

حداقل سازی مقدار قیر بکار رفته در مخلوط آسفالت به کمک مدل شبیه سازی - بهینه سازی با استفاده از LINGO

مقاله علمی - پژوهشی

محسن عموزاده عمرانی*، گروه مهندسی عمران، واحد سوادکوه، دانشگاه آزاد اسلامی، سوادکوه، ایران
رضوان باباگلی، استادیار، گروه مهندسی عمران، دانشگاه علم و فناوری مازندران، بهشهر، ایران
امیر ایزدی، استادیار، دانشکده فنی مهندسی، دانشگاه شمال، آمل، ایران
علی حسن نژاد اسفندانی، دانشجوی دکتری، گروه مهندسی عمران، واحد آیت الله آملی، دانشگاه آزاد اسلامی، آمل، ایران
*پست الکترونیکی نویسنده مسئول: Mo.Omrani@iaiu.ac.ir
دریافت: ۱۴۰۳/۰۹/۰۲ - پذیرش: ۱۴۰۳/۱۲/۲۵
صفحه ۲۰۶-۱۸۷

چکیده

از مهم ترین ویژگی هایی که در طرح اختلاط آسفالت مورد توجه قرار می گیرد، مقاومت مارشال آسفالت می باشد. پایین بودن مقدار مقاومت مارشال آسفالت باعث پایین آمدن کارایی آن و ایجاد مشکلاتی از جمله خستگی و ترک ها می شود. با توجه به تاثیر زیاد مقدار قیر در مقاومت فشاری آسفالت و هزینه بالای آن، هدف اصلی از طرح مخلوط آسفالت های گرم، انتخاب بهینه ترین مقدار قیر است؛ به طوری که بتواند مشخصات فنی بتن آسفالتی را در حدود مشخص حفظ کند. با توجه به هزینه های سنگین آسفالت و نگهداری آن، ضرورت استفاده از روش های جدید و پیشرفته تر در طرح و کنترل کیفی آسفالت روز به روز محسوس تر می شود. در این تحقیق، در ابتدا اطلاعات ۱۶۰ نمونه آزمایشگاهی بتن آسفالتی از آزمایشگاه مکانیک خاک استان مازندران تهیه شد و سپس بوسیله شبکه عصبی مصنوعی، مقاومت فشاری آسفالت با دقت خوب مدلسازی شد. در ادامه، مقدار قیر بهینه برای ۸ حالت مختلف سنگدانه با کمک نرم افزار بهینه سازی LINGO بدست آمد. نتایج نشان دادند که دانه بندی مناسب تاثیر زیادی در پایین آمدن مقدار قیر مصرفی و در نتیجه، کاهش هزینه آسفالت دارد.

واژه های کلیدی: مقاومت فشاری آسفالت، شبکه عصبی مصنوعی، بهینه سازی، LINGO

۱- مقدمه

مقدار قیر در مقاومت فشاری آسفالت و هزینه بالای آن، هدف اصلی از طرح مخلوط آسفالت های گرم انتخاب بهینه ترین مقدار قیر است؛ به طوری که بتواند مشخصات فنی بتن آسفالتی را در حدود مشخص حفظ کند. تاکنون روش های متعددی برای اختلاط بتن آسفالتی گرم پیشنهاد شده است که از آن جمله می توان به روش مارشال، روش مارشال اصلاح شده، روش ویم و روش سوپریو اشاره کرد. در حال حاضر، به طور متداول، طرح اختلاط مخلوط های آسفالتی گرم در ایران، بر اساس روش مارشال و مارشال اصلاح شده انجام می شود (Amouzadeh

یکی از مهم ترین ویژگی هایی که یک شهر را از سایر شهرها متمایز می کند و تاثیر زیادی بر منظر شهری دارد، آسفالت یکدست و مناسب معابر است. آسفالت ماده ای ترکیبی است که از مخلوط کردن شن و ماسه و قیر ساخته می شود و در ساخت جاده، باند فرودگاه و پشت بام ساختمان ها به کار گرفته می شود. از عمر آسفالت مدت زیادی نمی گذرد و این مخلوط که امروزه در سرتاسر دنیا بکار می رود، کمی بیش از یک قرن است که عملاً مورد استفاده بشر قرار گرفته است. آسفالت گرم نخستین نوع آسفالتی است که مردم با آن آشنا شده اند. با توجه به تاثیر زیاد

مصنوعی در دو قسمت آموزش و تست ارائه شد. مقادیر پیش بینی شده توسط مدل ماشین بردار پشتیبان با الگوریتم کرم شب تاب به مقادیر واقعی نرمی آسفالت خصوصا در قسمت تست نسبت به سایر مدل‌ها نزدیکتر می‌باشد. با توجه به اینکه طولانی شدن عمر آسفالت به پیش بینی عملکرد و ساختار آن و به ویژه وقوع و انتشار ترک خوردگی در آن بستگی دارد، کارلافتیس و بدر (Karlaftis et al, 2015) با استفاده از شبکه عصبی ایجاد ترک های سوسماری در آسفالت را پیش بینی کردند. شبکه عصبی استفاده شده در این تحقیق یک پرسپترون چند لایه از نوع بازگشتی بود که برای پیدا کردن تعداد نرون بهینه در لایه پنهان آن از الگوریتم ژنتیک استفاده شد. نتایج نشان دادند که روش پیشنهادی با توجه به دقت بالا در پیش بینی احتمال شروع ترک سوسماری می‌تواند منجر به پیشگیری به جای درمان این ترک در آسفالت گردد.

پورطهماسب و همکاران (Pourtahmasb et al, 2015) و شفافبخش و تناکی زاده (Shafabakhsh et al, 2015) از مدل عصبی - فازی برای پیش بینی ضریب ارتجاعی آسفالت استفاده کردند.

بقایی مقدم و همکاران (Baghaee Moghaddam et al, 2015) عمر خستگی آسفالت اصلاح شده با الیاف پلی اتیلن را به وسیله چهار مدل شبکه عصبی مصنوعی، برنامه نویسی ژنتیک و ماشین های بردار پشتیبان و ماشین های بردار پشتیبان با الگوریتم کرم شب تاب پیش بینی کردند. ورودی های این مدل ها شامل درصد پلی اتیلن بکار رفته، سطح تنش و دمای محیط می شدند. در این تحقیق آمده است که عمر آسفالت در اثر عبور و مرور وسایل نقلیه (خصوصا سنگین) به اتمام می رسد و برای استفاده بیشتر از آن می بایست یک لایه آسفالت جدید بر روی آسفالت قبلی اجرا شود که به شدت هزینه بر است و یا می بایست ویژگی های مخلوط آسفالت را اصلاح کرد. یکی از روش های نوین اصلاح مخلوط آسفالت استفاده از الیاف پلی اتیلن می باشد. نتایج نشان داد که ANN^۱ عملکرد ضعیف ترین و SSM^۲ با الگوریتم کرم شب تاب بهترین دقت را در پیش بینی عمر خستگی آسفالت داشته اند. در تحقیقی از گان (Ozgan, 2015) مقاومت فشاری آسفالت را با توجه به درجه حرارت و سن آسفالت مدل سازی کرد. او ۶۰ نمونه آزمایشگاهی آسفالت رو در سه درجه حرارت ۳۰، ۴۰ و ۵۰ درجه سانتی گراد و چهار سن ۱، ۳، ۴، ۵ و ۶ ساعت ساخت. او همچنین ۵ نمونه دیگر را در درجه حرارت ۱۷ درجه سانتی گراد و سن تصادفی ساخت. ارگان مقاومت مارشال آسفالت را بوسیله یک شبکه

(Omrani, 2023). در روش طرح اختلاط مارشال، درصد بهینه قیر بر اساس میانگین مقادیر درصد قیری که بیشترین استقامت مارشال، محدوده روانی قابل قبول، بیشترین وزن مخصوص و مناسب ترین مقدار فضای خالی در بتن آسفالتی را نتیجه می دهد، تعیین می شود. به دلیل تعدد متغیرها و پیچیدگی روابط بین آنها و مقاومت مارشال آسفالت، تاکنون رابطه تحلیلی ریاضی بین این متغیرها و مقاومت مارشال آسفالت ارائه نگردیده است. توسعه ابزارهای محاسباتی منجر به ظهور روش های جدید مدل سازی - بهینه سازی شده است. در چند سال اخیر شبکه های عصبی مصنوعی به عنوان ابزاری توانمند در مدل سازی مسائل پیچیده در بسیاری از رشته های مهندسی کاربردهای فراوانی یافته است. همچنین نرم افزار LINGO نیز به عنوان یک روش جدید در مسائل بهینه سازی در علوم مختلف دارای کاربرد رو به گسترشی می باشد. استفاده از الگوریتم های هوش مصنوعی از جمله شبکه عصبی مصنوعی در زمینه های مختلف مهندسی راه و ترابری مانند طراحی روسازی، طرح اختلاط آسفالت، مدیریت تعمیر و نگهداری راه، مهندسی ترافیک و سایر زمینه ها در حال توسعه و پیشرفت است.

در سال های اخیر شبکه های عصبی مصنوعی کاربرد وسیعی در مهندسی آسفالت داشته اند (Ozsahin et al, 2008; Mirzahosseini et al, 2011).

در تحقیقی عملکرد آسفالت گرم اصلاح شده با نانو و حاوی مصالح سرباره فولاد را با شبکه های عصبی مصنوعی توسط شفافبخش و همکاران (Shafabakhsh et al, 2015) پیش بینی شد. آن ها از یک شبکه چند لایه پیشرو با ۵ نرون در لایه ورودی، ۱۰ نرون در لایه پنهان و یک نرون در لایه خروجی استفاده کردند. ۲۱۶ سری داده برای آموزش و ۵۴ سری داده برای تست شبکه در نظر گرفته شدند. نتایج ارتباط خوب بین مقادیر پیش بینی شده توسط شبکه و مقادیر مشاهده شده را نشان دادند. سلطانی و همکاران (Soltani et al, 2015) نرمی مخلوط آسفالت را با ماشین های بردار پشتیبان، ماشین های بردار پشتیبان با الگوریتم کرم شب تاب، برنامه نویسی ژنتیک و شبکه مصنوعی عصبی مدل سازی کردند. شبکه عصبی مصنوعی استفاده شده در این تحقیق دارای ۷ نرون در لایه ورودی، ۳۹ نرون در لایه پنهان و یک نرون در لایه خروجی می باشد. همچنین از تابع انتقال سیگموئیدی و الگوریتم آموزشی مارکوات - لوئرگ در این شبکه استفاده شده است. نتایج عملکرد چهار مدل ماشین بردار پشتیبان، ماشین های بردار پشتیبان با الگوریتم کرم شب تاب، برنامه نویسی ژنتیک و شبکه عصبی

