

توسعه مدل پیش‌بینی مدول برجهندگی خاک‌های رسمی ثبت شده با استفاده از شبکه عصبی مصنوعی

مقاله علمی - پژوهشی

وحید خلیفه، استادیار، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران
علیرضا غنی‌زاده، دانشیار، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران
نوید ندیمی^{*}، دانشیار، بخش مهندسی عمران، دانشکده فنی - مهندسی، دانشگاه شهید باهنر کرمان، ایران

^{*}پست الکترونیکی نویسنده مسئول: navidnadimi@uk.ac.ir

دریافت: ۱۴۰۲/۰۷/۲۸ - پذیرش: ۱۴۰۲/۰۷/۲۰

صفحه ۸۵-۹۸

چکیده

مدول برجهندگی خاک یکی از شاخص‌های مهم در طراحی روسازی راه است که نقش سییار مهمی در تعیین ضخامت روسازی دارد. تعیین مدول برجهندگی خاک‌ها به روش مستقیم و بر اساس نتایج آزمایشاتی به دلیل هزینه‌های بالای آن از جهت تجهیزات و نیروی انسانی معمولاً مقرر نیست. لذا بر پایه اطلاعات میدانی گذشته می‌توان بر اساس روش‌های هوش مصنوعی اقدام به پیش‌بینی و تعیین این شاخص بر اساس داده‌های ورودی نمود. هدف از این مقاله توسعه مدلی جهت پیش‌بینی مدول برجهندگی خاک‌های رسمی ثبت شده با استفاده از شبکه عصبی مصنوعی است. بدین منظور ۶ نمونه خاک مختلف ثبت شده با افزودنی‌های نظیر آهک، خاکستر بادی و غبار کوره سیمان مورد بررسی قرار گرفتند. در این مقاله از داده‌های گزارش شده در پیوست طراحی روسازی به روش آشتون ۳۰۰۲ استفاده شد. با مقایسه خروجی‌های بدست آمده با داده‌های واقعی بر اساس شاخص‌های آماری همچون ضریب رگرسیون و جذر میانگین مربعات خطأ مشخص شد که در همه موارد نتایج مطلوبی بدست آمد. مقدار ضریب رگرسیون ۹۹٪ و جذر میانگین مربعات خطأ کمتر از ۴ درصد نشان از دقت بالای مدل توسعه داده شده در پیش‌بینی مدول برجهندگی خاک‌های ثبت شده دارد.

واژه‌های کلیدی: مدول برجهندگی، شبکه عصبی مصنوعی، پیش‌بینی، روسازی

۱- مقدمه

خاک‌های مختلف در زیر بار ترافیک در طراحی سازه‌ای روسازی در روش مکانیستیک-تجربی شناخته می‌شود (Jue et al., 2019) در روش مکانیستیک-تجربی سه سطح قابلیت اطمینان برای مدول برجهندگی تعریف شد. سطح اول با بالاترین سطح قابلیت اطمینان مربوط به نتایج واقعی آزمایش مدول برجهندگی است که در راه‌های با تردد بالای وسایل نقلیه سنگین مدنظر قرار گرفت. سطح دوم بر اساس تخمین مدول برجهندگی براساس رابطه همبستگی با دیگر خصوصیات خاک بیان شد و در سطح سوم که پایین‌ترین سطح قابلیت اطمینان

راه‌ها از مهم‌ترین دارایی‌های کشورها به شمار می‌آیند که سالانه هزینه‌های زیادی جهت ساخت و یا نگهداری از آنها صرف می‌شود. با توجه به هزینه‌بر بودن عملیات نگهداری از راه‌ها، همواره طراحی مناسب و اجرای با کیفیت روسازی از اهمیت بالایی برخوردار بوده است. در روند طراحی روسازی یکی از مهم‌ترین عوامل، مقاومت خاک بستر است که با مدول برجهندگی بیان می‌گردد (Ghorbani et al., 2020). مدول برجهندگی خاک بستر به طور گسترده به عنوان مشخصه مکانیکی اصلی توصیف‌کننده مدول الاستیسیته وابسته به تنش

استفاده از خاک سیمان دار در سازه های هیدرولیکی، روسازی و راهسازی، محوطه های وسیع و پارکینگ ها، ساختن سدها با شبیب تند و وسعت عملیات کم رواج بسیاری یافته است. معمولاً برای تثبیت خاک های ریزدانه با پلاستیسیته و قابلیت تورم بالا، ۶ تا ۶ درصد وزن خشک آن، آهک و برای خاک های ماسه ای و خاک های با پلاستیسیته کم، ۳ تا ۸ درصد وزن خشک آن، سیمان به خاک افزوده می شود. تاکنون تحقیقات زیادی در رابطه با تثبیت خاک بستر با استفاده از افزودنی هایی نظیر قیر، سیمان، آهک، خاکستر بادی، غبار کوره سیمان و سایر افزودنی ها در مقیاس آزمایشگاهی صورت گرفته است (Ardah et al., 2017; Dhar & Hussain, 2021; Ikechukwu et al., 2021; Okeke, 2020) اما با توجه به تجربیات بدست آمده و تعیین پارامترهای موثر در تثبیت با افزودنی های مختلف و همچنین زمان بر و هزینه بر بودن آزمایش های مستقیم، محققین به سوی مدل های ریاضیاتی پیش بینی مدول برجهندگی حرکت کرده اند. در طول دو دهه گذشته روش های هوش محاسباتی مختلفی همچون شبکه عصبی مصنوعی، سیستم استنتاج عصبی - فازی سازگار، برنامه ریزی ژنتیک و ماشین بردار پشتیبان و ... جهت پیش بینی مدول برجهندگی خاک بستر روسازی مورد استفاده قرار گرفته است. در مطالعه ای از شبکه های عصبی مصنوعی جهت پیش بینی مدول برجهندگی خاک بستر روسازی بر اساس داده های ایالت اوهايو استفاده شد. برای این منظور جهت ساخت مدل پیش بینی مدول برجهندگی، از متغیرهایی شامل درصد ذرات ریزدانه، شاخص خمیری، حد روانی، مقاومت فشاری تک محوری، درصد رطوبت بهینه، درصد رطوبت، درجه اشباع، تنش محدود کننده و تنش انحرافی به عنوان پارامترهای ورودی بهره برده شد (Hanittinan, 2007). در مطالعه دیگری جهت پیش بینی مدول برجهندگی خاک ریزدانه بستر با ساخت مدل های مختلف بر پایه شبکه های عصبی مصنوعی، میزان تأثیرگذاری داده های ورودی ارزیابی گردید و به این نتیجه رسیدند که تنش انحرافی بیشترین اثرگذاری را بر مدول خروجی دارد (Park et al., 2009) در یک بررسی دیگر چندین مدل شبکه عصبی بر اساس همبستگی بین مدول برجهندگی و خصوصیات معمول خاک بستر و حالت تنش با اهداف طراحی توسعه داده شد. در اینجا با جمع آوری ۹۷ داده مربوط به ۱۶ بخش از ایالت اول کلاما می امریکا و با در نظر گرفتن پارامترهایی ورودی شامل دانه بندی،

