

جستجوی بهترین مدل‌های معما ری در شبکه عصبی برای مدلسازی پارامترهای مکانیکی نرمال شده بتن

مقاله پژوهشی

سید امیرحسین هاشمی، گروه مهندسی عمران، دانشکده عمران و نقشه برداری، دانشگاه آزاد اسلامی، قزوین، ایران

علیرضا عاملی^{*}، گروه مهندسی عمران، واحد ملارد، دانشگاه آزاد اسلامی، ملارد، تهران، ایران

سید محمدجواد شفیعی شالکه، گروه مهندسی عمران، دانشکده عمران و نقشه برداری، دانشگاه آزاد اسلامی، قزوین، ایران

الله السادات هاشمی، گروه مهندسی عمران و معما ری، دانشکده فنی و مهندسی، دانشگاه رجاء، قزوین، ایران

^{*}پست الکترونیکی نویسنده مسئول: Amelii@gmail.com

دریافت: ۱۴۰۰/۰۲/۲۰ - پذیرش: ۱۴۰۰/۰۶/۲۰

صفحه ۴۱-۶۰

چکیده

در این پژوهش به منظور ارزیابی عملکرد شبکه عصبی از دو مدل شبکه عصبی *RBF* و شبکه عصبی *MLP* در راستای پیش‌بینی مقاومت‌های خمشی، کششی و فشاری استفاده شد. داده‌های مورد استفاده، از نتایج مدل‌های برازش شده بر تابع آزمایشات انجام شده بر روی نمونه‌های بتن غلتک حاوی مقادیر مختلف خرد لاستیک بازیافن، خاکستر بادی و نانوسیلیس بر اساس آزمایشات مقاومت فشاری، خمشی و کششی گرفته شده است. انواع مختلفه‌های عصبی مصنوعی برای پیش‌بینی انواع مقاومت بتن استفاده شده‌اند. در هر قسمت ساختار شبکه عصبی مورد استفاده به همراه جدول اطلاعات ورودی و نتایج خروجی آن شبکه آورده شده است. در هر نوع شبکه عصبی از تعداد لایه‌ها و تعداد نرون‌های مختلفی برای مدلسازی استفاده شده است. در جداول، ردیف‌های سبزرتگ نشان‌دهنده‌ی پیش‌بینی ساختاری است که توانسته به خوبی مقاومت‌های بتن را پیش‌بینی کند. همچنین پیش‌بینی نتیجه (کمترین خطأ و بالاترین ضریب همبستگی) با درنظر گرفتن عملکرد شبکه در پیش‌بینی همزمان انواع مقاومت انتخاب شده است. نتایج مقاومت‌های فشاری و کششی، در یک راستا بوده و عموماً هم راستا می‌باشد ولی مقاومت خمشی معمولاً نتایج متفاوتی را از خود نشان داده است.

واژه‌های کلیدی: مدل، معما ری، شبکه عصبی، پارامترهای مکانیکی، بتن

۱- مقدمه

اقتصادی در دنیا، به خصوص در کشورهای در حال توسعه و در پی آن نیاز به ساخت سازه‌های مختلف و مقاوم موجب شده تا بتن به عنوان یکی از پرصرف‌ترین مصالح ساختمانی شناخته شود. نسبت مصرف بتن به فولاد ده به یک و میزان مصرف کل بتنی که در سال ۱۹۹۱ میلادی در جهان مصرف شده است بالغ بر سه میلیارد تن یعنی در زمان خود تقریباً یک تن به ازای هر نفر در جهان تخمین زده می‌شود (Chen و همکاران(۲۰۱۵)). پیشرفت قابل ملاحظه و توسعه

سهولت به دسترسی اجزاء تشکیل دهنده، شکل پذیری و پایایی نسبتاً بالای آن را باید نام برد (اسکندری و همکاران (۱۳۹۳)). این عوامل باعث توجه روز افرون به آن شده است. در ساختمان یک سازه بتنی لازم است نسبت اجزاء بتن طراحی شود. برخلاف فولاد، در مورد بتن نمی‌توان به مشخصات ارائه شده از سوی سازندگان اکتفا کرد. بتن جسم بسیار سخت و سنگ مانندی است که از ترکیب مقدار معین و حساب شده سیمان، شن و ماسه و همچنین آب و بعضی از مواد مضاف بر اساس اهدافی خاص به دست می‌آید (مجتبی و همکاران (۱۳۹۷)).

بتن ماده‌ای شبیه به سنگ است که از گرفتن مخلوط مناسبی از سیمان، شن، ماسه و آب در درون قالبی با شکل و ابعاد مورد نظر، بدست می‌آید. از مزایای بتن می‌توان به شکل خمیری قبل از گیرش، مقاومت خوب آن در مقابل آتش‌سوزی و عوامل جوی، در دسترس بودن مصالح آن (به غیر از سیمان که یک تولید کارخانه‌ای است و مقاومت فشاری خوب آن همانند سنگ اشاره کرد. در مقابل این مزایا عیب بتن مقاومت کششی ضعیف آن است که باعث می‌شود نتوان از بتن در اعضا‌بی که تحت تأثیر کشش و یا خمسمی باشند، استفاده کرد. برای غلبه بر این محدودیت، در نیمه دوم قرن نوزدهم، بتن را در قسمت‌هایی که تحت کشش قرار می‌گیرند، توسط میلگردهای فولادی که مقاومت کششی آنها بالاست، مسلح نمودند. عامل مهمی که در این مکانیسم نقش اساسی بازی می‌کند، چسبندگی عالی بتن به میلگردهای مسلح کننده می‌باشد که می‌تواند کاملاً این دو ماده‌ی مختلف را با یکدیگر یکپارچه کند. این ترکیب به دست آمده بتن مسلح خوانده می‌شود (Choi و همکاران (۲۰۱۲)). با پیشرفت سریع تکنولوژی بتن در جهان، امکان تولید بتن‌های با مقاومت بالاتر افزایش یافته و نیز تعریف بتن با مقاومت بالا روز به روز در حال تغییر است. در سال ۱۹۵۰، بتن با مقاومت فشاری ۳۴ مگا پاسکال به عنوان بتن با مقاومت بالا محسوب می‌شد؛ در حالی که در سال‌های ۱۹۶۰ و ۱۹۷۰، از بتن‌های با مقاومت فشاری در حدود ۵۲ مگا پاسکال و ۶۲ مگا پاسکال به عنوان بتن با مقاومت بالا یاد می‌شد. در کارگاه‌های آمریکای شمالی معمولاً به بتن‌های با مقاومت