بتن آسفالتی بدست آمده تمامی شرایط گفته شده در آیین نامه را داشته و دارای بیشترین وزن مخصوص و استقامت مارشال نیز باشد. یو و همکاران (Yu et al, 2015) برنامه تعمیر و نگهداری آسفالت یک پروژه را با توجه به سه عامل عملکرد، هزینه و اثرات زیست محیطی بهینه کردند. آن‌ها با استفاده از الگوریتم ژنتیک سعی کردند که عملکرد آسفالت را بهینه و هزینه‌ها و خسارات زیست محیطی پروژه را کمینه کنند. زاورتانیک و همکاران (Zavrtanik et al, 2016) از شبکه‌های عصبی پیشرو با الگوریتم آموزشی بازگشتی برای تخمین فضای خالی در سنگدانه نمونه‌های آسفالت استفاده کردند. ۱۷۲۹۶ نمونه آزمایشگاهی در این تحقیق استفاده شدند. وردی‌های شبکه شامل درصد عبوری از الک‌های مختلف و وزن مخصوص سنگ دانه‌ها بودند. آن‌ها نتیجه گرفتند که شبکه‌های عصبی توانایی پیدا کردن ارتباط پنهانی بین پارامترهای ورودی و فضای خالی سنگ دانه آسفالت را دارند. درک مناسب از خواص آسفالت در ارزیابی عملکرد آسفالت ضروری است (Cao et al, 2016). از مهمترین خواص که طرح و کنترل کیفی آسفالت بر اساس آن صورت می‌گیرند مقاومت فشاری آسفالت می‌باشند که توسط آزمایش استقامت مارشال تعیین می‌شوند (Berthelot et al, 1999). مقدار مقاومت فشاری آسفالت تاثیر مهمی در عملکرد آسفالت از جمله ایجاد انواع ترک‌ها در آسفالت دارند (Tigdemir et al, 2015); Ogundipe et al, 2016). از آنجایی‌که بتن آسفالتی مخلوطی از قیر و مصالح سنگی است، مقاومت فشاری آن نیز تابعی از دانه بندی، ویژگیهای مصالح سنگی و همچنین درصد قیر مصرفی آن می‌باشد.

از آنجایی‌که ساخت و توسعه راه‌ها و خطوط آهن از مبانی پیشرفت اقتصادی و فرهنگی کشورها محسوب می‌شود و با توجه به هزینه‌های سنگین آسفالت و نگهداری آن، ضرورت استفاده از روش‌های جدید و پیشرفته تر طرح و کنترل کیفی آسفالت روز به روز محسوس تر می‌شود (Ozgan et al, 2010, AmouzadehOmrani, et al, 2024).

در این تحقیق توانایی شبکه‌های عصبی مصنوعی در پیش بینی مقاومت فشاری آسفالت پیش از ساخت آن مورد بررسی قرار گرفت. سپس با استفاده از رابطه بدست آمده از شبکه بوسیله نرم افزار LINGO به بهینه سازی مقدار قیر بهینه در آسفالت پرداخته شد.

عصبی سه لایه با الگوریتم آموزشی بازگشتی پیش بینی کرد. ۵۲ نمونه برای آموزش و ۱۳ نمونه برای تست شبکه استفاده شدند. نتایج نشان دادند که ارتباط قابل توجه‌ای بین درجه حرارت محیط و پایداری آسفالت وجود دارد به طوری که با افزایش درجه حرارت محیط پایداری آسفالت کاهش می‌یابد. همچنین مشاهده می‌شود دقت مدل منطق فازی در پیش بینی مقاومت مارشال آسفالت بسیار بالاتر از روش آماری استفاده شده می‌باشد.

رمضانپور و گوران (۱۳۸۹) مقاومت فشاری آسفالت را با استفاده از شبکه‌های عصبی مصنوعی پیش بینی کردند و همچنین به بررسی تاثیر تغییرات میزان فیلر، درصد قیر مصرفی، درصد جذب قیر مصالح و درصد شکستگی مصالح در مقاومت فشاری آسفالت پرداختند. آن‌ها به منظور تهیه داده های مورد نیاز جهت آموزش و صحت سنجی شبکه از نتایج آزمایشات انجام شده توسط آزمایشگاه مکانیک خاک استان مازندران بر روی نمونه های آسفالت اجرا شده در سطح استان مازندران، استفاده کردند. اطلاعات نمونه‌ها شامل منحنی دانه‌بندی و درصد شکستگی مصالح سنگی، درصد قیر نسبت به مخلوط آسفالت، وزن مخصوص قیر، درصد جذب قیر مصالح، وزن مخصوص حقیقی مصالح و استحکام (مقاومت فشاری) بودند.

۱۸۴ نمونه بتن آسفالتی در این تحقیق استفاده شد که ۱۴۹ نمونه جهت آموزش شبکه و ۳۵ نمونه جهت تست شبکه به کار گرفته شد. آن‌ها با توجه به دقت بالای شبکه‌های عصبی در پیش بینی مقاومت فشاری آسفالت و همچنین انطباق نتایج شبیه سازی تاثیر تغییرات فیلر، درصد قیر مصرفی، درصد جذب قیر مصالح و درصد شکستگی مصالح در مقاومت فشاری آسفالت با نتایج آزمایشگاهی و تئوری نتیجه گرفتند که شبکه های عصبی توانایی ارائه طرح اختلاط بهینه جهت تهیه آسفالت را دارا می باشند.

فخری و غنی زاده (۱۳۸۵) یک مدل برنامه ریزی غیر خطی برای تعیین درصد قیر بهینه در روش مارشال را استفاده کردند. برای این منظور ابتدا معادلات مربوط به تغییرات پارامترهای موثر در طرح اختلاط بتن آسفالتی شامل چگالی بتن آسفالتی، استقامت مارشال، روانی، درصد فضای خالی بتن آسفالتی، درصد فضای خالی مصالح سنگی و درصد فضای خالی پر شده با قیر، نسبت به درصد قیر مصرفی با استفاده از روش کمترین مربعات و از طریق تقریب با یک چند جمله ای درجه دوم تعیین شدند و سپس با تکیه بر این معادلات و استفاده از یک مدل برنامه ریزی غیر خطی چند هدفی، درصد بهینه قیر به گونه‌ای تعیین شدند که

۲- روش تحقیق

پارامترهای کافی برای بررسی پیچیدگی مساله به شکل مناسب باشد و پارامترها دارای گستردگی و توزیع مناسب در بازه خود باشند. در جدول (۱) مشخصات نمونه‌های آسفالت مورد استفاده به صورت آماری توصیف شده است. با بررسی آماری مشخصات این نمونه‌ها مشخص می‌شود که این داده‌ها از گستردگی آماری مناسبی برخوردار می‌باشند. داده‌های استفاده‌شده در این پژوهش از ۱۶۰ نمونه آسفالت گر تهیه‌شده توسط آزمایشگاه مکانیک خاک استان مازندران جمع‌آوری شد.

این نمونه‌ها از پروژه‌های اجرایی آسفالت در سطح استان مازندران، که عمدتاً شامل روسازی راه‌های شهری و بین‌شهری است، استخراج شدند. نوع آسفالت‌ها بر اساس استاندارد طرح اختلاط مارشال (AASHTO T245) تهیه شده‌اند و شامل مخلوطی از مصالح سنگی (شن و ماسه) و قیر با درجه نفوذ ۶۰-۷۰ (مناسب برای شرایط آب‌وهوایی معتدل تا سرد منطقه مازندران) هستند. دانه‌بندی مصالح سنگی مطابق با مشخصات استاندارد ایران (آیین‌نامه روسازی آسفالتی راه‌های ایران، نشریه ۲۳۴) انتخاب شده و تنوع آن‌ها در جدول ۱ مقاله (توصیف آماری) منعکس شده است. آزمایش‌های مارشال تحت شرایط استاندارد انجام شدند.

دمای تراکم: ۱۳۵-۱۴۵ درجه سانتی‌گراد (برای قیر ۷۰/۶۰).

تعداد ضربات تراکم: ۷۵ ضربه در هر طرف نمونه (مطابق با بارگذاری سنگین در استاندارد مارشال)

دمای آزمایش پایداری مارشال: ۶۰ درجه سانتی‌گراد، با استفاده از دستگاه مارشال استاندارد.

این شرایط به منظور شبیه‌سازی عملکرد آسفالت در محیط واقعی و انطباق با استانداردهای رایج طراحی شده‌اند. با این حال، اطلاعات دقیق‌تر درباره ترکیب شیمیایی قیر یا شرایط محیطی خاص (مانند رطوبت یا دمای محیط در زمان اجرا) در داده‌های اولیه ثبت نشده بود، که در ادامه به‌عنوان یکی از محدودیت‌ها بحث می‌شود.

در ابتدا اطلاعات نمونه‌های آزمایشگاهی بتن آسفالتی از آزمایشگاه مکانیک خاک استان مازندران تهیه شده و سپس بوسیله شبکه عصبی مصنوعی مقاومت فشاری مارشال آسفالت که مهمترین پارامتر در طرح اختلاط آسفالت می‌باشد، مدل سازی می‌شود. در انتها با استفاده از فرمول بدست آمده از مدل شبکه عصبی مصنوعی مقدار بهینه قیر برای رسیدن به مقاومت فشاری مورد نظر را برای چند حالت مختلف دانه بندی بدست آورده می‌شود.

۲-۱- جمع‌آوری و آماده سازی داده‌ها

از آنجا که روش‌های مورد بحث در این تحقیق مبتنی بر تجربیات و مشاهدات قبلی استوار است، گردآوری اطلاعاتی که از نظر کمیت و تنوع مناسب باشند، کاملاً الزامی می‌باشد. بدیهی است این اطلاعات می‌بایست شامل پارامترهای موثر در مقاومت فشاری آسفالت باشند. در این پژوهش، از تعداد ۱۶۰ نمونه آزمایشگاهی بتن آسفالتی که توسط آزمایشگاه مکانیک خاک استان مازندران بر روی نمونه‌های آسفالت اجرا شده در این منطقه انجام شده، استفاده گردیده است. پارامترهای تاثیرگذار در مقاومت فشاری آسفالت که در این تحقیق استفاده شدند شامل درصد شکستگی مصالح، درصد جذب قیر مصالح، وزن مخصوص قیر، وزن مخصوص حقیقی مصالح، درصد قیر مصرفی و درصد عبوری مصالح از الک‌های ۳/۴، ۱/۲، ۳/۸، ۴، ۸، ۵۰ و ۲۰۰ می‌باشند. یک مساله بسیار مهم دیگر در گردآوری و آماده کردن اطلاعات وجود تنوع کافی می‌باشد. به طوری که اطلاعات می‌بایست شامل دامنه نسبتاً وسیعی از انواع آسفالت‌ها باشد. به طور کلی، برای حل یک مساله به کمک شبکه عصبی مصنوعی و یا هر روش داده محور دیگر مهم‌ترین قسمت داشتن مجموعه داده‌های مناسب است. مجموعه داده مناسب مجموعه‌ای است که قابل اطمینان باشد، به دقت اندازه‌گیری شده باشد و یا از منابع مناسب گردآوری شده باشد، دارای تعداد