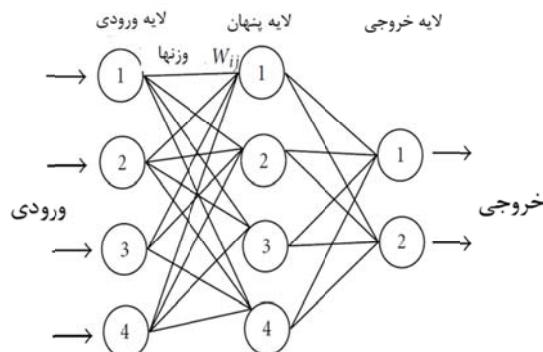
است، مدول برجهندگی محلی برای یک منطقه به صورت پیش فرض اعمال گشت که برای راه های با اهمیت کم قابل استفاده خواهد بود. مدول الاستیسته به عنوان نسبت تنش سیکلی حداقل به کرنش قابل برگشت در یک سیکل بارگذاری دینامیک تکرار شونده تعریف می شود (Zhang et al., 2019). تعیین مدول برجهندگی به دلیل هزینه های بالای آزمایش ها، غالب به صورت غیر مستقیم و از طریق آزمایش مقاومت باربری کالیفرنیا و وجود رابطه همبستگی بین این دو انجام می گیرد، اما در صورت نیاز به تعیین مستقیم این پارامتر، نیاز به آزمایش های پرهزینه و وقت گیری نظیر آزمایش بارگذاری سه محوری است. لذا تاکنون مدل های مختلفی جهت پیش بینی غیرمستقیم مدول برجهندگی بر اساس تحلیل های آماری و رگرسیون پیشنهاد شده است. در طول چهار دهه گذشته محققین زیادی به بررسی رفتار غیرخطی خاک بستر روسازی راه ها و عوامل موثر در آن شامل تنش انحرافی، وزن مخصوص خشک، درصد رطوبت، دانه بندی و شکل دانه ها، درصد ریزدانه (Ghorbani et al., 2020; Sung-Hee et al., 2007) با افزایش وزن مخصوص خشک و یا درجه تراکم خاک، مصالح بستر از مقاومت بالاتری برخوردار خواهد بود (S. Kim, 2004). در ضمن اثر وزن مخصوص خاک با تغییر در نوع سنگدانه ها، درصد ریزدانه و حالت تنش ۲۰۰۵ تغییر می کند. به عنوان نمونه در تحقیقی در سال مشخص شد که اثر وزن مخصوص با افزایش ذرات ریزدانه کاهش می یابد (S.-H. Kim et al., 2005) ۲۰۰۸ نتایج تحقیق دیگری نشان داد که مدول برجهندگی با افزایش وزن مخصوص خشک خاک در یک متوسط تنش نرمال پایین، افزایش می یابد (Hossain, 2008) علاوه بر موارد فوق، استفاده از برخی مواد افزودنی نظیر آهک، غبار کوره سیمان و خاکستر بادی به خاک بستر نیز تأثیر به سزایی در افزایش مدول برجهندگی خاک دارد؛ به چنین فرآیندی تثبیت خاک نیز می گویند. تثبیت خاک به مجموعه اقداماتی گفته می شود که به اصلاح و بهبود خواص فیزیکی و یا شیمیایی خاک جهت افزایش مقاومت باربری آن می انجامد (Hanandeh et al., 2020) تثبیت خاکها به روش های مختلفی نظیر روش های مکانیکی، شیمیایی، فیزیکی، بیولوژیکی (رویاندن گیاه) و حتی الکترونیکی امکان پذیر است. تثبیت با افزودنی ها یکی از قلیمی ترین روش های بهسازی خاک است.

۰/۹۷ و مدل الگوریتم ژنتیک ۰/۹۵ برای پیش‌بینی مدول برجهندگی بوده است. بنابراین این روش‌ها به عنوان شیوه‌های قدرتمند و کارایی جهت پیش‌بینی مدول برجهندگی در مقایسه با روش‌های تجربی است (Hanandeh et al., 2020). در مطالعه‌ای از دو روش جنگل تصادفی و تقویت گرادیان جهت پیش‌بینی مدول برجهندگی براساس نتایج آزمایشگاهی استفاده شد و نتایج نشان داد که واریانس به شدت کاهش یافت و دقت پیش‌بینی مدل بهبود یافت. روش تقویت گرادیان به عنوان روش برتر با ضریب تعیین ۰/۹۵ معروفی شد (Pahno et al., 2021). جهت تخمین دقیق و کارای مدلول برجهندگی خاک بستر، مدل‌های پیش‌بینی برمبانی داده‌های تجربی و تحلیل رگرسیون چندگانه با ۲۲ نمونه خاک توسعه داده شد. ضریب تعیین بالای مدل نشان داد که می‌توان از آن در شرایط مختلف جهت پیش‌بینی ضریب برجهندگی استفاده کرد (Zhang, Peng, Zeng, et al., 2021). در مطالعه‌ای با هدف توسعه یک روش دقیق و کارا برای تخمین مدول برجهندگی خاک بستر آزمایش‌های بارگذاری محوری تکراری انجام و مدلی توسعه داده شد. نتایج نشان داد که ضریب تعیین مدل بالا بوده و مدل منطقی و قابل استفاده بطور گسترده خواهد بود (Zhang, Peng, Liu, et al., 2021). در تحقیق دیگری از الگوریتم ژنتیک و یک رویکرد هوشمند ترکیبی با استفاده از الگوریتم ژنتیک و شبکه عصبی جهت تخمین مدول برجهندگی خاک بستر استفاده شد. نتایج نشان داد که هر دو مدل الگوریتم ژنتیک و رویکرد ترکیبی می‌تواند مدول برجهندگی خاک بستر را با دقت خوبی نسبت به سایر روش‌های موجود پیش‌بینی کنند (Ghorbani et al., 2020). همان‌گونه که ملاحظه می‌شود، تحقیقاتی که تاکنون انجام شده است، عمدتاً بر پایه بکارگیری روش‌های مختلف هوش محاسباتی، فرآبتكاری و تکاملی جهت پیش‌نمودن برجهندگی خاک‌های ریزدانه استوار بوده است و تحقیقات چندانی در راستای پیش‌بینی مدول برجهندگی خاک‌های تثبیت شده انجام نگرفته است. لذا در این مقاله از روش شبکه عصبی مصنوعی، که متداول‌ترین روش مورد استفاده در تحقیقات گذشته بوده است، جهت پیش‌بینی مدول برجهندگی خاک‌های ریزدانه تثبیت شده با استفاده از آهک، خاکستر بادی و غبار کوره سیمان بهره گرفته شده است. در اینجا با توجه به وجود داده‌های واقعی مدول برجهندگی برای چهار نوع خاک، سطح اول قابلیت اطمینان قابل تعریف است و پیش‌بینی مدول برجهندگی بر اساس این داده‌ها و براساس روش شبکه عصبی مصنوعی جهت استفاده در طراحی روسازی‌های جدید انجام خواهد گرفت.