همکاران (۲۰۱۴)). در ساخت بتن از آب برای هیدراسیون سیمان استفاده می‌شود و نتیجتاً از جمله اصلی ترین عوامل آسیب در یخ‌بندان به بتن، آب آزاد موجود در آن می‌باشد. در عین حال بتن نسبت به چوب و فولاد معمولی در برابر آب مقاومت بیشتری از خود نشان داده است. یکی از زمینه‌های مهم تحقیق و توسعه در زمینه بتن، دستیابی به بتن با دوام است. رسیدن به این مهم بدون استفاده از مواد افزودنی امکان پذیر نیست. بهبود خواص بتن به دو روش کلی: ۱- تسليح کردن بتن با استفاده از الیاف و میلگرد که عمدتاً جهت بهبود مقاومت خمثی و شکل پذیری بتن ۲- بهبود کیفیت خود بتن از طریق افزودن مواد شیمیایی، نانو مواد و پوزولان ها صورت می‌گیرد (Chen و همکاران (۲۰۱۹)). برای کاهش میزان مصرف آب در بتن از محلول روان کننده (بتن نرمال شده) به عنوان یکی از پرمصرف‌ترین افزودنی‌های بتن استفاده می‌شود. افزودنی‌های بتن مواد شیمیایی هستند که حین فرایند اختلاط بتن در مقادیر حداقل پنج درصد وزن سیمان موجود در بتن اضافه می‌شود تا بعضی از خواص آن را به شکل مطلوبی تغییر دهد. میزان مصرف مواد مضاف در بتن ناچیز است و معمولاً به صورت درصدی از وزن سیمان مشخص می‌شود (Lehner و همکاران (۲۰۱۵)). مواد افزودنی از نظر ترکیب نمکها و پلیمرهای قابل حل، تا کانی‌های غیرقابل حل، متغیر می‌باشند. اهدافی که مواد افزودنی برای آنها در بتن مورد مصرف قرار می‌گیرند به طور کلی شامل: بهبود کارایی، تسریع یا تعویق زمان‌گیرش، کترول افزایش مقاومت و افزایش مقاومت در مقابل: عمل یخ زدگی، ترک خوردنگی حرارتی، انساط قلیایی سنگ دانه و محلول‌های اسیدی و سولفاتی می‌شوند (Kabantsev و همکاران (۲۰۱۷)). در این پژوهش به جستجوی بهترین مدل‌های معماری در شبکه عصبی برای مدلسازی پارامترهای مکانیکی نرمال شده بتن پرداخته می‌شود. در حال حاضر بتن یکی از پرمصرف‌ترین فرآورده‌های ساختمانی در جهان شناخته شده است. از ویژگی‌های بسیار خوب آن، اقتصادی بودن،

همراه با دو مجموعه متفاوت از پارامترهای ورودی پرداختند. هدف از این پژوهش، ارزیابی عملکرد شبکه ای عصبی مصنوعی المان با درنظر گرفتن پارامترهای ورودی مختلف در پیش بینی مقاومت فشاری بتن خودتراکم بوده. از این رو، یکبار ۸ پارامتر تأثیرگذار و بار دیگر جهت نزدیک شدن هرچه بیشتر شرایط پیش بینی به شرایط آزمایشگاهی، ۱۴۰ پارامتر به عنوان ورودی وارد شبکه های عصبی المان شدند. نتایج نشان داد، شبکه های عصبی المان به عنوان ابزار قابل اعتمادی با صرفه جویی در زمان و هزینه دارای قدرت بالایی در پیش بینی مشخصه های موردنظر بوده اند. به علاوه، در پیش بینی هر دو مقاومت فشاری ۷ و ۲۸ روزه، شبکه های ساخته شده با تعداد ۱۴۰ پارامتر به ترتیب به میزان ۷۴/۵۴ و ۷۰/۴۴ درصد بهبود در خطای تست نسبت به شبکه ها با ۸ پارامتر دارند که این اثرگذاری مستقیم پارامترهای مؤثر در نظر گرفته شده به عنوان ورودی را بر میزان خطای شبکه در پیش بینی خواص مدنظر نشان می دهد (غلام زاده و همکاران(۱۳۹۷)). کلینیک بتن ایران در سال ۱۳۹۷، در پژوهشی به بررسی تأثیر میکروسیلیس بر مقاومت فشاری و کششی بتن سبک الیافی پرداختند. این پژوهش به بررسی تأثیر میکروسیلیس بر خواص مکانیکی بتن الیافی الاف فولادی و پلی پروپیلن حاوی سبکدانه اسکوریا می پردازد. میکروسیلیس در مقادیر ۱۰٪ و ۱۵٪ جایگزین وزنی سیمان شده است. میزان الاف فولادی و پلی پروپیلن در این مطالعات به ترتیب برابر با (۸۰٪-۴۰٪) حجم بتن و (۶۰٪-۴۰٪) حجم بتن و با نسبت طول به قطر ۶۲/۵ و ۶۰ می باشد. در این مطالعه ۹ ترکیب مختلف بتن سبک حاوی درصد های مختلف الاف فولادی و پلی پروپیلن ساخته شد و تحت آزمایش های مقاومت فشاری، مقاومت کششی به روش دو نیم شدن قرار گرفته اند که نتایج آزمایش ها بیانگر آن است که درصد بهینه میکروسیلیس ۱۰ درصد می باشد. همچنین الاف فولادی نسبت به الاف و پلی پروپیلن تأثیر بهتری بر خواص مکانیکی بتن سبک می باشد (کلینیک بتن ایران(۱۳۹۷)). صدری نژاد و همکاران در سال ۲۰۱۸، در پژوهشی به بررسی خواص مکانیکی و دوام بتن حاوی الاف مصنوعی هیرید پرداختند. در این پژوهش، خواص تازه و سخت شده بتن شامل هیریداسیون پلی اتیلن (PO) و پلی پروپیلن (PP)