جدول ۱. توصیف آماری مشخصات نمونه های آسفالت

مشخصات	دامنه	مینیمم	ماکزیمم	میانگین	انحراف معیار	واریانس
درصد عبوری از الک شماره ۳/۴	۱۱	۸۹	۱۰۰	۹۸,۲	۲,۲۸	۵,۲۱
درصد عبوری از الک شماره ۱/۲	۳۲,۵	۶۷,۵	۱۰۰	۸۶,۳۸	۶,۲۲	۳۸,۶۸
درصد عبوری از الک شماره ۳/۸	۳۷,۲	۵۹,۶	۹۶,۸	۷۷,۰۵	۷,۱	۵۰,۳۶
درصد عبوری از الک شماره ۴	۳۵,۲	۳۷,۸	۷۳	۵۲,۶۱	۶,۶۹	۴۴,۸
درصد عبوری از الک شماره ۸	۳۰,۶	۲۰,۲	۵۰,۸	۳۳,۳۲	۴,۱۷	۱۷,۳۶
درصد عبوری از الک شماره ۵۰	۱۴,۱	۶	۲۰,۱	۱۰,۷۸	۲	۴
درصد عبوری از الک شماره ۲۰۰	۸,۹	۱,۳	۱۰,۲	۶,۳۵	۱,۸۶	۳,۴۴
درصد شکستگی مصالح	۲۳	۷۷	۱۰۰	۹۳,۷۸	۴,۳۷	۱۹,۲
درصد جذب قیر مصالح	۰,۱۶	۰,۲۸	۰,۴۴	۰,۳۳	۰,۰۳۷۹	۰,۰۰۱۴
وزن مخصوص قیر (gr/cm ³)	۰,۰۱۶	۱,۰۰۵	۱,۰۲۱	۱,۰۱۳	۰,۰۰۵۲	۰,۰۰۰۰۲۷
وزن مخصوص حقیقی مصالح (gr/cm ³)	۰,۱۲۲	۲,۵۹۹	۲,۷۲۱	۲,۶۶	۰,۰۳۸	۰,۰۰۱۵
درصد قیر مصرفی	۲,۳	۳,۱۶	۵,۴۶	۴,۳۱	۰,۴	۰,۱۶
مقاومت مارشال (kg)	۷۹۵	۷۳۲	۱۵۲۷	۱۰۸۵,۳۵	۱۵۲,۶۵	۲۳۳۰۱,۹۷

۲-۲- انتخاب داده های اطلاعاتی

معمولا نرمال کردن الگوها تبدیلی است که المانهای آن‌ها را به بازه مشخصی مانند [۰/۹ ۰/۱] نگاشت می‌دهد. در این تحقیق برای نرمال کردن الگوها از رابطه ۱ استفاده شده است.

توصیه می‌شود تا ورودی‌های شبکه‌های عصبی مصنوعی استاندارد شوند. این کار مانع از کوچک شدن بیش از حد وزن‌ها می‌شود. بدین منظور لازم است ورودی‌های تمام نرون‌ها نرمال شوند.

(۱)

$$X_n = 0.8 \left(\frac{X - X_{Min}}{X_{Max} - X_{Min}} \right) + 0.1$$

که در آن:

X_n : معرف داده‌های نرمال شده

X : معرف داده‌های مشاهده‌ای خام

X_{Max} : معرف حداکثر داده‌های مشاهده‌ای خام

X_{Min} : معرف حداقل داده‌های مشاهده‌ای خام

کل فرآیند آموزش بر پایه یک فرض اساسی می‌باشد که داده‌های اطلاعاتی برای آموزش و آزمایش شبکه، نشان دهنده تابع نهفته مساله مورد نظر می‌باشند.

لایه ورودی

شامل ۱۲ نرون که هر یک نماینده یکی از پارامترهای ورودی هستند (درصد شکستگی مصالح، درصد جذب قیر مصالح، وزن مخصوص قیر، وزن مخصوص حقیقی مصالح، درصد قیر مصرفی، و درصد عبوری مصالح از الک‌های ۳/۴، ۱/۲، ۳/۸، ۴، ۵۰ و ۲۰۰). این پارامترها بر اساس تحلیل‌های آماری و اهمیت آن‌ها در تعیین مقاومت فشاری آسفالت انتخاب شدند.

لایه مخفی

شامل یک لایه با تعداد نرون‌های بهینه (۱۰ نرون) که با روش سعی و خطا و ارزیابی معیارهای عملکرد R^2 و RMSE تعیین شد. تابع فعال‌سازی لگاریتمی سیگموئید (Logsig) در این لایه استفاده شد، زیرا در آزمایش‌های اولیه، این تابع بهترین تعادل را بین دقت و تعمیم‌دهی مدل ارائه داد.

لایه خروجی

شامل یک نرون که مقاومت فشاری مارشال آسفالت (به کیلوگرم) را به‌عنوان خروجی پیش‌بینی می‌کند. تابع فعال‌سازی خطی (Purelin) در این لایه به کار رفت تا مقادیر پیوسته خروجی به‌درستی مدل‌سازی شوند.

تابع فعال‌سازی در لایه مخفی لگاریتمی سیگموئید بود، زیرا در مقایسه با توابع دیگر مانند Tansig و بهترین عملکرد را در آزمایش‌های اولیه نشان داد. در لایه خروجی، تابع خطی استفاده شد تا مقادیر پیوسته مقاومت فشاری به‌درستی پیش‌بینی شوند.

فرآیند آموزش شبکه با استفاده از الگوریتم Levenberg-Marquardt انجام شد که به دلیل سرعت همگرایی بالا و کارایی در مسائل با یک خروجی، مناسب این پژوهش تشخیص داده شد. این الگوریتم با بهینه‌سازی وزن‌ها و بایاس‌ها، خطای میانگین مربعات بین مقادیر پیش‌بینی‌شده و واقعی را کمینه می‌کند. داده‌ها به‌صورت ۸۰٪ (۱۲۸ نمونه) برای آموزش و ۲۰٪ (۳۲ نمونه) برای آزمایش تقسیم شدند. برای جلوگیری از بیش‌برازش، از تکنیک توقف زودهنگام استفاده شد که عملکرد مدل را در مجموعه آزمایش نظارت می‌کند و آموزش را در نقطه بهینه متوقف می‌کند. داده‌های ورودی پیش از ورود به شبکه نرمال‌سازی شدند و به بازه [۰,۹, ۰,۱] نگاشت شدند (با استفاده از رابطه $X_n = 0.1 + 0.8 \times \frac{X - X_{min}}{X_{max} - X_{min}}$) تا از تأثیر مقیاس‌های متفاوت پارامترها جلوگیری شود و همگرایی مدل بهبود یابد. وزن‌های اولیه به‌صورت تصادفی مقداردهی شدند و

به طور کلی در انتخاب داده‌ها این نکات را باید در نظر داشت. - داده‌های اطلاعاتی آموزش عمدتاً بر اساس شواهد و اتفاقات گذشته می‌باشند و لذا در صورت تغییر کلی در شرایط مساله روابط بین پارامترها نیز تغییر پیدا خواهد کرد.

شبکه‌های عصبی تنها مواردی را می‌توانند به درستی پیش‌بینی کنند که در گذشته نیز موردی تقریباً مشابه به آن اتفاق افتاده باشد و در مجموعه داده‌های اطلاعاتی آموزشی ملحوظ شده باشد و نمی‌توان انتظار داشت که شبکه در حالتی خارج از محدوده اطلاعات آموزشی پیش‌بینی صحیحی داشته باشد. در واقع شبکه‌های عصبی نوعی عملیات درون‌یابی را در فضای پارامترهای ورودی انجام می‌دهند و مدل‌های شبکه عصبی نیز تنها در بازه پارامترهای ورودی معتبر هستند. به عنوان مثال، اگر در اطلاعات ورودی برای آسفالت همه داده‌ها مربوط به حالتی باشند که مقاومت فشاری آسفالت پایین است، نمی‌توان انتظار داشت که شبکه مقادیر بالای مقاومت فشاری را به خوبی پیش‌بینی کند. داده‌های اطلاعاتی آموزشی باید شامل تمام ابعاد مساله باشند. به عنوان مثال در اطلاعات موجود برای مقاومت فشاری درصد قیر عمدتاً بین ۳ تا ۶ درصد می‌باشد. در این حالت اگر شبکه برای درصد قیر کمتر از ۳ و یا بیشتر از ۶ درصد اجرا شود جواب‌ها قابل اعتماد نخواهد بود و یا اگر دانه بندی مصالح به عنوان یکی از پارامترهای ورودی انتخاب شود باید داده‌های اطلاعاتی آموزشی شامل خاک‌هایی با دانه بندی‌های متنوع باشند. در این تحقیق از ۱۲۸ (۸۰ درصد) سری داده برای آموزش شبکه‌ها و از ۳۲ (۲۰ درصد) سری داده باقیمانده برای آزمایش عملکرد شبکه‌ها استفاده شد. انتخاب این سری داده‌ها برای مرحله آزمایش به صورت تصادفی بوده است، ولی در ادامه به بررسی غنی بودن اطلاعات پرداخته شد و پس از چند بار سعی و خطا، ۳۲ سری داده که به صورت تصادفی انتخاب شده باشند و شرایط غنی بودن را نیز دارا باشند، بدست آمدند.

۲-۱- نحوه عملکرد مدل شبکه عصبی مصنوعی

مدل شبکه عصبی مصنوعی استفاده‌شده در این پژوهش از نوع پرسپترون چندلایه است که به دلیل توانایی بالای آن در مدل‌سازی روابط غیرخطی پیچیده بین متغیرهای ورودی و خروجی انتخاب شد. این شبکه شامل سه لایه اصلی است.

داده‌ها در مقایسه با نتایج تجربی مورد قضاوت قرار دهد. شاخص‌های مختلفی مورد استفاده قرار می‌گیرند که چند نمونه از آن‌ها به شرح زیر هستند:

- ضریب همبستگی (R): این شاخص نشان دهنده درجه اعتبار بین دو متغیر می‌باشد. ضریب همبستگی به صورت رابطه ۲ تعریف می‌شود.

$$R^2 = 1 - \frac{\sum_{i=1}^n (x-y)^2}{\sum_{i=1}^n (x-y)^2}$$

- جذر میانگین مربعات خطا^۴: این شاخص متوسط مقدار خطا بین نتایج خروجی و مقدار واقعی را بیان می‌کند.

که در آن x ها مقادیر واقعی و y ها مقادیر پیش‌بینی شده توسط شبکه و مدل و n تعداد داده‌ها در مرحله آزمایش می‌باشد. هر چه مقدار RMSE به صفر نزدیکتر باشد، نشان دهنده نزدیک‌تر بودن مقادیر مشاهده شده و محاسبه شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x-y)^2}{n}}$$

روش فوق توسط مارگوارد در سال ۱۹۹۳ و لیونبرگ در سال ۱۹۹۴ مطرح شد و یک روش غیر خطی بهینه‌سازی می‌باشد. این روش معمولاً سریع‌تر از بقیه روش‌ها عمل می‌کند ولی دارای چند محدودیت است. از جمله این که این روش فقط برای شبکه‌هایی با یک خروجی قابل استفاده بوده و با افزایش تعداد وزن‌ها حجم حافظه مورد نیاز این روش به شدت (توان ۲) افزایش پیدا می‌کند، لذا برای شبکه‌های بزرگ محدودیت دارد. با توجه به اینکه خروجی شبکه مورد نظر در این تحقیق دارای یک خروجی و مشکل حافظه مطرح نبود از این روش استفاده شد.