حدود اتربرگ، وزن مخصوص، رطوبت بھینه و مقاومت فشاری تکمحوری و مدول برجهندگی به عنوان پارامتر خروجی، چهار مدل شبکه عصبی مصنوعی پس خور شامل شبکه خطی، شبکه عصبی رگرسیون عمومی، شبکه تابع شعاع مینا و شبکه پرسپترون چندلایه ارائه شد. تحقیقات آن‌ها نیز نشان از برتری مدل پرسپترون چند لایه نسبت به سایر مدل‌ها داشت (Musharraf et al., 2010). گروه دیگری از محققین به ارزیابی عملکرد الگوریتم ژنتیک و شبکه عصبی مصنوعی جهت بهبود دقت پیش‌بینی مدول برجهندگی خاک بستر بر پایه خصوصیات شاخص خاک پرداختند. همچنین اثر دقت مدول برجهندگی را بر پیش‌بینی عملکرد طراحی روسازی به روش مکانیستیک-تجربی مورد بررسی قراردادند. تحقیق آنها نشان داد که شبکه عصبی نسبت به مدل‌های رگرسیونی توانایی بهتری در پیش‌بینی مدول برجهندگی دارد (Nazzal & Tatari, 2013). در تحقیق دیگری جهت پیش‌بینی مدول برجهندگی خاک‌های چسبنده از دو روش ماشین یادگیری افزایشی بر پایه رگرسیون و ماشین بردار پشتیبان استفاده و نتایج آنها با یکدیگر مقایسه شد. در این مطالعه با بهره‌گیری از پایگاه داده‌ای با ۸۹۱ داده مستخرج از مطالعات دانشگاه اوهایو و با در نظر گرفتن ۹ متغیر ورودی به ساخت مدل پیش‌بینی مدول برجهندگی خاک‌های ریزدانه پرداخته شد. نتایج این تحقیقات نشان داد که تابع کرنل چندجمله‌ای دارای بیشترین دقت و دو پارامتر تنش محلودکننده و تنش انحرافی بیشترین تأثیر را بر مدول برجهندگی خاک‌های ریزدانه دارد (Pal & Deswal, 2014). در سال ۲۰۱۴ در یک مطالعه با مرتبط ساختن مدول برجهندگی با حالت تنش و خواص فیزیکی خاک مدل پیش‌بینی بر پایه شبکه‌های عصبی توسعه داده شد. در این مطالعه با استفاده از داده‌های مربوط به ایالت جورجیا مشخص شد که مدل معماری با ساختار ۱۲-۹-۱ قادر است که با کمترین خطأ، مدول برجهندگی را پیش‌بینی نماید (S. H. Kim et al., 2014). در سال ۲۰۱۶ گروهی از محققین با بهره‌گیری از داده‌های مربوط به ایالت اوهایو و استفاده از یک سیستم استنتاج تطبیقی عصبی-فازی به نتیجه مطلوبی جهت پیش‌بینی مدول برجهندگی خاک بستر رسیدند (Sadrossadat et al., 2018). در مرکز تحقیقاتی حمل و نقل لوئیزیانا مطالعه‌ای بر روی ۴ نوع خاک بستر تثبیت شده با ۱۲۵ نمونه با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک جهت پیش‌بینی مدول برجهندگی انجام شد. تثبیت‌کننده‌ها در این مطالعه عبارت بودند از سیمان، آهک و خاکستر بادی. نتایج مطالعه نشان داد که ضریب تعیین مدل شبکه عصبی مصنوعی

۲- روش تحقیق

بررسی نمایند (Amiri et al., 2020). شبکه عصبی مصنوعی از شمار زیادی عناصر پردازشی فوق العاده به هم پیوسته به نام نورون‌ها تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کنند. نورون‌ها شامل مجموعه‌ای از ورودی و خروجی‌ها و تعداد زیادی گره یا واحد پردازشگر موسوم به تابع انتقال هستند. مجموعه‌ای از نورون‌های موازی، یک لایه را تشکیل می‌دهند. هر شبکه عصبی مصنوعی می‌تواند برای تولید خروجی‌ها خود از چندین لایه تشکیل شود که شامل لایه‌های پنهان و لایه خروجی خواهد شد و این لایه‌ها به صورت سری به یکدیگر متصل می‌شوند. هر ورودی در شبکه عصبی دارای وزن متناظر با خود بوده که با تأثیرپذیری از آن و با هدف اعمال پردازش و تولید ورودی‌های لایه‌های بعدی وارد تابع انتقال خواهد شد. شکل ۱ این سیستم را نشان می‌دهد.



شکل ۱. شبکه مصنوعی سه لایه‌ای پیش خور

پیدا می‌کند، که ارتباط ورودی و خروجی را فراهم می‌سازد. خروجی (y_i) گره ۱ به صورت زیر محاسبه می‌شود (Raju et al., 2011)

تعداد نورون‌ها و لایه‌های پنهان به مسئله بستگی دارد و با استفاده از سعی و خطا بدست می‌آید. جهت نشان دادن قدرت اتصال بین دو گره به هر کمان (لينک) وزنی اختصاص

$$y_i = f(\sum_{i=1}^m W_{ij} X_i + b_i) \quad (1)$$

را نسبت به کل سیگنال‌های ورودی رسیده، مشخص می‌سازد. شکل رایج تابع فعالساز، تابع انتقال سیگموید است که به صورت زیر بیان می‌شود (Raju et al., 2011).

$$f(x) = \frac{1}{1 - e^{-x}} \quad (2)$$

تابع سیگموید در همه جا پیوسته است و یک فرآیند غیر خطی را می‌توان با آن نگاشت (Raju et al., 2011).

پاسخ در آن‌ها همواره رو به جلو پردازش شده و به نورون‌های لایه‌های قبل خود باز نمی‌گردد. در این نوع شبکه به سیگنال‌ها

X_i ورودی که به گره i رسیده است، W_i وزن لینک اتصال ورودی، m تعداد کل ورودی‌های رسیده به گره i و b_i نیز آستانه گره است. تابع f نیز تابع فعالساز نام دارد که پاسخ گره

دو نوع اصلی شبکه‌های عصبی شبکه‌های پیش خور و پس

خور هستند. شبکه‌های پیش خور، شبکه‌هایی هستند که مسیر

شبکه‌های عصبی پیش خور مورد استفاده قرار می‌گیرند. در این الگوریتم، هر الگوی ورودی مجموعه داده‌های آموزش از لایه ورودی به لایه خروجی عبور داده می‌شود. خروجی تولید شده شبکه با خروجی هدف مقایسه می‌شود و خطای صورت معادله ۳ محاسبه می‌گردد.

که در آن t_i مقدار خروجی مورد نظر به هدف است، y_i خروجی تولید شده در شبکه عصبی است، p تعداد گره‌های خروجی و P تعداد الگوهای آموزش است. این خطای در هر گره به صورت برگشتی منتشر و در نتیجه وزن‌های اتصال به روز خواهد شد.

$$E = \sum_p \sum_p (y_i - t_i)^2$$

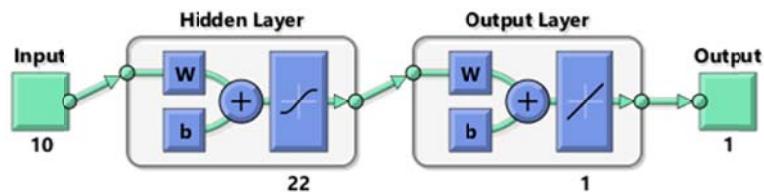
بنابراین با هر بار آموزش شبکه عصبی مصنوعی نتایج مختلفی به دست می‌آید. در حقیقت عملکرد شبکه عصبی مصنوعی حتی با فرض ثابت بودن معماری و سایر پارامترهای شبکه بسیار وابسته به مقادیر وزن‌ها و بایاس‌های اولیه است. بنابراین در این مقاله هر معماری شبکه عصبی به تعداد ۱۰ مرتبه اجرا گردید و بهترین نتیجه از بین این نتایج به عنوان نماینده آن معماری انتخاب شد. در اینجا تعداد نمونه‌ها در لایه مخفی از ۱۰ تا ۷۰ متغیر در نظر گرفته شد و با اجرای هر یک از معماری‌ها به تعداد ۲۰ مرتبه، تعداد بهینه نمونه‌ها برای هر شبکه به دست آمد. به منظور آموزش، اعتبارسنجی و آزمون شبکه، به ترتیب از ۶۵٪ و ۱۰٪ و ۲۵٪ از داده‌های مدول برجهنودگی استفاده شد. همچنین در این مقاله تابع انتقال لایه مخفی به صورت هایپربولیک تائزانت سیگموید و تابع انتقال لایه خروجی به صورت خطی در نظر گرفته شد. ارزیابی انجام شده نشان داد که شبکه بهینه برای خاک تثبیت شده با آنکه دارای معماری بهینه ۲۲-۱، ۱۰-۲۲-۱، برای خاک تثبیت شده با خاکستر بادی زغال‌سنگ دارای معماری بهینه ۲۱-۱ و برای خاک تثبیت شده با غبار کوره سیمان دارای معماری بهینه ۱۰-۲۲-۱ است که در آن، ۱۰ و ۱ به ترتیب تعداد متغیرهای ورودی و خروجی شبکه و اعداد ۲۲، ۲۱ و ۲۰ تعداد نمونه‌ها در لایه پنهان است. معماری بهینه شبکه عصبی مصنوعی در شکل‌های ۲ تا ۴ نشان داده است.