فشاری ۲۸ روزه و بیشتر از ۴۲ مگاپاسکال بتن با مقاومت بالا اطلاق می شود. امروزه بتن های با مقاومت فشاری کمتر از ۲۰ مگا پاسکال به عنوان بتن با مقاومت پایین، بتن های با مقاومت فشاری در محدوده ۲۰ تا ۴۰ مگا پاسکال به عنوان بتن با مقاومت فشاری معمولی یا متوسط، بتن های با مقاومت فشاری در محدوده ۴۰ تا ۸۰ مگا پاسکال عنوان بتن با مقاومت بالا، بتن های با مقاومت فشاری ۸۰ مگا پاسکال تا ۱۵۰ به عنوان بتن با مقاومت بسیار بالا، و بتن های با مقاومت فشاری بیش از ۱۵۰ مگا پاسکال به عنوان بتن با مقاومت فوق العاده زیاد قلمداد می شوند. Badogiannis و همکاران (۲۰۱۹). لازم به ذکر است که از انواع بتن های با مقاومت بالا به عنوان بتن با عملکرد بالا و یا بتن توانمند نیز یاد می شود؛ چرا که چنین بتن هایی معمولاً با نفوذپذیری کم و کیفیت بسیار خوب، دوام بسیار خوبی نیز در مقابل انواع شرایط نامناسب محیطی از خود نشان می دهند. تولید بتن با مقاومت بالا با به کارگیری نسبت های درست و مناسب ترکیبات بتن، کاهش نسبت آب به سیمان، استفاده از میکروسیلیس به عنوان جانشین بخشی از سیمان، و نیز استفاده از سنگ دانه های مقاوم و متراکم امکان پذیر خواهد بود (Gelardi و همکاران(۲۰۱۶)). شکری و همکاران در سال ۱۳۹۸ در پژوهشی به بررسی مدل سازی مقاومت فشاری بتن سبک فوم با استفاده از روش های شبکه عصبی مصنوعی و ماشین های بردار پشتیبان پرداختند. هدف اصلی در این پژوهش، ارزیابی مدل سازی مقاومت فشاری جهت آرائه روابطی برای پیش بینی مقاومت فشاری بتن فوم، مقایسه آن با مدل های هوشمند مصنوعی دیگر، ارزیابی دقت مدل و پارامترهای تأثیرگذار و در نهایت اعتبار سنجی آن بوده. مدل های ارائه شده در این مطالعه با استفاده از روش های شبکه عصبی مصنوعی و ماشین های بردار پشتیبان توسعه داده شد و نتایج آنها با استفاده از شاخص های آماری خطای مورد بررسی قرار گرفت. همچنین در آخر اعتبار مدل های توسعه داده شده مقاومت فشاری نیز، ارزو شون اعتبار سنجی با استفاده از معیارهای ارزیابی دیگر ارزیابی گردید که اعتبار مدل ها مورد تایید رضایت بخش بوده است (شکری و همکاران(۱۳۹۸)). غلام زاده و برنجیان در سال ۱۳۹۷، در پژوهشی به بررسی پیش بینی مقاومت فشاری بتن خودتراکم توسعه شبکه عصبی مصنوعی المان

مدلهای مختلف رابطه بین مقاومتهای نهایی برای تعدادی از مواد ترکیبی مورد تجزیه و تحلیل قرار می‌گیرد. نتایج بدست آمده به شما اجازه می‌دهد تا با دقت قابل قبول در مراحل اولیه طراحی سازه‌های کامپوزیت، مقاومت فشاری نهایی خود را از نتایج آزمایشات ساده بر روی نمونه‌های ماده در کشش و خمش سه نقطه ای یا از مقادیر شناخته شده مقاومت مربوطه، تعیین کند (Kondratiev و همکاران ۲۰۱۹).

۲-روش تحقیق

روش انجام تحقیق به صورت تجربی، از طریق مطالعه مقالات و تحقیقات علمی، گزارش‌های فنی، کتب، پایان نامه‌ها و پژوهش‌های تحقیقاتی صورت گرفته و مطالب موجود در سایت‌های اینترنتی علمی و فنی در زمینه جستجوی بهترین مدل‌های معماری در شبکه عصبی برای مدلسازی پارامترهای مکانیکی نرمال شده بتن مورد استفاده قرار می‌گیرد. پس از تعریف دقیق مسئله، ساختار ارائه شده تحلیل می‌شود و نتیجه گیری‌های لازم به عمل خواهد آمد و کارایی روش پیشنهادی برای برآورده کردن خواسته‌های مسئله مورد ارزیابی قرار خواهد گرفت. بردار وزن، معادل مقادیر اطلاعات سیناپسی و رودی‌های نورون می‌باشد. میزان تأثیر ورودی x_i بر خروجی y_i ، w_i قابل توسط مشخصه \bar{x}_i وزن اندازه گیری می‌شود. w_i قابل تنظیم بوده و بر اساستابع تبدیل و نوع الگوریتم یادگیری تعدیل می‌شود. تابع جمع عملیات پردازش نورون را انجام می‌دهد. در شبکه‌های تک نورونی، تابع جمع، خروجی مسئله را تا حدودی مشخص می‌کند. در شبکه‌های چند نورونی، تابع جمع سطح فعالیت نورون j در لایه‌های درونی را مشخص می‌سازد. رابطه (۱) تابع جمع را نشان می‌دهد. در این رابطه \bar{x}_i معادل ورودی‌های شبکه و w_{ij} معادل بردار وزن شبکه هستند.

(۱)

$$\sum x_j w_{ij}$$

تابع فعالیت، تابعی است که مقادیر خروجی یک نورون مصنوعی را بر اساس مقادیر ورودی‌اش تعیین می‌کند. به تعبیر بهتر، تابع فعالیت آستانه‌ای برای مقادیر خروجی هر

