالا مشخص است، شبکه‌های عصبی MLP، RBF و MLP

۷. پی‌نوشت‌ها

1. Reclaimed Asphalt Pavement
2. Multi Layer perceptron
3. Particle Swarm Optimization
4. Radial Basis Function
5. Statistical Package for the Social Sciences
6. Artificial neural network
7. S-100d-60t=1
S-100d-30t=2
S-100d-25t=3
8. Gyration=1
Marshall=2
9. سرباره جایگزین بخش درشت‌دانه (۹،۵-۴،۷۵ میلیمتر)
مخلوط شده است.
10. 60/70=1
80/100=2
11. Induction=1
Microwave=2
12. Mean Square Error

۸. مراجع

- طاهرخانی، حسن و ابراهیمی مقدم، امیر (۱۳۹۱). پیش‌بینی عمر خستگی مخلوط‌های آسفالتی با استفاده از شبکه‌های عصبی. پایان‌نامه کارشناسی ارشد. مهندسی عمران گرایش راه و ترابری. دانشگاه بین‌المللی امام خمینی (ره).
- عامری، محمود و ملاپیم، محمد (۱۳۸۲). تحلیل و طراحی روسازی‌های انعطاف‌پذیر با شبکه‌های عصبی مصنوعی. پایان‌نامه کارشناسی ارشد. مهندسی عمران گرایش راه و ترابری. دانشگاه علم و صنعت.
- فخری، م.، کریمی، م. و قربانی نیک، م. (۱۳۹۸). " تخمین ناهمواری روسازی بر اساس خرابی‌های سطحی با استفاده از شبکه عصبی (مطالعه موردی: محورهای شریانی ایران) "، فصلنامه مهندسی حمل و نقل، دوره ۱۲، شماره ۳، ۶۹۷-۷۱۳.

قادر به پیش‌بینی مناسب نتایج بدست آمده در آزمایشگاه هستند.

۶. نتیجه‌گیری

در این مقاله داده‌های خود ترمیمی بدست آمده از مقالات توسط شبکه عصبی چندلایه (MLP)، شبکه عصبی چندلایه با الگوریتم بهینه‌ساز ازدحام ذرات (PSO)، شبکه عصبی شعاعی پایه (RBF) و تجزیه و تحلیل آماری با نرم افزار SPSS تحلیل و نتایج این روش‌ها با یکدیگر مقایسه شدند. نتایج حاصل از این پژوهش به صورت خلاصه بیان شده است:

- از بین مدل‌های ارزیابی شده در این مقاله، دقت پیش‌بینی شاخص خودترمیمی مدل شبکه عصبی MLP با ضریب همبستگی ۰/۹۶۰، مدل شبکه عصبی RBF با ضریب همبستگی ۰/۹۳۹، مدل شبکه عصبی MLP بهینه‌سازی شده با الگوریتم PSO با ضریب همبستگی ۰/۷۸۶ و در آخر رگرسیون چندگانه با SPSS با ضریب همبستگی ۰/۷۲۱ بود، که شبکه عصبی MLP دارای بیشترین دقت در پیش‌بینی و رگرسیون چندگانه دارای کمترین دقت در پیش‌بینی است.
- معماری بهینه شبکه عصبی مصنوعی چندلایه به منظور پیش‌بینی شاخص خودترمیمی به صورت ۱-۱۲-۱۳، که نشان‌دهنده ۱۳ ورودی، ۱۲ نورون در لایه پنهان و ۱ خروجی (شاخص خود ترمیمی) است.
- برای اعتبار بیشتر مدل، داده‌های اضافی که هرگز در طول مدلسازی استفاده نشده بودند، بکار گرفته شدند، که شبکه‌های عصبی MLP و RBF برای شبیه‌سازی این داده‌ها در مقایسه با شبکه عصبی MLP بهینه‌سازی شده با الگوریتم PSO عملکرد بهتری داشتند.
- شبکه‌های عصبی MLP، RBF و MLP بهینه‌سازی شده با الگوریتم PSO در مقایسه با روش رگرسیون چندگانه در SPSS، درصد خطای پایینی داشته و قادر به پیش‌بینی مناسب نتایج بدست آمده در آزمایشگاه هستند.