تنها اجازه عبور از مسیر یکطرفه (از ورودی تا خروجی) داده می‌شود. بنابراین بازخورد یا فیدبک وجود ندارد. به این معنی که خروجی هر لایه تنها بر لایه بعد اثر می‌گذارد و در لایه‌ی خودش تغییری ایجاد نمی‌کند. تفاوت شبکه‌های پس خور با شبکه‌های پیش خور در آن است که در شبکه‌های برگشتی حداقل یک سیگنال برگشتی از یک نورون به همان نورون یا نورون‌های همان لایه یا نورون‌های لایه‌های قبل وجود دارد و اگر نورونی دارای فیدبک باشد، بدین مفهوم است که خروجی نورون در لحظه حال نه تنها به ورودی در آن لحظه، بلکه به مقدار خروجی خود نورون در لحظه‌ی گذشته نیز وابسته است. الگوریتم‌های برگشتی یا پس انتشار اغلب برای آموزش

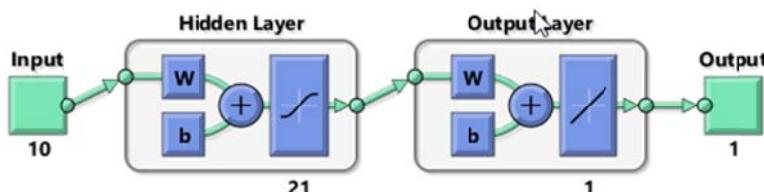
(۳)

۲-۲-معماری شبکه عصبی مصنوعی پیشنهادی

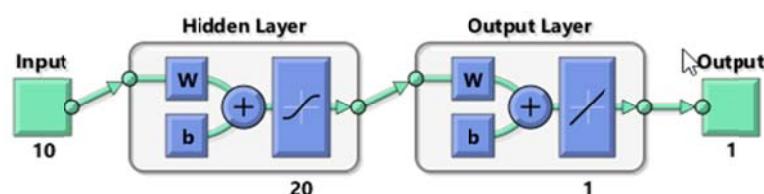
در این تحقیق برای سه افزودنی آهک، خاکستر بادی زغال‌سنگ و غبار کوره سیمان سه شبکه عصبی جداگانه توسعه داده شد. پیش از پیاده‌سازی شبکه عصبی مصنوعی، داده‌های ورودی و خروجی، بین ۰ تا ۱ نرمال‌سازی شد و فرآیند آموزش و آزمون این شبکه با استفاده از مقادیر نرمال شده انجام گرفت. به منظور آموزش و آزمون شبکه عصبی مصنوعی از جعبه ابزار شبکه‌های عصبی مصنوعی برنامه مطلب استفاده شد. دو پارامتر اساسی که در مدل‌سازی با استفاده از شبکه عصبی مصنوعی باید مقادیر بهینه آنها تعیین شود عبارتند از تعداد لایه‌های مخفی و همچنین تعداد نمونه‌ها در هر لایه مخفی. در این تحقیق با توجه به دقت کافی شبکه‌های تک لایه (یک لایه مخفی)، تعداد لایه‌های مخفی برابر با یک در نظر گرفته شد. همچنین به منظور تعیین بهینه نمونه‌ها در لایه مخفی از روش سعی و خطای استفاده شد. برای این منظور، یک کامپیوتری در محیط مطلب نوشته شد که فرآیند سعی و خطای را به صورت خودکار و با هدف تعیین تعداد بهینه نمونه‌ها در لایه مخفی انجام می‌داد. برنامه توسعه داده شده با ارزیابی تعداد مختلف نمونه‌ها در لایه مخفی، تعداد بهینه نمونه‌ها را با توجه به شرط کمینه‌سازی میزان جذر مربع متوسط خطای داده‌های آموزش، اعتبارسنجی و آزمون بدست می‌دهد. در جعبه ابزار شبکه‌های عصبی مصنوعی برنامه مطلب مقادیر اولیه وزن‌ها و بایاس‌ها به صورت تصادفی انتخاب می‌شود و



شکل ۲. معماری بهینه شبکه عصبی به منظور پیش‌بینی مدل برجهندگی خاک ثبت شده با آهک



شکل ۳. معماری بهینه شبکه عصبی به منظور پیش‌بینی مدل برجهندگی خاک ثبت شده با خاکستر بادی زغال‌سنگ



شکل ۴. معماری بهینه شبکه عصبی به منظور پیش‌بینی مدل برجهندگی خاک ثبت شده با غبار کوره سیمان

۲-۳- ارزیابی عملکرد مدل

در این مقاله از روابط زیر برای تعیین عملکرد و دقت مدل شبکه عصبی مصنوعی استفاده شده است:

۱- جذر میانگین مربعات خطأ^۲ (RMSE):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{x}_i)^2} \quad (4)$$

۲- ضریب رگرسیون (R^2):

$$R^2 = \left[\frac{1}{N} \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sigma_x \cdot \sigma_y} \right]^2 \quad (5)$$

شده جهت اجرای طراحی روسازی آشتو ۲۰۰۲ که در ایالت اوکلاهما آمریکا استخراج شده، استوار است. در این گزارش چهار نوع خاک با نام‌های p, k, v و c و سه نوع افروندی شامل آهک، خاکستر بادی زغال‌سنگ و غبار کوره سیمان مورد بررسی قرار گرفتند. جدول ۱ و ۲ به ترتیب مشخصات مهندسی و شیمیایی خاک‌های مورد استفاده را نشان می‌دهند.

که N تعداد داده‌های مشاهده شده، x_i ارزش x برای مشاهده‌ی iام، y_i ارزش y برای پیش‌بینی iام، \bar{x} میانگین x، \bar{y} میانگین y و σ_x و σ_y به ترتیب برابر انحراف معیار x و y است.

۴- داده‌های تحقیق

مطالعه حاضر بر پایه داده‌های مربوط به گزارش FHWA-OK-08-10 تحت عنوان خواص مهندسی خاک بستر ثبت

جدول ۱. مشخصات مهندسی خاک‌های مورد مطالعه

P-soil	K-soil	V-soil	C-soil	پارامتر / واحد
CL-ML	CL	CL	CH	نماذج USCS
A-4	A-6	A-6	A-7-6	طرح آشتو
رس لای دار با ماسه	رس باحد روانی کم	رس باحد روانی بالا	رس باحد روانی بالا	نام USCS
۸۳	۹۷	۱۰۰	۹۶	درصد ریزتر از ۰/۰۷۵ میلی‌متر
۲۷	۳۹	۳۷	۵۸	حد روانی
۲۱	۱۸	۲۶	۲۹	حد خمیری
۵	۲۱	۱۱	۲۹	شاخص خمیری
۰/۲۴	۰/۴۷	۰/۲۸	۰/۶۹	میزان فعال بودن (Activity)
۲/۶۵	۲/۷۱	۲/۶۱	۲/۶۴	وزن مخصوص
۱۳/۱	۱۶/۵	۲۳/۰	۲۰/۳	درصد رطوبت بهینه
۱۱۳/۴	۱۱۰/۶	۱۰۱/۹	۱۰۳/۷	حداکثر وزن مخصوص خشک (pcf)
۸/۹۱	۸/۸۲	۸/۱۴	۴/۱۷	pH
<۴۰	<۴۰	۱۵۴۰۰	۲۶۷	میزان سولفات (ppm)