مورد بررسی قرار گرفت. دوازده مخلوط از دوزهای مختلف الیاف پلی اتیلن (PO) و پلی پروپیلن (PP) مورد بررسی قرار گرفتند. مخلوط‌ها شامل الیاف پلی اتیلن (PO) در بخش‌های حجمی $1/5$ ، $1/4$ ، $1/3$ بودند که برخی از آنها با الیاف پلی پروپیلن (PP) با جرم $1/10$ ٪ جایگزین شدند. خواص مخلوط‌ها با استفاده از تست‌های مخروطی کاهش و غلظت معکوس در حالت تازه و با استفاده از تست‌های فشاری، تقسیم و خمش در حالت سخت شده مورد ارزیابی قرار گرفت. علاوه بر این، خواص دوام با استفاده از جذب آب، مقاومت الکتریکی و آزمون نفوذ کلر مورد بررسی قرار گرفت. تیرهای بتن مسلح شامل الیاف ساخته شده و تحت خوردن سریع تست شدند. تأثیر الیاف بر عملکرد ساختاری پرتوهای صوتی و خورنده با استفاده از آزمون Barگذاری چهار نقطه بررسی شد (Sadrinejad و همکاران ۲۰۱۸). سیلوستون و همکاران در سال ۲۰۲۰ یک بررسی ادبیات سیستماتیک برای روشن کردن تأثیر CNT‌ها بر مقاومت فشاری، خمشی و کششی مواد مبتنی بر سیمان انجام دادند. اختلاط CNT باعث افزایش مقاومت فشاری تا 30% و مقاومت خمشی و کششی تا 50% می‌شود. علاوه بر این، محتوای CNT بهینه برای دستیابی به این پیشرفت‌ها تا 1% وزن سیمان است (Sivestro و همکاران ۲۰۲۰). حسن و همکاران در سال ۲۰۲۱، در تحقیقی نشان دادند که مقاومت کششی فشاری و خمشی به شدت به دمای پخت بستگی دارد. نمونه‌های آزمایش شده با دمای 90°C درجه سانتیگراد طی ۷ روز از زمان ریخته گری به حداقل مقاومت فشاری و خمشی رسیدند. نمونه‌هایی از دمای پخت در مدت ۳ روز پس از ریخته گری به مقاومت فشاری قابل توجه (بیش از 45 مگاپاسکال) رسیده و پس از 90 روز به مقاومت‌های مشابه نمونه‌های 90°C درجه سانتیگراد دست یافتند. علاوه بر این، مدل‌های مختلفی مانند مدل Vipulanandan مکانیکی UHPFRC برای هرگونه دما، سن و محتوای فیبر فولاد تولید شده است (Hassan و همکاران ۲۰۲۱). کوندرتیو در سال ۲۰۱۹، در تحقیقی روابط بین مقاومت نهایی خمش ثابت، فشار و کشش مواد کامپوزیت پلیمر بررسی شده است. اعتبار فرضیات مورد استفاده در

تصویر، ارتباطات، طراحی کنترلر، تست و اندازه گیری، مدل سازی مالی و تجزیه و تحلیل، و زیست شناسی محاسباتی اشاره نمود. همچنین امکان گسترش محیط مطلب با استفاده از افزودن جعبه ابزار برای اهداف مختلف داده شده است. در این پژوهش از ورژن ۲۰۱۹ استفاده شده و شبیه سازی برروی سیستمی با قدرت پردازندۀ ۲ هسته ای و میزان رم ۴ گیگابایت انجام شده است.

۳- تجزیه و تحلیل

در جدول ۱ ماتریس طرح آزمایشات و طرح اختلال نمونه ها ارائه شده است. این داده ها به عنوان داده های ورودی مدل سازی در نظر گرفته می شوند. بر این اساس، پارامترهای خاکستر بادی، خرده لاستیک و نانو سیلیس به عنوان پارامترهای ورودی شبکه عصبی در نظر گرفته شده و مقادیر مقاومت کثشی، مقاومت فشاری و مقاومت خمشی به عنوان خروجی مدل در نظر گرفته می شوند.

همانطور که پیش از این نیز عنوان شد، در این پژوهش از انواع شبکه های عصبی feedforward، perceptron، elmannet، cascade forward و patternnet استفاده می شود که در فصل قبل کلیاتی از آنها مورد بررسی قرار گرفتند. لازم بذکر است که شبکه عای عصبی از انواع متعدد دیگری نیز برخوردارند که با توجه به ماهیت داده های موجود امکان استفاده از آنها در این پژوهش وجود نداشته است، مانند شبکه های عصبی سری زمانی و ... موضوعی که در شبکه عصبی حائز اهمیت است، تابع آموزش دهنده است. در جدول ۲ مقایسه ای بین رگرسیون توابع آموزش مختلف ارائه شود تا مشخص شود کدام تابع کارایی بالاتری داشته است.

نورون در نظر می گیرد. قانون فعال سازی تعیین می کند که چگونه یک نورون واکنش فعال سازی برای هر الگوی ورودی را انجام می دهد.تابع فعال سازی محدوده ای وسیعی از مقادیر ورودی را به مقادیر خروجی نگاشت می کند. منظور از خروجی، همان پاسخ مسئله است. خروجی نورون از رابطه ۱ مشخص می شود. در این رابطه x_{ij} و w_{ij} همان مقادیر رابطه ۲ می باشند

$$Y_i = \text{Activation Function} \left(\sum x_j w_{ij} \right)$$

خروجی خطی و غیر خطی هر لایه شبکه عصبی دو لایه به

فرم زیر می باشد:

(۴) و (۵)

$$\text{neuron}(1.i) \begin{cases} s_i^{(1)} = \sum_{k=0}^n w_{ik}^{(1)} x_k \\ z_i = \delta(s_i^{(1)}) \\ i = 1.2. \dots .p \end{cases}$$

$$\text{neuron}(1.i) \begin{cases} s_j^{(2)} = \sum_{q=0}^n w_{jq}^{(2)} z_q \\ y_j = \delta(s_j^{(2)}) \\ i = 1.2. \dots .m \end{cases}$$

وزن های لایه اول و دوم شبکه عصبی دو لایه به صورت برداری:

(۳) و (۴)

$$W^{(1)} = [W_1^{(1)} \ W_2^{(1)} \ \dots \ W_p^{(1)}]^T = \begin{bmatrix} w_{11}^{(1)} & \dots & w_{1n}^{(1)} \\ w_{21}^{(1)} & \dots & w_{2n}^{(1)} \\ \vdots & \ddots & \vdots \\ w_{p1}^{(1)} & \dots & w_{pn}^{(1)} \end{bmatrix}$$

$$W^{(2)} = [W_1^{(2)} \ W_2^{(2)} \ \dots \ W_p^{(2)}]^T = \begin{bmatrix} w_{11}^{(2)} & \dots & w_{1n}^{(2)} \\ w_{21}^{(2)} & \dots & w_{2n}^{(2)} \\ \vdots & \ddots & \vdots \\ w_{p1}^{(2)} & \dots & w_{pn}^{(2)} \end{bmatrix}$$

در این پژوهش از نرم افزار MATLAB استفاده شده است. نرم افزار مطلب دارای طیف کاربردی گسترده ای است، که از آن جمله می توان به سیگناال و پردازش

جدول ۱. ماتریس طرح آزمایشات و طرح اختلاط نمونه‌ها (عاملی و همکاران، ۱۳۹۷)