فرآیند آموزش چندین بار تکرار شد تا بهترین پیکربندی با کمترین خطا به دست آید.

۳-۲- معیارهای ارزیابی عملکرد مدل

برای مقایسه مدل‌ها با یکدیگر و ارزیابی آن‌ها نیاز به شاخص‌هایی است که بتواند کارکرد مدل‌ها را در کل مجموعه

(۲)

که در آن x مقدار واقعی، y مقدار پیش‌بینی شده برای x و \bar{x} و \bar{y} میانگین x ها و y ها می‌باشد. اگر مقدار R^2 بیشتر از ۰٫۸ شود، نشان دهنده ارتباط قوی بین مقادیر واقعی و مقادیر پیش‌بینی شده است و در مقابل مقادیر پایین R^2 ارتباط ضعیف و یا عدم ارتباط بین مقادیر را نشان می‌دهد. این شاخص بین مجموعه خروجی‌های واقعی و نتایج حاصل از پیش‌بینی مدل برازش خطی انجام می‌دهد. نزدیک بودن نتایج مدل به خط $y = x$ مبنای قوی بودن همبستگی است.

(۳)

۴-۲- روش آموزش شبکه

در این تحقیق از یک پرسپترون سه لایه استفاده شده است. روش‌های مختلف آموزش پرسپترون چند لایه به صورت متفاوت عمل می‌کنند، اما، هدف همه آن‌ها حرکت به سمت خطای مینیمم با سرعت هر چه بیشتر می‌باشد. روش Levenberg-Marquardt در حین آموزش، جهت بیشترین شیب در صفحه را برای رسیدن به خطای مینیمم به دست می‌آورد و متناسب با میزان یادگیری در آن جهت گام بر می‌دارد. در واقع شیب کاهشی برای هر داده به طور کاملاً جداگانه بر روی سطح خطا محاسبه می‌شود و ترتیب انتخاب داده‌ها به صورت تصادفی می‌باشد ولی در نهایت تقریب خوبی برای شیب کل سطح خطا به دست می‌آید.

چندین بار از ابتدا با انتخاب وزن‌های اولیه تصادفی انجام می‌گردد تا کمترین خطا حاصل شود. نکته قابل ذکر این‌که مقدار دهی اولیه تاثیر نسبتاً زیادی در سرعت کاهش خطا و موفقیت در رسیدن به مینیمم کلی دارد. در نتیجه برای آموزش هر شبکه چندین بار عمل مقداردهی تصادفی، آموزش و آزمایش انجام شده است تا بهترین نتیجه و کمترین خطای ممکن حاصل شود. تابع جمع نیز در شبکه MLP به صورت خطی می‌باشد و در واقع جمع وزنی ورودی‌ها مستقیماً به عنوان ورودی به تابع فعالیت منتقل می‌شود یا به بیان برداری حاصل ضرب داخلی دو بردار وزن‌ها و ورودی‌ها را به عنوان ورودی نهایی به تابع فعالیت می‌دهد.

ورودی با تعداد نرون‌های ورودی باید برابر باشد. همچنین تعداد سطرها ماتریس خروجی نیز باید با تعداد نرون‌های خروجی برابر باشد. در این تحقیق با توجه به اینکه خروجی همیشه شامل یک نرون (مقاومت فشاری آسفالت) می‌باشد، بنابراین، در خروجی نیازمند ماتریسی با یک سطر هستیم. در نرون‌های میانی (لایه پنهان)، با تغییر در نوع و تعداد نرون‌های ورودی و در نتیجه رسیدن به تعداد نرون‌های بهینه، نیازمند ایجاد ماتریس‌هایی با ابعاد مختلف می‌باشیم تا بتوان شبکه را تشکیل داد. از طرفی حجم داده‌های ورودی و خروجی بسیار بالا می‌باشد و تشکیل چنین ماتریس‌هایی بسیار وقت گیر می‌باشد. به همین دلیل برای انجام کار برنامه‌ای در محیط MATLAB نوشته شده است.

این برنامه نوشته شده ماتریس‌های ورودی را از روی پارامترهای ورودی کاربر تشکیل می‌دهد. از مزیت‌های این برنامه می‌توان به راحتی کار و جلوگیری از اتلاف زمان اشاره کرد. با این برنامه می‌توان چندین ساختار مختلف شبکه را برای داده‌های ورودی متفاوت در زمانی بسیار کم مورد بررسی قرار داد. با توجه به اینکه ساختار کلی شبکه‌های عصبی مصنوعی بصورت آزمون و خطا بدست می‌آید، و از طرفی تعداد زیاد پارامترهایی که در کارایی شبکه موثر هستند، نیاز به ساخت شبکه‌های عصبی در ساختارهای مختلف و پارامترهای متفاوت، باعث شده است که برنامه ریزی برای کل فرآیند ساختار شبکه در ردیف کارهای این تحقیق قرار بگیرد. از این رو کلیه مراحل ساختار شبکه عصبی مصنوعی در یک برنامه جامع آورده شده است. کلیات مراحل انجام شبیه سازی در فلوچارت شکل (۱) نشان داده شده است.

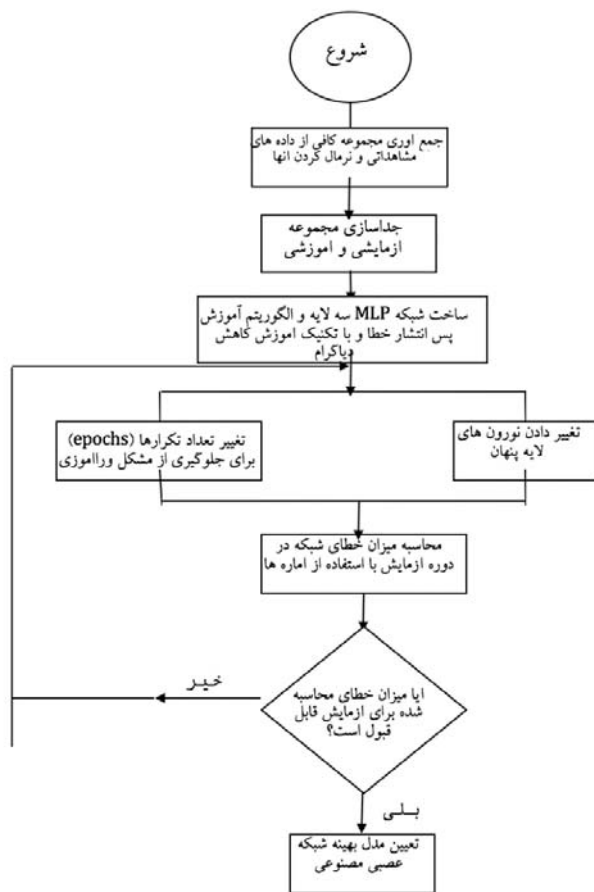
در این روش، فرض می‌شود تابع مورد نظر برای مدل‌سازی یک تابع خطی است، بنابراین در یک گام مینیمم به دست می‌آید و در صورت کوچک‌تر بودن خطا در موقعیت جدید، وزن‌های شبکه برای قرار گرفتن در این موقعیت تنظیم می‌شوند؛ در غیر این صورت از این گام صرف نظر می‌شود. فرض خطی بودن تابع در نزدیکی مینیمم تقریباً قابل قبول بوده، در حالی که در فاصله‌ای دور از مینیمم این فرض تقریب بسیار بالایی دارد. قبل از شروع مرحله آموزش وزن‌های اولیه به صورت تصادفی انتخاب می‌شوند. سپس با تغییر در پارامترهای شبکه از قبیل تعداد لایه‌های مخفی، تعداد نرون‌های لایه و یا لایه‌های مخفی، عدد مومنتم، نرخ آموزش، تابع فعالیت و غیره، مرحله آموزش

۲-۵- معماری شبکه و تابع فعالیت

انتخاب معماری در محاسبات مربوط به شبکه عصبی با روش سعی و خطا می‌باشد و شاید از ضعف‌های عمده این تکنیک باشد، طی آن با استفاده از ارقام مختلف لایه‌های پنهان و نرون‌های مربوط، می‌توان شبکه بهینه را تعیین نمود. هر چه تعداد لایه‌ها و نرون‌ها افزایش یابد، باعث عملکرد بهتر شبکه برای دوره آموزش می‌شود و اما همین معیارها برای دوره آزمون شبکه کاهش می‌یابد. این مسأله را برازش بیش از حد اطلاق می‌کنند و بدین سبب بروز می‌کند که شبکه به خاطر داشتن تعداد زیادی لایه‌ی پنهان نرون‌های مربوط، بیش از اندازه بر اساس داده‌های دوره آموزش واسنجی می‌گردد و قدرت انعطاف را برای دیگر الگوها از دست می‌دهد، لذا معیاری مانند R^2 برای دوره آموزش بسیار بالا و برای دوره آزمون بسیار پایین می‌شود. توابع فعالیت مختلفی مانند *Logsig*, *Tansig*, *Purelin* در لایه پنهان و خروجی آزمایش شدند که تابع فعالیت *Logsig* عملکرد بهتری نسبت به سایر توابع نشان داد و این تابع به عنوان تابع فعالیت انتخاب گردید.

۲-۶- الگوریتم برنامه

در اولین مرحله از تشکیل شبکه‌های عصبی، شبکه مورد نظر با ساختار دلخواه ایجاد شد. دو پارامتر تشکیل دهنده ساختار شبکه، تعداد نرون‌های ورودی و خروجی می‌باشند. برای اینکه بتوان ماتریس‌های ورودی و خروجی را وارد شبکه کرد، نیاز به هماهنگی بین ابعاد ماتریس‌های ورودی و خروجی با تعداد نرون‌های ورودی و خروجی است. یعنی تعداد سطرها ماتریس



شکل ۱. فلوچارت مراحل انجام پیش بینی با مدل ANN

۷-۲- معرفی نرم افزار MATLAB

مسائل آن‌هاست، آشنا می‌شوند. نام MATLAB اختصار عبارت MATLAB LABORATORY می‌باشد. محیط محاوره‌ای و کاربردی MATLAB می‌تواند با برنامه‌هایی که توسط کاربر به زبان FORTRAN یا C نوشته می‌شود توسعه یابد. MATLAB یک زبان برنامه نویسی سطح بالا بوده و برنامه نویسی در آن بسیار راحت است. در این تحقیق از بسته نرم افزاری MATLAB (ویرایش ۷) استفاده شده است و با نوشتن برنامه‌ای در این محیط جهت شبیه سازی و تهیه مدل پیش بینی مقاومت فشاری آسفالت، اقدام شده است.