جدول ۲. مشخصات شیمیایی خاک‌های مورد مطالعه

درصد وزنی				ترکیب شیمیایی
P-soil	K-soil	V-soil	C-soil	
۷۳/۷	۶۰/۷	۵۰/۲	۴۷/۵	(SiO ₂) سیلیکا
۷/۰	۱۱/۹	۱۶/۴	۱۶/۱	(Al ₂ O ₃) آلومینا
۲/۲	۴/۴	۶/۷	۶/۸	(Fe ₂ O ₃) اکسید آهن
۱۴/۹	۷/۰	۴/۱	۳/۹	SSR نسبت سیلیکا به سیکوئی اکسید
۲/۹	۳/۳	۳/۵	۰/۱	(CaO) اکسید کلسیم / SiO ₂ / (Al ₂ O ₃ + Fe ₂ O ₃)
۱/۸	۳/۲	۴/۷	۰/۹	(MgO) اکسید منیزیم
۰/۸	۰/۸	۱/۰	۰/۲	(Na ₂ O) اکسید سدیم
۱/۴	۲/۱	۴/۴	۲/۱	(K ₂ O) اکسید پتاسیم
۰/۰	۰/۰	۱/۷	۰/۰	(SO ₃) اکسید سولفور
۵/۱	۷/۸	۷/۱	۲۵/۱	افت حرارتی
۵۴/۰	۸۸/۸	۹۴/۸	۸۷/۲	درصد عبوری از الک نمره ۳۵
۳۱/۹	۲۷/۶	۲۹/۰	۳۰/۵	UCS (psi)

پارامتر ورودی عبارت‌داشت از درصد ذرات عبوری از الک نمره ۲۰۰، شاخص خمیری (PI)، درصد رس (عبوری از الک ۰/۰۷۵ میلی‌متر)، pH خاک، مساحت سطح ویژه خاک، درصد رطوبت خاک (٪)، چگالی خشک خاک، درصد افزودنی، تنش محدود کننده (σ₃) و تنش انحرافی (σ_d). مشخصات آماری مجموعه داده‌های مدول برجهندگی چهار نوع خاک ثبت شده با سه نوع افزودنی آهک، خاکستر بادی زغال‌سنگ و غبار کوره سیمان در جدول ۳ نشان داده شده است.

آزمایش مدول برجهندگی با درصدهای مختلف افزودنی روی هر یک از خاک‌ها انجام شد و تعداد ۷۲۰ داده مربوط به مدول برجهندگی بدست آمد. میزان افزودنی آهک به ترتیب صفر، ۳، ۶ و ۹ درصد، میزان افزودنی خاکستر بادی زغال‌سنگ به ترتیب صفر، ۵، ۱۰ و ۱۵ و در نهایت میزان افزودنی غبار کوره سیمان به ترتیب صفر، ۵، ۱۰ و ۱۵ درصد در نظر گرفته شدند. در تحقیق حاضر، ۱۰ پارامتر ورودی به منظور مدل‌سازی مدول برجهندگی مصالح ثبت شده در نظر گرفته شده است. این ۱۰

جدول ۳. مشخصات آماری مجموعه داده‌ی مدول برجهندگی خاک پستر

M_R (MPa)	σ_d (kPa)	σ_3 (kPa)	درصد CKD	درصد CFA	درصد آهک	DD (g/cm ²)	MC (%)	SSA (m ² /g)	pH	CC (%)	PI	P _{#200} (%)	مشخصات آماری
۴۹/۶۰	۱۲/۴۱	۱۳/۷۸	۰/۰۰	۰/۰۰	۰/۰۰	۱۴/۹۰	۱۱/۷۰	۵۱/۰۰	۴/۱۷	۱۱/۰۰	۱۸/۰۰	۸۳/۰۰	کوچکترین داده
۲۶۱۴/۵۰	۶۲/۰۵	۴۱/۳۶	۱۵/۰۰	۱۵/۰۰	۹/۰۰	۱۸/۱۰	۲۶/۸۰	۱۱۸/۵۰	۸/۹۱	۴۸/۰۰	۲۹/۰۰	۱۰۰/۰۰	بزرگترین داده
۷۳۳/۷۵	۳۷/۹۹	۲۷/۶۰	۷/۰۹	۷/۴۷	۴/۴۹	۱۶/۵۴	۱۸/۸۱	۹۴/۸۶	۷/۴۷	۳۵/۹۰	۲۳/۵۲	۹۳/۳۹	میانگین
۵۶۲/۲۲	۱۷/۲۳	۱۱/۳۱	۵/۰۹	۵/۰۹	۳/۳۷	۰/۸۱	۴/۰۵	۲۷/۱۰	۱/۹۷	۱۴/۵۹	۴/۲۹	۷/۳۸	انحراف معیار
۶۴۲/۷۲	۳۷۷۲۳	۲۷/۵۸	۵/۰۰	۵/۰۰	۳/۰۰	۱۶/۴۰	۱۸/۵۰	۱۱۶/۵۰	۸/۱۴	۴۵/۰۰	۲۶/۰۰	۹۴/۰۰	میانه

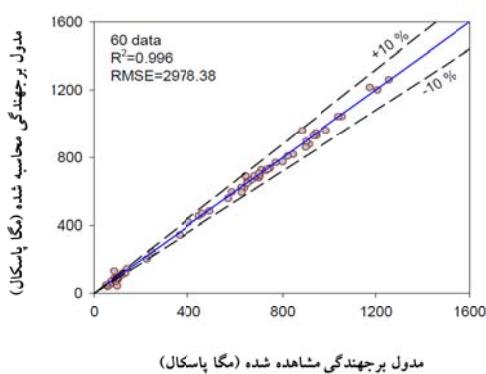
P_{#200}: درصد عبوری از الک نمره ۲۰۰ خاک، PI: شاخص خمیری خاک، CC: درصد رس خاک، SSA: مساحت سطح ویژه خاک (m²/g)

MC: درصد رطوبت، DD: چگالی خشک (kN/m³), σ_3 : تنش محدودکننده، σ_d : تنش انحرافی، M_R: مدول برجهندگی

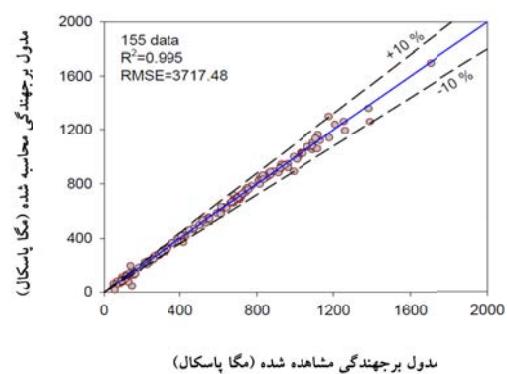
۳- نتایج تحقیق

ثبت شده با این سه نوع افزودنی است. درصد خطای پیش‌بینی مدل‌های شبکه عصبی مصنوعی برای سه نوع افزودنی آهک، خاکستر زغال‌سنگ و غبار کوره سیمان به ترتیب در شکل‌های ۸ تا ۱۰ نشان داده شده است. ملاحظه می‌شود، در مورد اکثر داده‌ها خطای پیش‌بینی کمتر از ۱۰ درصد است. به علاوه میانگین خطای قدر مطلق نیز برای این شکل‌ها نشان داده شده است. میانگین قدر مطلق درصد خطای مدل شبکه عصبی مصنوعی توسعه داده شده برای سه نوع افزودنی آهک، خاکستر زغال‌سنگ و غبار کوره سیمان به ترتیب برابر با ۵/۰۴۹، ۵/۰۲۵ و ۳/۰۵۸ است که نشان دهنده قابلیت اطمینان بالای مدل توسعه داده شده در پیش‌بینی مدول برجهندگی مصالح ثبت شده است.