خرده لاستیک (%)	حاکستر بادی (%)	نانوسیلیس (%)	مقاومت فشاری (مگاپاسکال)	مقاومت خمی (مگاپاسکال)	مقاومت کششی (مگاپاسکال)
20	50	1	43.13	7.75	4.32
10	70	2	33.53	5.14	3.14
20	60	1	32.38	5.75	3.33
30	60	1	33.28	5.15	3.07
20	60	1	32.07	6.06	3.02
10	60	1	38.88	6.71	3.72
10	50	0	38.21	4.35	3.36
20	60	0	22.71	5.26	2.72
30	50	0	30.25	4.07	2.72
30	70	2	24.43	3.41	2.4
20	60	1	30.37	6.27	3.28
20	60	1	34.78	6.06	3.41
10	70	0	26.69	3.83	2.56
20	60	1	33.61	6.27	3.11
20	60	2	29.45	5.89	3.15
20	70	1	28.08	5.45	2.95
30	50	2	33.29	4.38	2.84
10	50	2	44.46	4.97	4.22
30	70	0	21.86	3.24	2.05

جدول ۲. مقایسه همبستگی (رگرسیون) توابع آموزش مختلف شبکه عصبی

ضریب همبستگی	تعريف تابع	نوع تابع	شماره
۰,۹۳۵۶	Levenberg-Marquardt	Trainlm	۱
۰,۸۵۶۳	Scaled conjugate gradient	Trainscg	۲
۰,۹۰۶۵	Bayesian regularization	Trainbr	۳
۰,۸۳۴۶	BFGS quasi-Newton	trainbfg	۴
۰,۹۲۶۸	Conjugate gradient backpropagation with Powell-Beale restarts	traincgb	۵
۰,۹۰۶۳	Conjugate gradient backpropagation with Polak-Ribière updates	traincgp	۶
۰,۸۴۷۴	Gradient descent with adaptive learning rate	traingda	۷
۰,۸۹۷۹	Gradient descent with momentum	traingdm	۸
۰,۹۰۶۷	Gradient descent with momentum and adaptive learning rate	traingdx	۹
۰,۹۱۲۲	One-step secant	trainoss	۱۰

قبل از مدلسازی هر کدام از مقاومت‌ها با استفاده از شبکه عصبی feedforward، ابتدا نیاز است که تعداد لایه‌ها و تعداد نرون‌های مطلوب جهت مدلسازی تعیین گردد. این موضوع در جدول ۳ ارائه شده است.

از میان توابع فوق، تابع Levenberg-Marquardt که در کتابخانه متلب تحت عنوان trainlm شناخته می‌شود دارای بیشترین مقدار همبستگی می‌باشد. از این رو از این تابع برای آموزش داده‌ها استفاده می‌شود.

جدول ۳. مقایسه معماری‌های مختلف شبکه عصبی feedforward

شماره	نوع مقاومت بتن	تعداد لایه	تعداد نرون	خطای آموزش	خطای ارزیابی	همبستگی آموزش	همبستگی ارزیابی
۱	فشاری	۱	۵	۰.۰۱۳۳۰۴	۰.۰۳۲۴۶	۰.۸۹۶۳۷۵	۰.۸۴۶۶۳۴
	خمشی						
	کششی						
۲	فشاری	۱	۱۰	۰.۰۱۰۴۹۹	۰.۰۳۷۶۳۵	۰.۹۳۲۱۸۹	۰.۶۰۰۰۹۴
	الخمشی						
	کششی						
۳	فشاری	۱	۵۰	۰.۰۲۴۳۹۳	۰.۰۰۳۰۱	۰.۷۷۱۵۴۶	۰.۹۸۷۰۱۳
	الخمشی						
	کششی						
۴	فشاری	۱	۱۰۰	۰.۰۲۴۰۹۶	۰.۲۱۵۱۳۳	۰.۷۸۱۳۰۷	۰.۲۰۰۸۴۶
	الخمشی						
	کششی						
۵	فشاری	۱	۵	۰.۰۱۸۲۸۸	۰.۰۲۲۷۵۱	۰.۸۰۹۱۹۲	۰.۸۴۷۳۳۸
	الخمشی						
	کششی						
۶	فشاری	۵	۱۰	۰.۰۰۸۹۵۴	۰.۰۶۲۲۹	۰.۹۳۰۳۸۳	۰.۵۵۱۴۳۹
	الخمشی						
	کششی						
۷	فشاری	۵	۳۰	۰.۰۲۶۲۹۷	۰.۱۷۸۴۲	۰.۵۸۸۳۲۹	-۰.۳۷۷۶۵
	الخمشی						
	کششی						
۸	فشاری	۵	۱۰	۰.۰۰۳۰۹۴	۰.۰۸۰۵۸۴	۰.۹۶۵۶۸۳	۰.۴۱۵۵۲
	الخمشی						
	کششی						
۹	فشاری	۵	۱۰	۰.۰۲۰۶۰۸	۰.۰۱۵۵۹۱	۰.۸۴۸۸۴۶	۰.۹۰۵۰۶۶
	الخمشی						
	کششی						
۱۰	فشاری	۵	۳۰	۰.۰۴۶۶۹۴	۰.۰۷۱۴۵۱	۰.۴۷۰۶۹۳	۰.۳۵۵۳۱
	الخمشی						
	کششی						
۱۱	فشاری	۵	۳۰	۰.۰۱۴۰۷۷	۰.۰۳۲۱۰۷	۰.۸۷۲۲۳۴	۰.۷۸۵۱۶
	الخمشی						
	کششی						
۱۲	فشاری	۵	۳۰	۰.۰۱۵۴۷۵	۰.۰۲۶۲۳	۰.۸۹۸۲۳۳	۰.۶۷۴۶۲۳
	الخمشی						
	کششی						

0.52049	0.927944	0.035181	0.012861	۵	۱۰	فشاری	۸
0.106739	0.498513	0.033605	0.059711			خمشی	
0.31611	0.916053	0.03959	0.012193			کششی	
0.917994	0.823367	0.022605	0.017867	۱۰	۱۰	فشاری	۹
0.561376	0.383732	0.045961	0.054625			خمشی	
0.971995	0.685372	0.007084	0.022054			کششی	
0.422348	0.906794	0.03623	0.013649	۲۰	۱۰	فشاری	۱۰
0.07443	0.512673	0.044554	0.057044			خمشی	
0.480403	0.857111	0.013029	0.019645			کششی	

شبکه عصبی *cascadeforward*

این شبکه از لایه‌های میانی و خروجی، حاوی تعداد وزن‌ها و بایاس‌ها به ازای هر نرون تشکیل شده است. علاوه بر این، مستقیماً ورودی‌های این شبکه، به لایه خروجی اتصال یافته و وزنی به آنها اختصاص داده می‌شود. برای مدلسازی هر کدام از مقاومت‌ها با استفاده از شبکه عصبی *cascadeforward* مطلوب جهت مدلسازی به شبکه داده می‌شود. این موضوع در جدول ۴ ارائه شده است.