- Huang, Y. (2004). *Pavement Analysis and Design*. Pearson Prentice Hall, Upper Saddle River, NJ, ISBN-13: 9780131842441
- Hecht-Neilsen, R. (1990). *Neurocomputing*. Addison-Wesley, Boston.
- Liu, Z., et al. (2019). "Induction Heating and Fatigue-Damage Induction Healing of Steel Fiber-Reinforced Asphalt Mixture". *J. Mater. Civ. Eng.*
- Lou, B., Sha, A., Li, Y., Wang, W., Liu, Z., Jiang, W., Cui, X. (2020). "Effect of metallic-waste aggregates on microwave self-healing performances of asphalt mixtures". *Construction and Building Materials*.
- Mondal, P., Nandi, A., & Jana, N. D. (2019). "An Improved Particle Swarm optimization based Neural Network Training for Classification". *IEEE Region Symposium (TENSYP)*, 681-686.
- Norambuena-Contreras, J., et al. (2019). "Mechanical and Self-Healing Properties of Stone Mastic Asphalt Containing Encapsulated Rejuvenators". *Journal of Materials in Civil Engineering*, 31(5).
- Norambuena-Contreras, J., & Garcia, A. (2016). "Self-healing of asphalt mixture by microwave and induction heating". *Materials & Design*, 106, 404-414.
- Norambuena-Contreras, J., & González, A. (2017). "Influence of the Microwave Heating Time on the Self-Healing Properties of Asphalt Mixtures". *Applied Sciences*, 7(10), 1076.
- Norambuena-Contreras, J., Gonzalez, A., Concha, J.L., Gonzalez-Torre, I., & Schlangen, E. (2018). "Effect of metallic waste addition on the electrical, thermophysical and microwave crack-healing properties of asphalt
- کاووسی، ا.، امانی، س. و محمد کریمی، م. (۱۳۹۸) "ارزیابی تاثیر کربن فعال در ترمیم القایی مخلوط‌های آسفالتی پیرشده تحت امواج مایکروویو"، فصلنامه مهندسی حمل و نقل، دوره ۱۱، شماره ۳، ۷۷۳-۷۹۲.
- EAPA, European Asphalt Pavement Association. (2017, Aug 1). Retrieved from <http://www.eapa.org/asphalt.php>
- Fakhri, M., Baveli Bahmai, B., Javadi, S., Sharafi, M. (2020). "An evaluation of the mechanical and self-healing properties of warm mix asphalt containing scrap metal additives". *Journal of Cleaner Production*, 253.
- González, A., Norambuena-Contreras, J., Storey, L., & Schlangen, E. (2018). "Self-healing properties of recycled asphalt mixtures containing metal waste: An approach through microwave radiation heating". *Journal of Environmental Management*, 214, 242-251.
- González, A., Norambuena-Contreras, J., Storey, L., & Schlangen, E. (2018). "Effect of RAP and fibers addition on asphalt mixtures with self-healing properties gained by microwave radiation heating", *Construction and Building Materials*, 159, 164-174.
- González, A., Valderrama, J., & Norambuena-Contreras, J. (2019). "Microwave crack healing on conventional and modified asphalt mixtures with different additives: an experimental approach". *Road Materials and Pavement Design*, 20, 149-S162.
- Gupta, M., Jin, L., & Homma, N. (2004). *Static and Dynamic Neural Network*. Hobokon, New Jersey.

mixtures". Construction and Building Materials, 187, 1039-1050.

– Phan, T., Park, D., & Le, T. (2018). "Crack healing performance of hot mix asphalt containing steel slag by microwaves heating". Construction and Building Materials, 180, 503-511.

– Suzuki, K. (2011). Artificial Neural Networks - Methodological Advances and Biomedical Applications. ISBN 978-953-307-243-2.

– Shafiei Najd, M., Hassanzadeh, Y., Alami, M., & Abdi Kordani, A. (2018). "Meteorological Drought Analysis Using Particle Swarm Optimization Algorithm-Artificial Neural Networks Based on MSPI Index". Water and Soil Science, 28(2), 107-120.

پیش‌بینی شاخص خودترمیمی مخلوط‌های آسفالتی با استفاده از شبکه عصبی مصنوعی

مهسا روحی فریمان، درجه کارشناسی در رشته مهندسی عمران را در سال ۱۳۹۸ از دانشگاه فنی مهندسی اسفراين أخذ نمود. ایشان در سال ۱۴۰۰ موفق به کسب درجه کارشناسی ارشد در رشته مهندسی عمران - راه و ترابری از دانشگاه صنعتی شاهرود گردید. زمینه های پژوهشی مورد علاقه ایشان تکنولوژی و مواد روسازی و مدلسازی است.



سیدعلی حسینی، درجه کارشناسی در رشته مهندسی عمران - عمران را در سال ۱۳۸۳ از دانشگاه صنعتی شاهرود و درجه کارشناسی ارشد در رشته مهندسی عمران - راه و ترابری را در سال ۱۳۸۶ از دانشگاه صنعتی خواجه نصیرالدین طوسی اخذ نمود. در سال ۱۳۹۵ موفق به کسب درجه دکتری در رشته مهندسی عمران - راه و ترابری از دانشگاه صنعتی خواجه نصیرالدین طوسی گردید. زمینه های پژوهشی مورد علاقه ایشان مدیریت و نگهداری روسازی راه، ارزیابی آزمایشگاهی و میدانی مخلوط‌های آسفالتی و طراحی روسازی راه بوده و در حال حاضر عضو هیات علمی با مرتبه استادیار در دانشگاه صنعتی شاهرود است.



عباس محمدی، درجه کارشناسی در رشته مهندسی آب را در سال ۱۳۶۸ از دانشگاه صنعتی شریف و درجه کارشناسی ارشد در رشته برنامه ریزی حمل و نقل را در سال ۱۳۷۴ از دانشگاه علم و صنعت اخذ نمود. در سال ۱۳۸۳ موفق به کسب درجه دانشوری در رشته برنامه ریزی حمل و نقل از دانشگاه علم و صنعت ایران گردید. زمینه های پژوهشی مورد علاقه ایشان شامل مهندسی ترافیک، شبیه سازی جریان ترافیک، و برنامه ریزی حمل و نقل بوده و در حال حاضر عضو هیات علمی با مرتبه مربی در دانشگاه صنعتی شاهرود است.