شکل‌های ۵ تا ۷ به ترتیب عملکرد مدل شبکه عصبی مصنوعی توسعه داده شده را برای سه مدل پیش‌بینی مدول برجهندگی در خاک ثبت شده با آهک، خاکستر زغال‌سنگ و غبار کوره سیمان با توجه به داده‌های آموزش و آزمون نشان می‌دهند. بر روی هر یک از این شکل‌ها تعداد داده شده جذر میانگین مربعات خطأ و ضریب رگرسیون نشان داده شده است. همچنین خطوط مربوط به محدوده خطای ۱۰٪ نیز ترسیم شده است. همانگونه که ملاحظه می‌شود ضریب رگرسیون شبکه عصبی مصنوعی برای داده‌های آموزش و آزمون در کلیه مدل‌های توسعه داده شده بیش از ۹۹٪ است که مقادیر بسیار بالایی هستند و نشان دهنده قابلیت بالای شبکه عصبی در پیش‌بینی پارامتر مدول برجهندگی خاک‌های

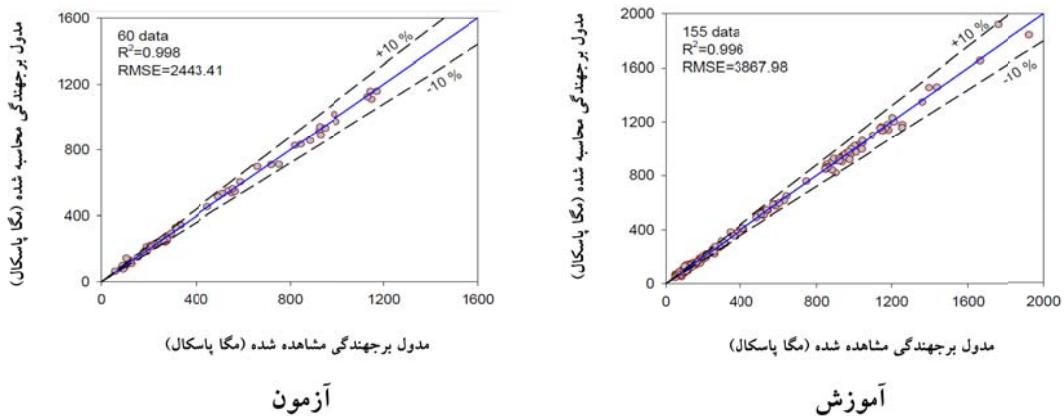


آزمون

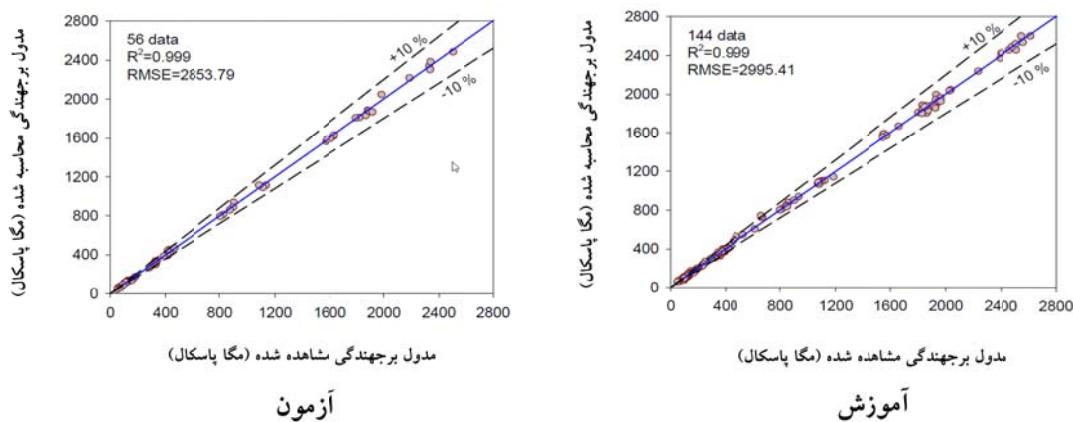


آموزش

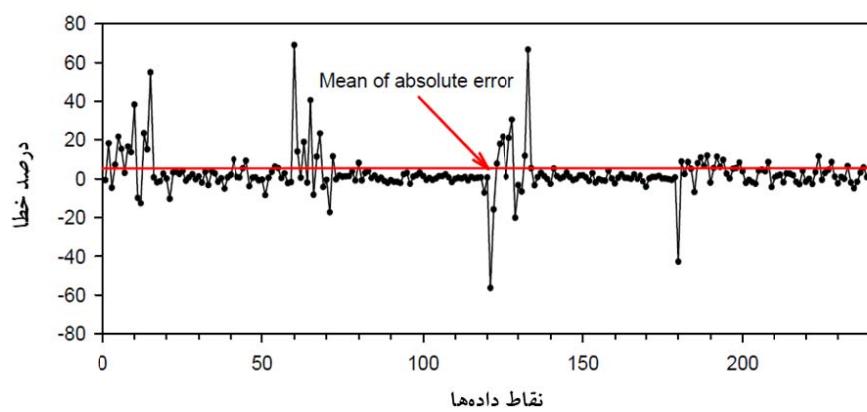
شکل ۵. عملکرد شبکه عصبی مصنوعی توسعه داده شده در پیش‌بینی مدول برجهندگی خاک ثبت شده با آهک



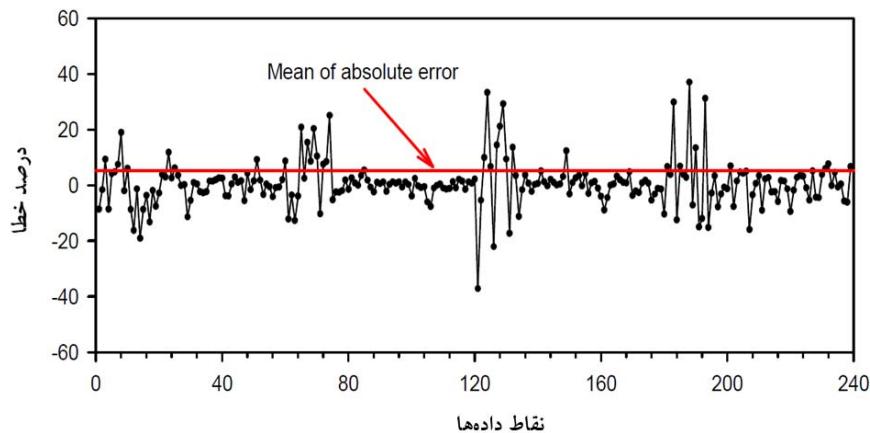
شکل ۶. عملکرد شبکه عصبی مصنوعی توسعه داده شده در پیش‌بینی مدول برجهندگی خاک تثیت شده با خاکساز با دیزل گالستنگ