بر اساس معماری‌های مختلفی که بخشی از آن‌ها در جدول فوق ارائه شده است، مشخص می‌شود که تغییر تعداد لایه‌ها از ۱ تا ۱۰ لایه، در شرایطی که تعداد نرون‌ها تا حد مطلوبی افزایش یابند، سبب بهبود عملکرد یعنی کاهش خطأ و افزایش همبستگی میان داده‌های اندازه گیری شده و پیش‌بینی شده توسط شبکه می‌شود. از این رو، می‌توان نتیجه گرفت بهترین معماری برای شبکه عصبی *feedforward* در راستای تعیین انواع مقاومت‌ها برابر با ۱۰ لایه و ۱۰ نرون است.

جدول ۴. مقایسه معماری‌های مختلف شبکه عصبی *cascadeforward*

همبستگی ارزیابی	همبستگی آموزش	خطای ارزیابی آموزش	خطای آموزش	تعداد نرون	تعداد لایه	نوع مقاومت بتن	شماره
0.754583	0.92002	0.037677	0.010384	۵	۱	فشاری	۱
0.158116	0.520579	0.080862	0.042295			خمشی	
0.526448	0.933238	0.047025	0.007264			کششی	
0.815325	0.905492	0.045183	0.013262	۱۰	۱	فشاری	۲
0.190851	0.662833	0.118021	0.044273			خمشی	
0.807195	0.882168	0.048268	0.013322			کششی	
0.969717	0.738097	0.017056	0.019139	۵۰	۱	فشاری	۳
0.394037	0.476655	0.08719	0.04046			خمشی	
0.883697	0.723363	0.034621	0.012415			کششی	

0.894483	0.8185	0.032768	0.014196	۱۰۰	۱	فشاری	۴
0.334539	0.527965	0.074502	0.046302			خمشی	
0.946152	0.739418	0.011195	0.020598			کششی	
0.510935	0.943903	0.046516	0.007713	۵	۵	فشاری	۵
0.652355	0.408476	0.121863	0.036689			خمشی	
0.656389	0.914125	0.045909	0.008474			کششی	
0.846095	0.870995	0.030988	0.01225	۱۰	۵	فشاری	۶
0.9419	0.325024	0.080146	0.045676			خمشی	
0.921643	0.838759	0.030719	0.012384			کششی	
0.489838	0.948987	0.039624	0.007982	۲۰	۵	فشاری	۷
0.858515	0.448896	0.046653	0.059618			خمشی	
0.742338	0.852795	0.008953	0.020678			کششی	
0.643516	0.909053	0.033062	0.016182	۵	۱۰	فشاری	۸
-0.60972	0.638734	0.07602	0.049868			خمشی	
0.358998	0.932136	0.048845	0.010675			کششی	
0.842033	0.89953	0.033847	0.01122	۱۰	۱۰	فشاری	۹
0.329197	0.416604	0.064729	0.051709			خمشی	
0.924533	0.81092	0.016029	0.019824			کششی	

شبکه عصبی *elmannet*

برای مدلسازی هر کدام از مقاومت ها با استفاده از شبکه عصبی *elmannet*، تعداد لایه ها و تعداد نرون های مطلوب جهت مدلسازی به شبکه داده شده است. این موضوع در جدول ۵ ارائه شده است.

همانطور که در جدول ۴ مشاهده می شود، بهترین معماری برای شبکه عصبی *cascadeforward* جهت پیش بینی همزمان انواع مقاومت های بتن، داشتن ۵ لایه میانی و ۱۰ نرون در هر لایه است. لذا با داشتن این معماری، می توان به مدلسازی پیش بینی هر کدام از مقاومت های مورد نظر پرداخت.

جدول ۵. مقایسه معماری های مختلف شبکه عصبی *elmannet*

شماره	نوع مقاومت بتن	تعداد لایه	تعداد نرون	خطای آموزش	خطای ارزیابی	همبستگی آموزش	همبستگی ارزیابی
۱	فشاری	۱	۵	0.012331	0.036982	0.915139	0.76913
	خمشی			0.041675	0.090355	0.523968	0.061956

فصلنامه علمی پژوهشنامه حمل و نقل، سال هجدهم، دوره سوم، شماره ۶۸، پاییز ۱۴۰۰

0.632144	0.951288	0.045368	0.005226			کششی	
0.774917	0.88603	0.031697	0.014903	۱۰	۱	فشاری	۲
0.191102	0.52574	0.051956	0.052878			خمشی	
0.775452	0.865443	0.028251	0.017653			کششی	
0.880471	0.835373	0.024132	0.016305	۵۰	۱	فشاری	۳
0.53843	0.323589	0.096927	0.03345			الخمشی	
0.773915	0.888927	0.039193	0.007794			کششی	
0.81223	0.897096	0.03733	0.010921	۱۰۰	۱	فشاری	۴
0.2229	0.329547	0.090083	0.054432			الخمشی	
0.921048	0.796269	0.026225	0.019085			کششی	
0.677116	0.927477	0.035512	0.010744	۵	۵	فشاری	۵
0.78665	0.476871	0.057826	0.057094			الخمشی	
0.777301	0.84779	0.008128	0.02122			کششی	
0.98316	0.698916	0.010019	0.026127	۱۰	۵	فشاری	۶
0.564678	0.546035	0.190565	0.034937			الخمشی	
0.945777	0.648606	0.029207	0.020421			کششی	
0.433072	0.930565	0.035572	0.012278	۲۰	۵	فشاری	۷
-0.29985	0.533695	0.061198	0.054774			الخمشی	
0.153733	0.917787	0.042386	0.012165			کششی	
0.856667	0.860538	0.01783	0.021186	۵	۱۰	فشاری	۸
0.315127	0.602854	0.153641	0.032488			الخمشی	
0.687243	0.919523	0.055823	0.0098			کششی	
0.379376	0.677128	0.09974	0.067447	۱۰	۱۰	فشاری	۹
0.234339	0.221396	1.226708	2.474263			الخمشی	
0.381767	-0.16898	0.640067	1.822348			کششی	
0.869331	0.872825	0.009395	0.021882	۳۰	۱۰	فشاری	۱۰
0.889819	0.500642	0.073493	0.052758			الخمشی	

0.851816	0.862573	0.016902	0.019199			کششی	
0.875024	0.862577	0.010221	0.021867	۵۰	۱۰	فشاری	۱۱
-0.48024	0.635899	0.111676	0.044298			خمشی	
0.483934	0.884806	0.030438	0.015782			کششی	

شبکه عصبی perceptron

این شبکه تنها از یک لایه میانی و یک نرون حاوی وزن و بایاس تشکیل شده است. برای مدلسازی هر کدام از مقاومت‌ها با استفاده از شبکه عصبی perceptron، این شبکه را در محیط نرم افزار اجرا می‌کنیم. این موضوع در جدول ۶ ارائه شده است.