MATLAB یک نرم افزار جهت استفاده دانشجویان و محققین رشته های ریاضی و مهندسی است که اولین نگارش‌های آن در دانشگاه نیومکزیکو و استانفورد در سال ۱۹۷۰ در جهت حل مسائل تئوری ماتریس‌ها، جبر خطی و آنالیز عددی بوجود آمد و امروزه صدها هزار کاربر دانشگاهی، صنعتی و ... در زمینه‌های بسیار متنوع مهندسی نظیر ریاضیات پیشرفته، جبر خطی، مخبرات، مهندسی سیستم و ... با MATLAB به عنوان یکی از اولین محیط های محاسباتی و تکنیکی که قادر به حل

۳- نتایج و بحث


۳-۱- نتایج مدل شبکه عصبی مصنوعی

است در ابتدا مقدار خطای شبکه زیاد می‌باشد و به مجرد شروع آموزش این مقدار کاهش می‌یابد. پس از یک تا چند دوره آموزش در اکثر شبکه‌های طراحی شده خطای شبکه ثابت و روند کاهشی آن تقریباً متوقف می‌شود. از این مرحله به بعد با تغییر پارامترهای نرخ آموزش و عدد مومنتم از مینیمم‌های محلی رهایی یافته و شبکه به مینیمم کلی نزدیک می‌شود. تغییر توابع فعالیت نیز هم‌چنین در رسیدن به بهترین پاسخ موثر است. اگر چه این امر منوط به طراحی صحیح شبکه و انتخاب صحیح داده‌های اطلاعاتی و پارامترهای در نظر گرفته شده به عنوان ورودی مساله می‌باشد. بهترین نتیجه عملکرد این مدل در هر دو قسمت آموزش و آزمایش در جدول ۲ نشان داده شده است. به منظور ارزیابی بهتر عملکرد مدل، در شکل‌های ۲ و ۳ منحنی پراکندگی مقاومت فشاری آسفالت پیش بینی شده در مقابل مقاومت فشاری واقعی در مرحله آموزش و آزمایش نشان داده شده است. همان طور که در جدول ۲ و شکل‌های ۲ و ۳ مشاهده می‌شود مدل ANN عملکرد قابل قبولی در پیش بینی مقاومت فشاری آسفالت داشته است.

مدل شبکه MLP مورد استفاده در این تحقیق به دلیل تعداد ۱۲ عدد پارامتر ورودی، دارای ۱۲ نرون در لایه ورودی می‌باشد. در لایه خروجی، شبکه فقط دارای یک نرون می‌باشد که خروجی را تعیین می‌کند. پارامترهای ورودی شامل درصد شکستگی مصالح، درصد جذب قیر مصالح، وزن مخصوص قیر، وزن مخصوص حقیقی مصالح، درصد قیر مصرفی و درصد عبوری مصالح از الک‌های ۳/۴، ۱/۲، ۳/۸، ۴، ۸، ۵۰ و ۲۰۰ می‌باشند. مقدار مقاومت فشاری آسفالت نیز پارامتر خروجی شبکه می‌باشد. بعد از آزمایش انواع شبکه‌ها بهترین نتیجه در شبکه‌های با یک لایه مخفی به دست آمد. لذا شبکه MLP مورد استفاده دارای یک لایه ورودی، یک لایه میانی و یک لایه خروجی می‌باشند. اگر چه تعداد لایه‌های میانی را می‌توان بیشتر در نظر گرفت ولی به علت افزایش تعداد وزن‌ها نسبت به تعداد داده‌های اطلاعاتی و نیز تاثیر ناچیز آن، به یک لایه میانی اکتفا شده است. دسته آموزش برای آموزش شبکه مورد استفاده قرار می‌گیرند و دسته آزمایش برای نظارت بر کارایی شبکه و جلوگیری از بیش‌آموزش آن در مرحله آموزش و رسیدن به روابط پیچیده میان مقادیر ورودی و خروجی به کار می‌روند. با توجه به این که مقدار دهی اولیه وزن‌ها به صورت تصادفی



شکل ۲. منحنی پراکندگی مقاومت فشاری آسفالت در مرحله آموزش



شکل ۳. منحنی پراکندگی مقاومت فشاری آسفالت در مرحله آزمایش

جدول ۲. نتایج عملکرد مدل ANNs

		مرحله آموزش		مرحله آزمایش	
شاخص ارزیابی		R ²	RMSE	R ²	RMSE
خروجی	مقاومت فشاری	۰,۹۳۹	۳۹,۳۷	۰,۸۶۳	۳۷,۶۶

۲-۲- آنالیز حساسیت پارامترهای ورودی

بعد از به دست آمدن شبکه بهینه و مشخص شدن وزن‌های آن، می‌توان به کمک وزن‌ها اهمیت نسبی پارامترها و میزان تاثیر هر یک از آن‌ها در خروجی را به دست آورد. محاسبه اهمیت نسبی پارامترها با استفاده از روش پیشنهادی گارسن انجام شده است. اهمیت نسبی پارامترهای مربوط به مدل مقاومت فشاری در جدول ۳ آمده است. مراحل محاسبه اهمیت نسبی پارامترها به ترتیب زیر انجام می‌شود.

برای هر نرون در لایه میانی (i) قدرمطلق حاصلضرب وزن‌های اتصال‌های این نرون با هر نرون در لایه ورودی (j) در وزن‌های اتصال این نرون با لایه خروجی آن محاسبه می‌شود. به این صورت که شماره نرون ورودی j و شماره نرون لایه

پنهان i و مقادیر حاصلضرب‌ها (P_{ij}) می‌باشند. این کار

درمورد تمامی متغیرهای ورودی (j) صورت می‌گیرد.

در هر نرون لایه میانی برای محاسبه Q_{ij} ها هر P_{ij} بر مجموع P_{ij} های آن نرون تقسیم می‌شود.

برای هر نرون در لایه ورودی برای محاسبه S_j مجموع Q_{ij} های مربوط به این نرون محاسبه می‌شود.

اهمیت نسبی هر یک از متغیرهای ورودی به صورت حاصل

تقسیم S_j بر مجموع مقادیر این پارامتر درمورد تمام متغیرهای ورودی بر حسب درصد محاسبه می‌گردد (Garson et al, 1991).

جدول ۳. اهمیت نسبی پارامترهای مدل ANN (برحسب درصد)

پارامترهای ورودی	اهمیت نسبی %
درصد شکستگی مصالح	۱۱,۵۷
درصد جذب قیر مصالح	۳,۶۸
وزن مخصوص قیر	۳,۳۱
درصد قیر مصرفی	۱۵,۸۴
وزن مخصوص حقیقی مصالح	۱۰,۱۸
درصد عبوری از الک شماره ۳/۴	۸,۷۲
درصد عبوری از الک شماره ۱/۲	۷,۱۸
درصد عبوری از الک شماره ۳/۸	۷,۶۳
درصد عبوری از الک شماره ۴	۶,۸۴
درصد عبوری از الک شماره ۸	۷,۸۶
درصد عبوری از الک شماره ۵۰	۸,۲۸
درصد عبوری از الک شماره ۲۰۰	۸,۹۰

کیفیت مورد نظر مهمترین مورد در طرح اختلاط آسفالت گرم می باشد. با استفاده از فرمول ماتریسی بدست آمده از شبکه عصبی مصنوعی بین پارامترهای ورودی و مقاومت فشاری آسفالت و همچنین قرار دادن شرط مقاومت فشاری حداقل ۱۰۰۰ کیلوگرم در برنامه بهینه سازی برای ۴ حالت مختلف دانه بندی، مقدار بهینه قیر بدست آمد. ۴ پارامتر درصد شکستگی مصالح، درصد جذب قیر مصالح، وزن مخصوص قیر و وزن مخصوص حقیقی مصالح در هر ۴ حالت مختلف دانه بندی ثابت فرض شده است. در جدول (۴) مقدار پارامترهای ثابت ورودی برای هر ۴ حالت مختلف دانه بندی آورده شده است. این مقادیر با توجه به میانگین داده‌های مورد استفاده تعیین شده‌اند.

در ادامه برنامه LINGO برای چهار حالت مختلف دانه بندی با شرط مقاومت فشاری حداقل ۱۰۰۰ کیلوگرم و بر اساس فرمول ماتریسی بدست آمده از شبکه عصبی مصنوعی بین

با توجه به نتایج مشخص می‌شود که تمام پارامترهای ورودی تاثیر قابل توجهی بر مقاومت فشاری آسفالت دارند و درصد قیر مصرفی بیشترین تاثیر و وزن مخصوص قیر کمترین تاثیر را دارند. در این جا می‌توان گفت در پیش‌بینی مقاومت فشاری آسفالت مشکلی دیده نمی‌شود و این شبکه‌ها با وزن‌های به دست آمده قادر به پیش‌بینی آن با دقت بسیار بالا می‌باشند. اگر چه در صورت دسترسی به اطلاعات متنوع‌تر از نمونه‌های آزمایش مارشال دیگر استان و یا مناطق دیگر (پارامترهای با بازه متنوع‌تر) و استفاده از آن‌ها در آموزش، قدرت تعمیم‌دهی این شبکه‌ها افزایش پیدا خواهد کرد.

۳-۳- بهینه‌سازی مقدار قیر مصرفی با استفاده از

LINGO

با توجه به هزینه قابل توجه قیر در ساخت آسفالت و تاثیر زیاد آن در کیفیت آسفالت، پیدا کردن مقدار قیر بهینه برای رسیدن به

است. مقدار قیر مینیمم و همچنین دانه بندی استفاده شده برای هر چهار حالت در جدول (۵) آورده شده است.

پارامترهای ورودی و مقاومت فشاری آسفالت برای بدست آوردن مقدار قیر مصرفی بهینه (مینیمم) اجرا شد. شرط دیگر دامنه مقدار قیر مصرفی می باشد که بین ۳ تا ۶ درصد قابل تغییر

جدول ۴. مقدار پارامترهای ثابت ورودی در بهینه یابی مقدار قیر

مقدار	ورودی های ثابت
۹۴	درصد شکستگی مصالح
۰,۳۳	درصد جذب قیر مصالح
۱,۰۱۳	وزن مخصوص قیر
۲,۶۶	وزن مخصوص حقیقی مصالح

دانه بندی ۳ که یک دانه بندی ریز دانه محسوب می شود برای رسیدن به مقاومت فشاری بالای ۱۰۰۰ کیلوگرم برنامه مقدار قیر ۴,۶۹ درصد را لازم دانسته است. این مورد از نظر تئوری درست می باشد چون وقتی دانه بندی ریز دانه باشد سطح خارجی سنگ دانه ها (که می بایست توسط قیر پوشش داده شود) افزایش می یابد. البته شایان ذکر است که زیاد شدن درصد قیر مصرفی به مقدار قابل توجه هزینه تهیه آسفالت را افزایش می دهد. در حالت دانه بندی ۴ که یک دانه بندی خیلی درشت دانه محسوب می شود، برنامه نتوانست مقدار قیری برای رسیدن به مقاومت فشاری بالای ۱۰۰۰ کیلوگرم حداقل در بازه ۳ تا ۶ درصد بدست آورد.