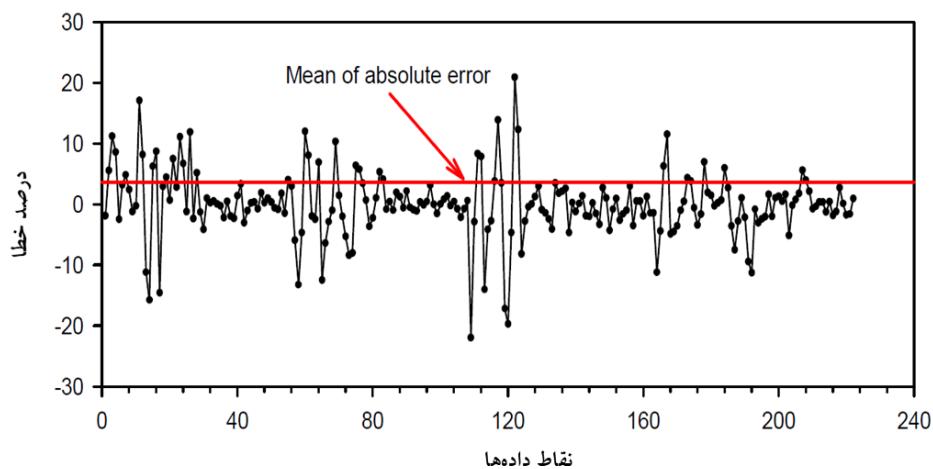
شکل ۷. عملکرد شبکه عصبی مصنوعی توسعه داده شده در پیش‌بینی مدول برجهندگی خاک تثیت شده با غبار کوره سیمان



شکل ۸. درصد خطای پیش‌بینی مدول برجهندگی خاک تثیت شده با آهک



شکل ۹. درصد خطای پیش‌بینی مدل برجهندگی خاک تثبیت شده با خاکستر با دی‌زغال‌ستگ



شکل ۱۰. درصد خطای پیش‌بینی مدل برجهندگی خاک تثبیت شده با غبار کوره سیمان

۱-۳- تحلیل حساسیت

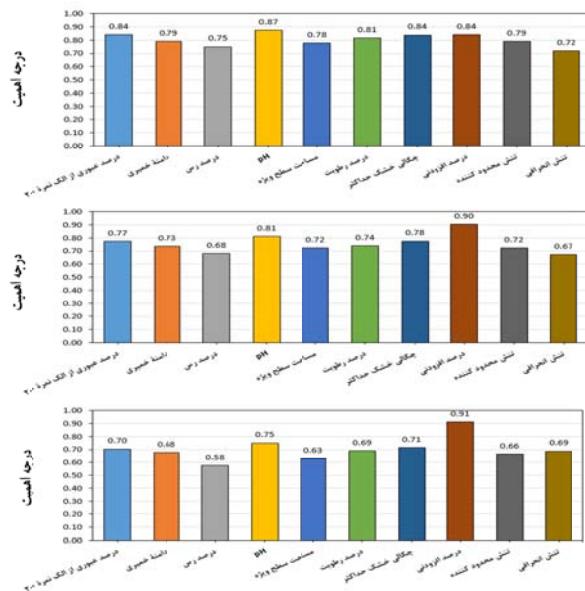
بررسی تأثیر هر یک از پارامترهای ورودی بر پارامتر خروجی مورداستفاده قرار گیرد (Yang, Y. Zhang, 2007). در این روش درجه حساسیت پارامتر ورودی با تعیین درجه همبستگی بین جفت داده‌های ورودی و خروجی و با استفاده از رابطه شماره ۶ تعیین می‌شود.

تحلیل حساسیت معمولاً به منظور تعیین درجه اهمیت تأثیر هر یک از پارامترهای ورودی (متغیرهای مستقل) بر روی پارامتر خروجی (متغیر وابسته) انجام می‌شود. تعیین درجه اهمیت هر یک از ورودی‌ها به انتخاب مدل مناسب جهت برقراری ارتباط بین پارامترهای ورودی و خروجی کمک می‌کند. یکی از روش‌های تحلیل حساسیت، روش Cosine Amplitude Method (CAM) است که می‌تواند به منظور

$$R_i = \frac{\sum_{k=1}^m x_{ik} y_k}{\sqrt{\sum_{k=1}^m x_{ik}^2 \sum_{k=1}^m y_k^2}} \quad (6)$$

درجه اهمیت pH از کلیه پارامترها خاک بیشتر و درجه اهمیت درصد رس (عبوری از الک ۰/۰۷۵ میلی متر) از کلیه پارامترها خاک کمتر است. همچنین ملاحظه می شود که درجه اهمیت درصد عبوری از الک نمره ۲۰۰ نیز مطابق انتظار مقداری بالا است. از بین دو پارامتر مربوط به تراکم، درجه اهمیت چگالی خشک بیشتر از درصد رطوبت است. به جز در حالت ثبیت با آهک، درصد افزودنی دارای بیشترین درجه اهمیت است. به علاوه می توان دید که پارامترهای مربوط به وضعیت تنفس (تنفس انحرافی و تنفس محدود کننده در مقایسه با سایر پارامترها مشخصات خاک، چگالی خشک و درصد افزودنی) تأثیر کمتری بر مدول برجهندگی مصالح ثبیت شده دارند.

که در این رابطه، x_{ik} مقدار متغیر مستقل آم برای داده k ام و y_k مقدار متغیر وابسته برای داده k ام (نظیر x_{ik}) و عددی مثبت شود، تعداد کل داده ها است. در صورتی که R_i عددی مثبت شود، ورودی موردنظر بر روی خروجی تأثیر مثبت دارد و در صورتی که R_i عددی منفی شود، ورودی موردنظر بر روی خروجی تأثیر منفی دارد. همچنین در صورت عدم ارتباط پارامتر خروجی و ورودی، مقدار R_i برابر با صفر خواهد بود. شکل ۱۱ به ترتیب درجه اهمیت تأثیر هر یک از پارامترهای ورودی بر مدول برجهندگی خاک ثبیت شده با آهک، خاکستر زغال سنگ و غبار کوره سیمان را نشان می دهد. همانگونه که ملاحظه می شود از بین پارامترهای مربوط به مشخصات خاک



شکل ۱۱. درجه اهمیت تأثیر پارامترهای ورودی مختلف بر مدول برجهندگی خاک های ثبیت شده

۴- نتیجه گیری

مدل های توسعه داده شده بیش از ۹۹٪ است که نشان دهنده قابلیت بالای شبکه عصبی در پیش بینی مدول برجهندگی است. همچنین میانگین قدر مطلق درصد خطای مدل شبکه عصبی مصنوعی، برای سه نوع افزودنی آهک، خاکستر زغال سنگ و غبار کوره سیمان زیر ۶ درصد است که قابلیت اطمینان بالای مدل توسعه داده شده را نشان می دهد. به علاوه تحلیل حساسیت انجام شده، نشان از تأثیر بالای درصد افزودنی و pH و تأثیر کمتر درصد رس و تنفس انحرافی در خروجی مدل دارند.

در این مقاله با استفاده از شبکه عصبی مصنوعی، مدلی جهت پیش بینی مدول برجهندگی خاک های رسی ثبیت شده توسعه داده شد. برای این هدف از پایگاه داده ای با ۷۲۰ داده از مدول برجهندگی خاک های مختلف استفاده شد. پارامتر ورودی در مدل توسعه داده شده شامل درصد ذرات عبوری از الک نمره ۲۰۰، شاخص خمیری، درصد رس، pH خاک، مساحت سطح ویژه خاک، درصد رطوبت خاک، چگالی خشک خاک، درصد افزودنی، تنفس محدود کننده و تنفس انحرافی و بر این اساس خروجی مدل نیز مدول برجهندگی خاک بود. ضریب رگرسیون شبکه عصبی مصنوعی برای داده های آموزش و آزمون در کلیه