همانطور که در جدول ۵ مشاهده می‌شود، بهترین معماری برای شبکه عصبی elmannet جهت پیش‌بینی همزمان انواع مقاومت‌های بتن، داشتن ۱۰ لایه میانی و ۳۰ نرون در هر لایه است که از آن برای مدلسازی پیش‌بینی هر کدام از مقاومت‌های مورد نظر استفاده می‌شود.

جدول ۶. معماری شبکه عصبی perceptron

همبستگی ارزیابی	همبستگی آموزش	خطای ارزیابی	خطای آموزش	تعداد نرون	تعداد لایه	نوع مقاومت بتن	شماره
0.44161	0.453193	0.36896	0.242927	۱	۱	فشاری	۱
0.755056	-0.01285	0.134209	0.302037			الخمشی	
0.593724	NaN	0.258279	0.293267			کششی	

لایه خروجی در این نوع شبکه با سایر شبکه‌های عصبی ارائه شده در این قسمت متفاوت است. قبل از مدلسازی هر کدام از مقاومت‌ها با استفاده از شبکه عصبی patternnet، ابتدا نیاز است که تعداد لایه‌ها و تعداد نرون‌های مطلوب جهت مدلسازی تعیین گردد. این موضوع در جدول ۷ ارائه شده است.

همانطور که در جدول ۶ مشاهده می‌شود، این شبکه به علت محدودیت در تنوع، با یک ساختار اجرا شده است که عمکرد نامطلوبی را در پیش‌بینی انواع مقاومت‌های بتن از خود نشان داده است.

شبکه عصبی patternnet این شبکه از لایه‌های میانی و خروجی، حاوی تعداد وزن‌ها و بایاس‌ها به ازای هر نرون تشکیل شده است. ساختار

جدول ۷. مقایسه معماری‌های مختلف شبکه عصبی patternnet

همبستگی ارزیابی	همبستگی آموزش	خطای ارزیابی	خطای آموزش	تعداد نرون	تعداد لایه	نوع مقاومت بتن	شماره شبکه
0.811721	0.878338	0.077491	0.01452	۵	۱	فشاری	۱
-0.24124	0.423166	0.140664	0.033339			الخمشی	
0.718406	0.870436	0.059777	0.009036			کششی	

0.732343	0.868897	0.040293	0.016155	۱۰	۱	فشاری	۲
0.384467	0.542756	0.047378	0.049451			خمشی	
0.814752	0.837728	0.027801	0.020226			کششی	
0.821061	0.859034	0.036427	0.014221	۵۰	۱	فشاری	۳
0.929268	0.353163	0.094502	0.040493			خمشی	
0.911316	0.819361	0.034193	0.013657			کششی	
0.963721	0.744836	0.020261	0.025082	۱۰۰	۱	فشاری	۴
0.459913	0.526504	0.062161	0.047859			خمشی	
0.915964	0.707845	0.014951	0.021248			کششی	
0.756108	0.922538	0.060506	0.007411	۵	۵	فشاری	۵
0.634768	0.33754	0.061247	0.045337			خمشی	
0.738593	0.903303	0.055765	0.007559			کششی	
0.856262	0.880674	0.047501	0.015451	۱۰	۵	فشاری	۶
0.712754	0.334734	0.069503	0.04366			خمشی	
0.766302	0.894808	0.044537	0.008721			کششی	
0.036001	0.241054	0.880121	0.404212	۲۰	۵	فشاری	۷
0.454588	-0.16755	1.862234	2.028955			خمشی	
-0.4333	-0.55731	0.81119	0.581331			کششی	
0.846034	0.786806	0.04381	0.013159	۵	۱۰	فشاری	۸
0.095272	0.424817	0.12819	0.031476			خمشی	
0.882327	0.656039	0.055377	0.010196			کششی	
0.125411	-0.40606	0.638506	0.964641	۱۰	۱۰	فشاری	۹
-0.58514	0.341746	1.26455	0.626726			خمشی	
-	-	2.171874	2.254868			کششی	

تعداد لایه‌ها از ۱ تا ۱۰ لایه، سبب بهبود عملکرد مدل،
یعنی کاهش خطا و افزایش همبستگی میان داده‌های

بر اساس معماری‌های مختلفی که بخشی از آن‌ها در
جدول فوق ارائه شده است، مشخص می‌شود که تغییر

است. از این رو، می‌توان نتیجه گرفت بهترین معناری برای شبکه عصبی patternnet در راستای تعیین انواع مقاومت‌ها دارا بودن ۱ لایه و ۵۰ نرون است. در جداول ۸ و ۹ مقایسه‌ای بین ساختار هر کدام از انواع شبکه‌های عصبی بکار رفته در این پژوهش جهت تعیین انواع مقاومت‌های کششی، خمسی و فشاری ارائه شده است.

اندازه گیری شده و پیش‌بینی شده توسط شبکه نشده است و برخلاف سایر شبکه‌های عصبی ارائه شده در این پژوهش این افزایش با یک روند مشخصی منجر به بدتر شدن عملکرد شبکه عصبی شده است. البته این قائله شامل افزایش تعداد نرون‌ها نشده، بلکه افزایش آنها تا تعداد ۵۰ نرون عملکرد شبکه عصبی را بهبود بخشدیده.

جدول ۸ مقایسه کمترین خطای حاصل از پیش‌بینی انواع مدل‌ها در حالت ارزیابی

patternnet	perceptron	elmannet	cascadeforward	feedforward	مدل
0.036427	0.36896	0.009395	0.030988	0.022605	فشاری
0.094502	0.134209	0.073493	0.080146	0.045961	خمسی
0.034193	0.258279	0.016902	0.030719	0.007084	کششی

جدول ۹. مقایسه بیشترین ضریب همبستگی حاصل از پیش‌بینی انواع مدل‌ها در حالت ارزیابی

patternnet	perceptron	elmannet	cascadeforward	feedforward	مدل
0.821061	0.44161	0.869331	0.846095	0.917994	فشاری
0.929268	0.755056	0.889819	0.9419	0.561376	خمسی
0.911316	0.593724	0.851816	0.921643	0.971995	کششی

منتخب در این پژوهش انتخاب کرد. شبکه عصبی cascadeforward در مجموع نسبت به سایر شبکه‌ها ضریب همبستگی بالاتر و مجموع مربعات خطای هر لایه میانی و ۱۰ نرون در هر لایه شبکه در حالت بهینه دارای ۵ لایه میانی و ۱۰ نرون در هر لایه است. در جدول ۱۰ مقایسه نتایج واقعی با نتایج حاصل از شبکه عصبی منتخب آورده شده است.