در حالت دانه بندی ۱ که یک دانه بندی نرمال می باشد درصد قیر مصرفی ۴,۲۰ بدست آمد که مقدار معمولی در طرح اختلاط آسفالت گرم می باشد و حداقل در این مورد نشان می دهد که رابطه بدست آمده برای مقاومت فشاری آسفالت درک قابل قبولی از نتایج آزمایشگاهی دارد. در حالت دانه بندی ۲ که یک دانه بندی درشت دانه به حساب می آید برای رسیدن به مقاومت فشاری بالای ۱۰۰۰ کیلوگرم برنامه مقدار قیر ۳,۸۸ درصد را کافی دانسته است. این مورد از نظر تئوری درست می باشد چون وقتی دانه بندی درشت دانه باشد سطح خارجی سنگ دانه ها (که می بایست توسط قیر پوشش داده شود) کاهش می یابد ولی احتمال دارد که این نمونه شرایط دیگر طرح اختلاط مارشال مانند وزن مخصوص آسفالت را پوشش ندهد. در حالت

جدول ۵. مقدار قیر مصرفی مینیمم بدست آمده از LINGO برای ۴ حالت مختلف دانه بندی

پارامترهای ورودی	دانه بندی ۱	دانه بندی ۲	دانه بندی ۳	دانه بندی ۴
درصد عبوری از الک شماره ۳/۴	۹۸	۹۲	۱۰۰	۸۹
درصد عبوری از الک شماره ۱/۲	۸۶	۷۴	۹۸	۶۸
درصد عبوری از الک شماره ۳/۸	۷۷	۶۴	۹۰	۶۰
درصد عبوری از الک شماره ۴	۵۳	۴۱	۶۵	۳۸
درصد عبوری از الک شماره ۸	۳۳	۲۵	۴۳	۲۱
درصد عبوری از الک شماره ۵۰	۱۱	۷	۱۵	۶
درصد عبوری از الک شماره ۲۰۰	۶	۳	۹	۱,۵
درصد قیر مصرفی	۴,۲۰	۳,۸۸	۴,۶۹	-

۳-۴- تأثیر دانه‌بندی بر مقاومت مارشال و مقدار قیر مصرفی

دانه‌بندی نرمال (حالت ۱)

مشخصات: درصد عبوری از الک‌ها به ترتیب ۹۸٪ (۳/۴)، ۸۶٪ (۱/۲)، ۷۷٪ (۳/۸)، ۵۳٪ (۴)، ۳۳٪ (۸)، ۱۱٪ (۵۰) و ۶٪ (۲۰۰).
مقدار قیر بهینه: ۴.۲۰٪ (LINGO)

مقاومت مارشال پیش‌بینی شده ۱۰۸۵ (ANN) کیلوگرم (میانگین داده‌های واقعی).

تحلیل: این دانه‌بندی به‌عنوان یک حالت متعادل و نزدیک به استانداردهای رایج طرح مارشال، مقدار قیر متوسطی (۴.۲۰٪) را نتیجه داد که با مقاومت مارشال مطلوب (بالای ۱۰۰۰ کیلوگرم) هم‌راستاست. این نشان‌دهنده تعادل مناسب بین اندازه ذرات ریز و درشت است که هم پوشش‌دهی قیر را تضمین می‌کند و هم از مصرف اضافی قیر جلوگیری می‌کند.

دانه‌بندی درشت‌دانه (حالت ۲)

مشخصات: درصد عبوری از الک‌ها به ترتیب ۹۲٪ (۳/۴)، ۷۴٪ (۱/۲)، ۶۴٪ (۳/۸)، ۴۱٪ (۴)، ۲۵٪ (۸)، ۷٪ (۵۰) و ۳٪ (۲۰۰).
مقدار قیر بهینه: ۳.۸۸٪ (LINGO)

مقاومت مارشال پیش‌بینی شده ۱۰۰۵ (ANN) کیلوگرم (حداقل مقاومت هدف).

تحلیل: در این حالت، کاهش ذرات ریز (مانند درصد عبوری ۳٪ از الک ۲۰۰ در مقابل ۶٪ در حالت نرمال) منجر به کاهش سطح ویژه سنگ‌دانه‌ها شد. این کاهش باعث شد که مقدار قیر کمتری (۳.۸۸٪) برای رسیدن به مقاومت حداقل ۱۰۰۰ کیلوگرم کافی باشد. از نظر تئوری، این یافته با کاهش نیاز به قیر برای پوشش‌دهی سطح سنگ‌دانه‌ها سازگار است، اما ممکن است فضای خالی بیشتری ایجاد کند که باید در تحلیل‌های تکمیلی بررسی شود.

دانه‌بندی ریزدانه (حالت ۳)

مشخصات: درصد عبوری از الک‌ها به ترتیب ۱۰۰٪ (۳/۴)، ۹۸٪ (۱/۲)، ۹۰٪ (۳/۸)، ۶۵٪ (۴)، ۴۳٪ (۸)، ۱۵٪ (۵۰) و ۹٪ (۲۰۰).
مقدار قیر بهینه: ۴.۶۹٪ (LINGO)

مقاومت مارشال پیش‌بینی شده (ANN): ۱۱۲۰ کیلوگرم.

تحلیل: افزایش ذرات ریز (مانند درصد عبوری ۹٪ از الک ۲۰۰ در مقابل ۶٪ در حالت نرمال) سطح ویژه سنگ‌دانه‌ها را افزایش داد و در نتیجه، برای پوشش‌دهی کامل و دستیابی به مقاومت مارشال بالای ۱۰۰۰ کیلوگرم، مقدار قیر بیشتری (۴.۶۹٪) لازم بود. این افزایش قیر با تئوری‌های مهندسی آسفالت هم‌خوانی دارد، اما هزینه بالاتر را به دنبال دارد که باید در کاربردهای عملی مدنظر قرار گیرد.

دانه‌بندی خیلی درشت‌دانه (حالت ۴)

مشخصات: درصد عبوری از الک‌ها به ترتیب ۸۹٪ (۳/۴)، ۶۸٪ (۱/۲)، ۶۰٪ (۳/۸)، ۳۸٪ (۴)، ۲۱٪ (۸)، ۶٪ (۵۰) و ۱.۵٪ (۲۰۰).
مقدار قیر بهینه: ۳-۶٪ (LINGO) ناممکن در بازه ۳-۶٪.

مقاومت مارشال پیش‌بینی شده (ANN) کمتر از ۱۰۰۰ کیلوگرم در بازه قیر مجاز.

تحلیل: این دانه‌بندی با کاهش شدید ذرات ریز (مانند ۱.۵٪ عبوری از الک ۲۰۰)، سطح ویژه را به حداقل رساند، اما به دلیل عدم وجود ذرات کافی برای پر کردن فضاهای خالی و ایجاد چسبندگی مناسب، حتی با حداکثر قیر مجاز (۶٪) نتوانست به مقاومت ۱۰۰۰ کیلوگرم برسد. این نتیجه نشان‌دهنده محدودیت دانه‌بندی‌های بیش‌ازحد درشت در تأمین مقاومت مارشال است.

تحلیل عمیق تر مشکلات هزینه‌ای ناشی از افزایش درصد قیر

بنابراین، حتی تغییرات اندک در درصد قیر می‌تواند تأثیرات اقتصادی چشمگیری در پروژه‌های راه‌سازی داشته باشد. برای تحلیل عمیق‌تر، فرض می‌کنیم هزینه قیر در بازار ایران (بر اساس قیمت‌های تقریبی سال ۱۴۰۳) حدود ۲۰ میلیون تومان به ازای هر تن باشد، و هزینه مصالح سنگی (شن و ماسه) حدود ۲۰۰ هزار تومان به ازای هر تن. با این فرض، هزینه تولید یک تن آسفالت برای حالات مختلف دانه‌بندی به صورت زیر تخمین زده می‌شود.

در این پژوهش، نتایج بهینه‌سازی با LINGO نشان داد که مقدار قیر مصرفی بهینه برای دانه‌بندی‌های مختلف بین ۳,۸۸٪ تا ۴,۶۹٪ متغیر است، با این حال، افزایش درصد قیر (به‌ویژه در دانه‌بندی ریزدانه با ۴,۶۹٪) هزینه‌های تولید آسفالت را به‌طور قابل توجهی تحت تأثیر قرار می‌دهد. قیر به‌عنوان یکی از گران‌ترین اجزای مخلوط آسفالت گرم، معمولاً ۵۰-۷۰٪ از هزینه کل مواد اولیه را تشکیل می‌دهد. (Yu et al., 2015)

دانه‌بندی نرمال (۴,۲۰٪ قیر)

$$\text{قیر} = ۸۴۰,۰۰۰ = ۰.۰۴۲ \times ۲۰,۰۰۰,۰۰۰$$

$$\text{مصالح سنگی} = ۱۹۱,۶۰۰ = ۰.۰۹۵۸ \times ۲۰۰,۰۰۰$$

$$\text{جمع کل: حدود } ۱,۰۳۱,۶۰۰ \text{ تومان به ازای هر تن.}$$

دانه‌بندی درشت‌دانه (۳,۸۸٪ قیر)

$$\text{قیر} = ۷۷۶,۰۰۰ = ۰.۰۳۸۸ \times ۲۰,۰۰۰,۰۰۰$$

$$\text{مصالح سنگی} = ۱۹۲,۲۴۰ = ۰.۰۹۶۱۲ \times ۲۰۰,۰۰۰$$

$$\text{جمع کل: حدود } ۹۶۸,۲۴۰ \text{ تومان به ازای هر تن (۶,۲٪ کاهش نسبت به حالت نرمال).}$$

دانه‌بندی ریزدانه (۴,۶۹٪ قیر)

$$\text{قیر} = ۹۳۸,۰۰۰ = ۰.۰۴۶۹ \times ۲۰,۰۰۰,۰۰۰$$

$$\text{مصالح سنگی} = ۱۹۰,۶۲۰ = ۰.۰۹۵۳۱ \times ۲۰۰,۰۰۰$$

$$\text{جمع کل: حدود } ۱,۱۲۸,۶۲۰ \text{ تومان به ازای هر تن (۹,۴٪ افزایش نسبت به حالت نرمال).}$$

این محاسبات نشان می‌دهد که افزایش قیر از ۴,۲۰٪ (حالت نرمال) به ۴,۶۹٪ (حالت ریزدانه) هزینه هر تن آسفالت را حدود ۹۷,۰۰۰ تومان (۹,۴٪) افزایش می‌دهد، در حالی که کاهش آن به ۳,۸۸٪ (حالت درشت‌دانه) حدود ۶۳,۰۰۰ تومان (۶,۲٪) صرفه‌جویی به همراه دارد. در مقیاس یک پروژه راه‌سازی با حجم ۱۰,۰۰۰ تن آسفالت، این تفاوت‌ها به ترتیب به افزایش هزینه ۹۷۰ میلیون تومانی یا صرفه‌جویی ۶۳۰ میلیون تومانی منجر می‌شود.