۵-مراجع

- 31(3), 4019004.
doi.org/10.1061/(ASCE)MT.19435533.0002623
- Kim, S.-H., Little, D. N., Masad, E., & Lytton, R. L. (2005). Estimation of level of anisotropy in unbound granular layers considering aggregate physical properties. *International Journal of Pavement Engineering*, 6(4), 217–227.
doi.org/10.1080/10298430500335244
- Kim, S.-H., Yang, J., & Jeong, J.-H. (2014). Prediction of subgrade resilient modulus using artificial neural network. *KSCE Journal of Civil Engineering*, 18(5), 1372–1379.
doi.org/10.1007/s12205-014-0316-6
- Kim, S. (2004). Determination of aggregate physical properties and its effect on cross-anisotropic behavior of unbound aggregate materials. *Texas A&M University*.
- Musharraf, Z., Pranshoo, S., Ali, E., & Luther, W. (2010). Neural Network Modeling of Resilient Modulus Using Routine Subgrade Soil Properties. *International Journal of Geomechanics*, 10(1), 1–12.
doi.org/10.1061/(ASCE)15323641(2010)10:1(1)
- Nazzal, M. D., & Tatari, O. (2013). Evaluating the use of neural networks and genetic algorithms for prediction of subgrade resilient modulus. *International Journal of Pavement Engineering*, 14(4), 364–373.
doi.org/10.1080/10298436.2012.671944
- Okeke, C. A. U. (2020). Engineering behaviour of lime- and waste ceramic dust-stabilized expansive soil under continuous leaching. *Bulletin of Engineering Geology and the Environment*, 79(4), 2169–2185.
doi.org/10.1007/s10064-019-01648-2
- Pahno, S., Yang, J. J., & Kim, S. S. (2021). Use of Machine Learning Algorithms to Predict Subgrade Resilient Modulus. In *Infrastructures*, Vol. 6, Issue 6.
doi.org/10.3390/infrastructures6060078
- Pal, M., & Deswal, S. (2014). Extreme Learning Machine Based Modeling of Resilient Modulus of Subgrade Soils. *Geotechnical and Geological Engineering*, 32(2), 287–296.
doi.org/10.1007/s10706-013-9710-y
- Park, H. I., Kweon, G. C., & Lee, S. R. (2009). Prediction of Resilient Modulus of Granular Subgrade Soils and Subbase Materials using Artificial Neural Network. *Road Materials and Pavement Design*, 10(3), 647–665.
- Amiri, A. M., Nadimi, N., & Yousefian, A. (2020). Comparing the efficiency of different computation intelligence techniques in predicting accident frequency. *IATSS Research*, 44(4), 285–292.
doi.org/10.1016/j.iatssr.2020.03.003
- Ardah, A., Chen, Q., & Abu-Farsakh, M. (2017). Evaluating the performance of very weak subgrade soils treated/stabilized with cementitious materials for sustainable pavements. *Transportation Geotechnics*, 11, 107–119.
doi.org/https://doi.org/10.1016/j.trgeo.2017.05.002
- Dhar, S., & Hussain, M. (2021). The strength and microstructural behavior of lime stabilized subgrade soil in road construction. *International Journal of Geotechnical Engineering*, 15(4), 471–483.
doi.org/10.1080/19386362.2019.1598623
- Ghorbani, B., Arulrajah, A., Narsilio, G., Horpibulsuk, S., & Bo, M. W. (2020). Development of genetic-based models for predicting the resilient modulus of cohesive pavement subgrade soils. *Soils and Foundations*, 60(2), 398–412.
doi.org/10.1016/j.sandf.2020.02.010
- Hanandeh, S., Ardah, A., & Abu-Farsakh, M. (2020). Using artificial neural network and genetics algorithm to estimate the resilient modulus for stabilized subgrade and propose new empirical formula. *Transportation Geotechnics*, 24, 100358.
doi.org/10.1016/j.trgeo.2020.100358
- Hanittinan, W. (2007). Resilient modulus prediction using neural network algorithm. *The Ohio State University*.
- Hossain, M. (2008). Characterization of Subgrade Resilient Modulus for Virginia Soils and Its Correlation with the Results of Other Soil Tests.
- Ikechukwu, A. F., Hassan, M. M., & Moubarak, A. (2021). Resilient modulus and microstructure of unsaturated expansive subgrade stabilized with activated fly ash. *International Journal of Geotechnical Engineering*, 15(8), 915–938.
doi.org/10.1080/19386362.2019.1656919
- Jue, L., Junhui, Z., Guoping, Q., Jianlong, Z., & Yuqing, Z. (2019). Three-Dimensional Simulation of Aggregate and Asphalt Mixture Using Parameterized Shape and Size Gradation. *Journal of Materials in Civil Engineering*,

- Yang, Y. Zhang, Q. (2007). Analysis for the results of point load testing with artificial neural network. *Computer Methods & Advances in Geomechanics*.
- Zhang, J., Gu, F., & Zhang, Y. (2019). Use of building-related construction and demolition wastes in highway embankment: Laboratory and field evaluations. *Journal of Cleaner Production*, 230, 1051–1060.
doi.org/https://doi.org/10.1016/j.jclepro.2019.05.182
- Zhang, J., Peng, J., Liu, W., & Lu, W. (2021). Predicting resilient modulus of fine-grained subgrade soils considering relative compaction and matric suction. *Road Materials and Pavement Design*, 22(3), 703–715.
doi.org/10.1080/14680629.2019.1651756
- Zhang, J., Peng, J., Zeng, L., Li, J., & Li, F. (2021). Rapid estimation of resilient modulus of subgrade soils using performance-related soil properties. *International Journal of Pavement Engineering*, 22(6), 732–739.
doi.org/10.1080/10298436.2019.1643022
- doi.org/10.1080/14680629.2009.9690218**
- Raju, M. M., Srivastava, R. K., Bisht, D. C. S., Sharma, H. C., & Kumar, A. (2011). Development of Artificial Neural-Network-Based Models for the Simulation of Spring Discharge. *Advances in Artificial Intelligence*, 2011, 686258.
doi.org/10.1155/2011/686258
- Sadrossadat, E., Heidaripanah, A., & Ghorbani, B. (2018). Towards application of linear genetic programming for indirect estimation of the resilient modulus of pavements subgrade soils. *Road Materials and Pavement Design*, 19(1), 139–153.
doi.org/10.1080/14680629.2016.1250665
- Sung-Hee, K., Erol, T., N., L. D., & Nakseok, K. (2007). Effect of Gradation on Nonlinear Stress-Dependent Behavior of a Sandy Flexible Pavement Subgrade. *Journal of Transportation Engineering*, 133(10), 582–589.
doi.org/10.1061/(ASCE)0733-947X(2007)133:10(582)

Development of a Model for Predicting the Resilient Modulus of Stabilized Clay Soils Using Artificial Neural Network

Vahid Khalifeh, Assistant Professor, Department of Civil Engineering, Sirjan University of Technology, Sirjan, Iran.

Ali Reza Ghanizadeh, Associate Professor, Department of Civil Engineering, Sirjan University of Technology, Sirjan, Iran.

Navid Nadimi, Associate Professor, Civil Engineering Department, Shahid Bahonar University of Kerman, Kerman, Iran.

E-mail: navidnadimi@uk.ac.ir

Received: June 2023- Accepted: November 2023

ABSTRACT

In road pavement design, soil resilient modulus is one of the factors that play a very important role in determining pavement thickness. In the past, determining the Resilient Modulus of soil directly from laboratory results has not always been practical due to its high costs, both in terms of equipment and labor. Therefore, it is possible to predict and determine this parameter based on past field data using artificial intelligence. Our goal in this paper is to develop a model for predicting the resilient modulus of stabilized clay soils using artificial neural networks. In this study, four different soil samples stabilized with additives, such as lime, fly ash, and cement kiln dust, were examined using the pavement design appendix of the AASHTO 2002 specification. By comparing the results to the laboratory data based on the statistical indicators such as regression coefficient (0.99), root mean square error (less than 6 percent), we found that the artificial neural network was highly accurate in predicting the resilient modulus.

Keywords: Resilience Modulus, Artificial Neural Network, Prediction, Pavement