۴-ارزیابی حساسیت مدل

تحلیل حساسیت در این پژوهش با هدف شناسایی میزان تأثیر هر یک از پارامترهای ورودی بر خروجی مدل (مقاومت فشاری مارشال آسفالت) انجام شد. روش گارسن که مبتنی بر وزن‌های شبکه عصبی مصنوعی است، برای محاسبه اهمیت نسبی پارامترها استفاده شد. این روش با بررسی وزن‌های اتصال بین لایه‌های ورودی، مخفی، و خروجی، سهم هر پارامتر را به‌صورت درصد محاسبه می‌کند. نتایج اولیه (جدول ۳) نشان داد که:

درصد قیر مصرفی (۱۵,۸۴٪) بیشترین تأثیر را بر مقاومت مارشال دارد.

وزن مخصوص حقیقی مصالح (۱۰,۱۸٪) و درصد شکستگی مصالح (۱۱,۵۷٪) در رتبه‌های بعدی قرار دارند.

پارامترهای دانه‌بندی (الک‌های ۳/۴ تا ۲۰۰) در مجموع حدود ۵۵٪ از اهمیت نسبی را تشکیل می‌دهند. وزن مخصوص قیر (۳,۳۱٪) و درصد جذب قیر مصالح (۳,۶۸٪) کمترین تأثیر را دارند.

-تأثیر تغییر پارامترها بر نتایج

درصد قیر مصرفی

تغییر: میانگین ۴,۳۱٪ به ۴,۷۴٪ (۱۰+٪) و ۳,۸۸٪ (۱۰-٪)

تأثیر بر مقاومت مارشال: افزایش به ۴,۷۴٪ مقاومت را از ۱۰۸۵ کیلوگرم (میانگین داده‌ها) به ۱۱۵۲ کیلوگرم (۶,۲+٪) و کاهش به ۳,۸۸٪ آن را به ۱۰۱۸ کیلوگرم (۶,۲-٪) تغییر داد.

تأثیر بر قیر بهینه: در دانه‌بندی نرمال، قیر بهینه برای مقاومت حداقل ۱۰۰۰ کیلوگرم با افزایش قیر به ۴,۱٪ (-۲,۴٪ نسبت به ۴,۲۰٪) و با کاهش به ۴,۳۵٪ (۳,۶+٪) تغییر کرد.

تحلیل: این حساسیت بالا نشان‌دهنده نقش حیاتی قیر در چسبندگی و پایداری مخلوط است، اما تغییرات کوچک نیز می‌تواند بهینه‌سازی هزینه را تحت تأثیر قرار دهد.

درصد عبوری از الک ۲۰۰ (ذرات ریز)

تغییر: میانگین ۶,۳۵٪ به ۶,۹۹٪ (۱۰+٪) و ۵,۷۲٪ (۱۰-٪)

تأثیر بر مقاومت مارشال: افزایش به ۶,۹۹٪ مقاومت را به ۱۱۱۰ کیلوگرم (۲,۳+٪) و کاهش به ۵,۷۲٪ آن را به ۱۰۶۰ کیلوگرم (۲,۳-٪) رساند.

تأثیر بر قیر بهینه: در دانه‌بندی نرمال، قیر بهینه به ۴,۲۵٪ (۱,۲+٪) با افزایش ذرات ریز و به ۴,۱۵٪ (۱,۲-٪) با کاهش آن تغییر کرد. تحلیل: ذرات ریز با افزایش سطح ویژه، نیاز به قیر را بالا می‌برند، اما تأثیر آن‌ها بر مقاومت کمتر از قیر است، که با اهمیت نسبی ۸,۹۰٪ (جدول ۳) سازگار است.

درصد شکستگی مصالح

تغییر: میانگین ۹۳,۷۸٪ به ۱۰۳,۱۶٪ (۱۰+٪) و ۸۴,۴۰٪ (۱۰-٪)

تأثیر بر مقاومت مارشال: افزایش به ۱۰۳,۱۶٪ مقاومت را به ۱۱۲۵ کیلوگرم (۳,۷+٪) و کاهش به ۸۴,۴۰٪ آن را به ۱۰۴۵ کیلوگرم (۳,۷-٪) تغییر داد.

تأثیر بر قیر بهینه: قیر بهینه به ۴,۱۸٪ (۰,۵-٪) با افزایش و ۴,۲۳٪ (۰,۷+٪) با کاهش تغییر کرد.

تحلیل: شکستگی مصالح با بهبود قفل‌شدگی ذرات، مقاومت را افزایش می‌دهد، اما تأثیر آن بر قیر بهینه محدود است. وزن مخصوص قیر

تغییر: میانگین ۱,۰۱۳ به ۱,۱۱۴ (۱۰+٪) و ۰,۹۱۲ (۱۰-٪).

تأثیر بر مقاومت مارشال: افزایش به ۱,۱۱۴ مقاومت را به ۱۰۹۰ کیلوگرم (۰,۵+٪) و کاهش به ۰,۹۱۲ آن را به ۱۰۸۰ کیلوگرم (۰,۵-٪) رساند.

تأثیر بر قیر بهینه: تغییر ناچیز (کمتر از ۰,۱٪) در قیر بهینه مشاهده شد.

تحلیل: این پارامتر کم‌اهمیت (۳,۳۱٪) تأثیر اندکی بر نتایج دارد، که نشان‌دهنده وابستگی کمتر مقاومت به خواص فیزیکی قیر در مقایسه با مقدار آن است.

این تحلیل نشان می‌دهد که مدل نسبت به درصد قیر مصرفی و دانه‌بندی (به‌ویژه ذرات ریز) حساسیت بیشتری دارد، در حالی که پارامترهایی مانند وزن مخصوص قیر و درصد جذب قیر مصالح تأثیرات کمتری ایجاد می‌کنند. تغییرات قیر به‌طور مستقیم مقاومت را تحت تأثیر قرار می‌دهد و در بهینه‌سازی، حتی تغییرات کوچک (مثلاً ۰,۱۵٪) می‌تواند هزینه را به‌طور قابل توجهی تغییر دهد. دانه‌بندی نیز با تنظیم سطح ویژه و چسبندگی، تعادل بین مقاومت و قیر مصرفی را تعیین می‌کند. این یافته‌ها با مطالعات پیشین مانند (Ozgan, 2011) و (shafabakhsh et al., 2011) که قیر و دانه‌بندی را عوامل اصلی مقاومت مارشال می‌دانند، هم‌راستا است.

۵- نتیجه گیری

درصد قیر مصرفی بیشترین تاثیر و وزن مخصوص قیر کمترین تاثیر را دارند.

برای دانه بندی نرمال درصد قیر مصرفی بهینه ۴,۲۰ بدست آمد که مقدار معمولی در طرح اختلاط آسفالت گرم می باشد و در این مورد نشان داد که رابطه بدست آمده برای مقاومت فشاری آسفالت درک قابل قبولی از نتایج آزمایشگاهی دارد. نتایج نشان می دهد که مدل نسبت به درصد قیر مصرفی و دانه بندی (به ویژه ذرات ریز) حساسیت بیشتری دارد، در حالی که پارامترهایی؛ مانند، وزن مخصوص قیر و درصد جذب قیر مصالح تأثیرات کمتری ایجاد می کنند. تغییرات قیر به طور مستقیم مقاومت را تحت تأثیر قرار می دهد و در بهینه سازی، حتی تغییرات کوچک (مثلاً ۰,۱۵٪) می تواند هزینه را به طور قابل توجهی تغییر دهد. دانه بندی نیز با تنظیم سطح ویژه و چسبندگی، تعادل بین مقاومت و قیر مصرفی را تعیین می کند.

در یک دانه بندی با بافت درشت دانه برای رسیدن به مقاومت فشاری بالای ۱۰۰۰ کیلوگرم، برنامه، مقدار قیر ۳,۸۸ درصد را کافی دانست. این مورد از نظر تئوری درست می باشد، چون وقتی دانه بندی درشت دانه باشد، سطح خارجی سنگ دانه ها (که می بایست توسط قیر پوشش داده شود) کاهش می یابد، ولی احتمال دارد که این نمونه شرایط دیگر طرح اختلاط مارشال؛ مانند، وزن مخصوص آسفالت را پوشش ندهد.

در یک دانه بندی با بافت ریزدانه برای رسیدن به مقاومت فشاری بالای ۱۰۰۰ کیلوگرم، برنامه، مقدار قیر ۴,۶۹ درصد را لازم دانسته است. این مورد از نظر تئوری درست می باشد، چون وقتی دانه بندی ریزدانه باشد، سطح خارجی سنگ دانه ها (که می بایست توسط قیر پوشش داده شود) افزایش می یابد. البته شایان ذکر است که زیاد شدن درصد قیر مصرفی به مقدار قابل توجه، هزینه تهیه آسفالت را افزایش می دهد.

برای یک دانه بندی با بافت خیلی درشت دانه، برنامه نتوانست مقدار قیری برای رسیدن به مقاومت فشاری بالای ۱۰۰۰ کیلوگرم حداقل در بازه ۳ تا ۶ درصد بدست آورد.

از مهم ترین ویژگی هایی که در طرح اختلاط آسفالت مورد توجه قرار می گیرد مقاومت مارشال آسفالت می باشد. پایین بودن مقدار مقاومت مارشال آسفالت باعث پایین آمدن کارایی آن و ایجاد مشکلاتی از جمله خستگی و ترک ها می شود. از آنجایی که بتن آسفالتی مخلوطی از قیر و مصالح سنگی است، مقاومت فشاری آن نیز تابعی از دانه بندی، ویژگی های مصالح سنگی و همچنین درصد و نوع قیر مصرفی آن می باشد. با توجه به هزینه های سنگین آسفالت و نگهداری آن ضرورت استفاده از روش های جدید و پیشرفته تر در طرح و کنترل کیفی آسفالت روز به روز محسوس تر می شود. در این پژوهش، اطلاعات نمونه های آزمایشگاهی بتن آسفالتی (۱۶۰ نمونه آزمایشگاهی) از آزمایشگاه مکانیک خاک استان مازندران تهیه شد و سپس به وسیله شبکه عصبی مصنوعی، مقاومت فشاری مارشال آسفالت که مهمترین پارامتر در طرح اختلاط آسفالت می باشد، مدل سازی شد. پارامترهای ورودی شامل درصد شکستگی مصالح، درصد جذب قیر مصالح، وزن مخصوص قیر، وزن مخصوص حقیقی مصالح، درصد قیر مصرفی و درصد عبوری مصالح از الک های ۳/۴، ۱/۲، ۳/۸، ۴، ۸، ۵۰ و ۲۰۰ می باشند. مقدار مقاومت فشاری آسفالت نیز پارامتر خروجی شبکه است. برنامه LINGO برای چهار حالت مختلف دانه بندی با شرط مقاومت فشاری حداقل ۱۰۰۰ کیلوگرم بر اساس فرمول ماتریسی بدست آمده از شبکه عصبی مصنوعی بین پارامترهای ورودی و مقاومت فشاری آسفالت، برای بدست آوردن مقدار قیر مصرفی بهینه (مینیمم) اجرا شد. در انتها، با استفاده از فرمول بدست آمده از مدل شبکه عصبی مصنوعی، مقدار بهینه قیر (با شرط بازه بین ۳ تا ۶ درصد) برای رسیدن به مقاومت فشاری مورد نظر برای چند حالت مختلف دانه بندی بدست آورده شد. اهم نتایج حاصل از پژوهش حاضر، به شرح زیر است.

منحنی پراکندگی مقاومت فشاری آسفالت پیش بینی شده در مقابل مقاومت فشاری واقعی در مرحله آموزش و آزمایش نشان دادند که مدل ANN عملکرد قابل قبولی در پیش بینی مقاومت فشاری آسفالت داشته است.

با انجام آنالیز حساسیت به روش گارسن بر روی وزن های ماتریس بدست آمده از شبکه مشخص شد که تمام پارامترهای ورودی تاثیر قابل توجهی بر مقاومت فشاری آسفالت دارند و

با اقلیم یا بارگذاری متفاوت (مانند مناطق گرم و خشک) را محدود کند.

عدم ثبت برخی متغیرها: داده‌های اولیه شامل پارامترهای اصلی (دانه‌بندی، درصد قیر، و غیره) بودند، اما اطلاعاتی مانند درصد رطوبت مصالح، دمای محیط در زمان اختلاط، یا سن نمونه‌ها در زمان آزمایش به صورت سیستماتیک ثبت نشده بود. این متغیرها ممکن است بر مقاومت مارشال تأثیر داشته باشند (Ozgan, 2011).

حجم نمونه: اگرچه ۱۶۰ نمونه برای مدل‌سازی ANN کافی به نظر می‌رسد، اما در مقایسه با برخی مطالعات مشابه (مانند Zavrtanik et al., 2016 با ۱۷۲۹۶ نمونه)، حجم داده‌ها محدود است. این محدودیت می‌تواند دقت مدل را در پیش‌بینی حالات نادر یا خارج از دامنه داده‌های موجود کاهش دهد. کیفیت داده‌ها: داده‌ها از آزمایشگاه مکانیک خاک مازندران به‌عنوان یک منبع معتبر محلی جمع‌آوری شدند، اما، احتمال خطای انسانی در اندازه‌گیری‌ها یا تفاوت در تجهیزات کالیبراسیون وجود دارد که به‌صورت مستقیم بررسی نشد. این محدودیت‌ها در تحلیل نتایج مدنظر قرار گرفتند و با استفاده از نرمال‌سازی داده‌ها و انتخاب تصادفی مجموعه‌های آموزش و آزمایش، تلاش شد تا تأثیر آن‌ها به حداقل برسد. با این حال، ادعان داریم که افزودن داده‌های متنوع‌تر می‌تواند دقت و تعمیم‌پذیری مدل را بهبود بخشد.

نتایج این پژوهش نشان داد که دانه‌بندی به‌عنوان یکی از عوامل کلیدی، نه تنها بر مقدار قیر بهینه، بلکه بر مقاومت مارشال، فضای خالی و وزن مخصوص مخلوط تأثیر مستقیم دارد. افزایش قیر از ۴٫۲۰٪ (حالت نرمال) به ۴٫۶۹٪ (حالت ریزدانه)، هزینه هر تن آسفالت را حدود ۹۷٫۰۰۰ تومان (۹٫۴٪) افزایش می‌دهد و ممکن است فضای خالی را بیش از حد کاهش دهد. در حالی که کاهش آن به ۳٫۸۸٪ (حالت درشت‌دانه) حدود ۶۳٫۰۰۰ تومان (۶٫۲٪) صرفه‌جویی به همراه دارد، اما باید مراقب افزایش فضای خالی و کاهش دوام بود. در مقیاس یک پروژه راه‌سازی با حجم ۱۰٫۰۰۰ تن آسفالت، این تفاوت‌ها می‌تواند به ترتیب به افزایش هزینه ۹۷۰ میلیون تومانی یا صرفه‌جویی ۶۳۰ میلیون تومانی منجر می‌شود.

محدودیت‌ها و چالش‌های گردآوری داده‌ها

اگرچه داده‌های مورد استفاده از نظر آماری متنوع بودند (دامنه مقاومت مارشال از ۷۳۲ تا ۱۵۲۷ کیلوگرم، درصد قیر از ۳٫۱۶ تا ۵٫۴۶)، اما چالش‌ها و محدودیت‌های زیر در فرآیند جمع‌آوری و آماده‌سازی داده‌ها وجود داشت:

محدودیت جغرافیایی: تمامی نمونه‌ها از پروژه‌های استان مازندران جمع‌آوری شدند، که ممکن است تنوع شرایط آب‌وهوایی، نوع خاک، یا الگوهای ترافیکی سایر مناطق را به‌طور کامل نمایندگی نکند. این امر می‌تواند تعمیم‌پذیری مدل به مناطق

۶- پی‌نوشت‌ها

- 1- Multilayer perceptron
- 2- Artificial Neural Network
- 3- Support Vector Machine
- 4- Root Mean Squared Error

۷- مراجع

-Amouzadeh Omrani, M. (2023). Laboratory comparison of mechanical properties of emulsified cold recycled asphalt containing cement kiln dust and steel slag with recycled asphalt containing cement. *Journal of Transportation Infrastructure Engineering*, 9(3), 57-79.

-رمضانپور ن، گوران اوریمی م. (۱۳۸۹). پیش‌بینی مقاومت فشاری آسفالت و بررسی تاثیر تغییرات میزان فیلر، درصد قیر مصرفی، درصد جذب قیر مصالح و درصد شکستگی مصالح در مقاومت فشاری آسفالت با استفاده از شبکه‌های عصبی مصنوعی. *اولین کنفرانس منطقه‌ای مهندسی عمران، دانشگاه آزاد اسلامی واحد قائمشهر.*

-فخری، منصور و غنی زاده، علیرضا (۱۳۸۵). تعیین درصد بهینه قیر در روش طرح اختلاط مارشال با استفاده از یک مدل برنامه‌ریزی خطی. *پروژه‌نامه حمل و نقل، سال سوم، شماره چهارم، ۳۰۵-۳۱۴.*

- Ozgan H. (2011). Artificial neural network based modelling of the Marshall Stability of asphalt concrete. *Expert Systems with Applications*, 38, 6025–6030.
- Ozsahin TS, Oruc S. (2008). Neural network model for resilient modulus of emulsified asphalt mixtures. *Construct Build Mater.* 22, 1436–1445.
- Pourtahmasb MS, Karim MR, Shamshirband S. (2015). Resilient modulus prediction of asphalt mixtures containing Recycled Concrete Aggregate using an adaptive neuro-fuzzy methodology. *Construction and Building Materials*, 82, 257–263.
- Shafabakhsh, G. A., Ani, O. J., & Talebsafa, M. (2015). Artificial neural network modeling (ANN) for predicting rutting performance of nano-modified hot-mix asphalt mixtures containing steel slag aggregates. *Construction and Building Materials*, 85, 136-143.
- Soltani M, Baghaee Moghaddam T, Karim MR, Shamshirband S. Sudheer C. (2015). Stiffness performance of polyethylene terephthalate modified asphalt mixtures estimation using support vector machine-firefly algorithm. *Measurement*, 63, 232–239.
- Tigdemir MS, Kalyoncuoglu F, Kalyoncuoglu UY. 2004. Application of ultrasonic method in asphalt concrete testing for fatigue life estimation. *NDT&E International*, 8(7), 597–602.
- Yu B, Gu. X. Ni F, Guo R. (2015). Multi-objective optimization for asphalt pavement maintenance plans at project level: Integrating performance, cost and environment. *Transportation Research Part D*, 41, 64–74.
- Zavrtanik N. Prosen J. Tušar M. Turk G. (2016). The use of artificial neural networks for modeling air void content in aggregate mixture. *Automation in Construction*, 63, 155–161.
- AmouzadehOmrani, M., Hadizadeh, E., & Hajimirzajan, A. (2024). Investigating the causes and factors of railway accidents caused by the escape of a train carrying dangerous goods and its role in the Khayyam station accident. *Road*, 32(118), 75-90.
- Baghaee Moghaddam T. Soltani M. Karim MR, Shamshirband S, Petkovic D, Baaj H. (2015). Estimation of the rutting performance of Polyethylene Terephthalate modified asphalt mixtures by adaptive neuro-fuzzy methodology. *Construction and Building Materials*, 96, 550–555.
- Berthelot C. Crockford B. Lytton R. (1999). Comparison of Alternative Test Methods for Predicting Asphalt Concrete Rut Performance. *44th Annual Conference Canadian Technical Asphalt Association Proceedings*. Canada, 405-434.
- Cao, P. Jin F. Zhou C. Feng D. Song W. (2016). Steady-state dynamic method: An efficient and effective way to predict dynamic modulus of asphalt concrete. *Construction and Building Materials*, 111, 54–62.
- Garson, G.D. (1991). Interpreting neural-networks connection weight, *AI Expert*, 6(7), 47-51.
- Karlaftis AG, Badr A. (2015). Predicting asphalt pavement crack initiation following rehabilitation treatments. *Transportation Research Part C*.
- Mirzahosseini MR, Aghaeifar A. Alavi AH. Gandomi AH, Seyednour R. (2011). Permanent Ogundipe OM. 2016. Marshall Stability and flow of lime-modified asphalt concrete. *Transportation Research Procedia*, 14, 685-693.
- Ozgan E, Saruhan H. (2010). Modeling of asphalt concrete via simulated annealing. *Advances in Engineering Software*, 41, 680-683.

A Simulation-Optimization Model to Minimize the Bitumen of Asphalt Mixture Using LINGO

*Mohsen Amouzadeh Omrani, Department of Civil Engineering, Sava.C.,
Islamic Azad University, Savadkooh, Iran.*

*Rezvan Babagoli, Assistant Professor, Department of Civil Engineering, University of Science
and Technology of Mazandaran, Behshahr, Iran.*

Amir Izadi, Assistant Professor, Civil Department, Shomal University, Amol, Iran.

*Ali Hassannejad Esfandani, Ph.D., Student, Department of Civil Engineering, Am.C.,
Islamic Azad University, Amol, Iran.*

E-mail: Mo.Omrani@iau.ac.ir

Received: May 2025- Accepted: August 2025

ABSTRACT

One of the most important features considered in asphalt mixing design is the Marshall strength of asphalt. A low Marshall strength of asphalt reduces its efficiency and causes problems such as fatigue and cracks. Given the high impact of bitumen content on the compressive strength of asphalt and its high cost, the main goal of hot asphalt mix design is to select the most optimal bitumen content so that it can maintain the technical specifications of asphalt concrete within certain limits. Given the high costs of asphalt and its maintenance, the need to use new and more advanced methods in asphalt design and quality control is becoming more and more apparent. In this study, initially, information on 160 asphalt concrete laboratory samples was obtained from the Soil Mechanics Laboratory of Mazandaran Province, and then the compressive strength of asphalt was successfully and accurately modeled using an artificial neural network. Subsequently, the optimal bitumen content was obtained for 4 different aggregate conditions with the help of LINGO optimization software. The results showed that proper grading has a significant impact on reducing the amount of bitumen used and, consequently, the cost of asphalt.

Keywords: Compressive Strength of Asphalt, Artificial Neural Network, Optimization, LINGO