همانطور که مشاهده می‌شود، بهترین عملکرد انواع شبکه‌ها، بجز شبکه perceptron بسیار مطلوب است و تمامی آنها قادرند تا درصد بسیار بالایی میزان مقاومت‌های بتن را پیش‌بینی کنند. با این وجود از آنجا که ما در این پژوهش یک مدل واحد را برای پیش‌بینی هر سه مقاومت ایجاد می‌کیم، در نتیجه می‌توان مدل شبکه عصبی cascadeforward را که در مجموع عملکرد بهتری برای هر سه مقاومت دارد به عنوان مدل

جدول ۱۰. پیش بینی هر سه مقاومت با استفاده از شبکه عصبی cascadeforward (مقادیر نرمアル شده)

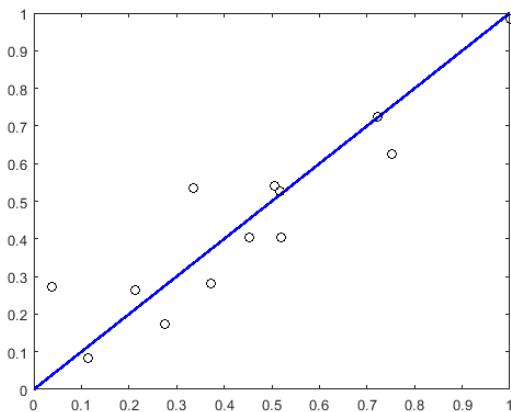
آزمایش	مقاطومت فشاری - واقعی	مقاطومت فشاری - پیش بینی شده	مقاطومت خمثی - واقعی	مقاطومت خمثی - پیش بینی شده	مقاطومت کششی - واقعی	مقاطومت کششی - پیش بینی شده
۱	0.335841	0.533745	0.587583	0.430024	0.484581	0.518442
۲	0.275221	0.174402	0.490022	0.369709	0.396476	0.25589
۳	0.213717	0.265183	0.13082	0.420992	0.22467	0.349681
۴	0.45177	0.40349	0.625277	0.38557	0.427313	0.40985
۵	0.723451	0.72336	0.24612	0.452714	0.577093	0.657601
۶	1	0.983871	0.383592	0.541621	0.955947	0.874785
۷	0.519912	0.40349	0.67184	0.38557	0.46696	0.40985
۸	0.113717	0.08362	0.037694	0.318426	0.154185	0.162099
۹	0.505752	0.541797	0.252772	0.350148	0.348018	0.470019
۱۰	0.516372	0.525694	0.421286	0.5099	0.480176	0.566865
۱۱	0.037611	0.273235	0.447894	0.341116	0.295154	0.301258
۱۲	0.753097	0.624527	0.769401	0.481307	0.735683	0.612233
۱۳	0.371239	0.281286	0.184035	0.26124	0.295154	0.252835
۱۴	0.571681	0.40349	0.625277	0.38557	0.599119	0.40985
۱۵	0.465487	0.40349	0.556541	0.38557	0.563877	0.40985
۱۶	0	-0.17689	0	0.229519	0	-0.05508
۱۷	0.376549	0.40349	0.67184	0.38557	0.54185	0.40985
۱۸	0.94115	0.632579	1	0.401431	1	0.56381
۱۹	0.50531	0.182453	0.423503	0.289833	0.449339	0.207467

حال که به مدل صحیحی دست یافتیم، نتایج مربوط به هر عاملکرد هر سه مقاومت خمثی، کششی و فشاری را با بهره گیری از معماری منتخب در شکل های زیر ارائه می دهیم. از این رو با استفاده از شبکه عصبی

مقاآمت را با ساختار مدل مطلوب (مناسب) ارائه می دهیم. از این رو با استفاده از شبکه عصبی

شکل ۱ محور افقی نشان‌دهنده داده‌های واقعی و محور عمودی

نشان دهنده داده‌های ارائه شده توسط شبکه عصبی منتخب است. هرچه نقاط دایره‌ای توخالی به خط آبی رنگ (خط با شیب ۱)، نزدیکتر باشند، نشان‌دهنده‌ی نزدیکی بیشتر بین دو مقدار یاد شده است. مشاهده می‌شود که در شبکه عصبی منتخب وضعیت مناسبی به لحاظ قرارگیری دایره‌ها نزدیک خط وجود دارد.

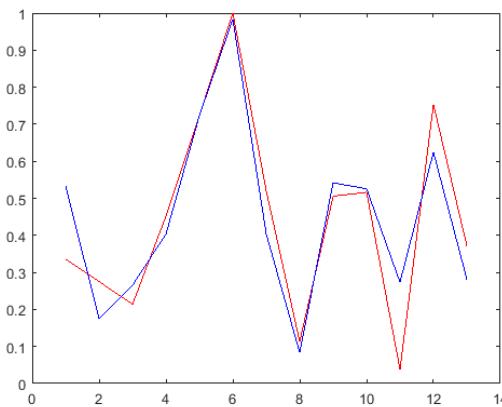


شکل ۱. نمودار رگرسیون جهت پیش‌بینی مقاومت فشاری

شبکه عصبی در پیش‌بینی داده‌ها بهتر بوده است. مشاهده می‌شود که در شبکه عصبی منتخب، در حالت کلی وضعیت مناسبی به لحاظ قرارگیری خطوط نزدیک هم وجود دارد.

مقاومت فشاری
این مدل بر اساس داده‌های ورودی و با توجه به تابع آموزش **trainlm** با ۵ لایه و ۱۰ نمون مورد ارزیابی قرار می‌گیرد. لازم به ذکر است که تقسیم بندی داده‌ها را ۷۰ درصد داده‌های آموزش و ۳۰ درصد داده‌های ارزیابی تشکیل می‌دهد. در شکل‌های زیر انطباق بین مقادیر پیش‌بینی شده و مقادیر متناظر آن برای مقاومت فشاری نمونه، بررسی شده است. در

در شکل ۲ خط قرمزرنگ نشان‌دهنده داده‌های واقعی و خط آبی نشان‌دهنده داده‌های ارائه شده توسط شبکه عصبی منتخب است. هرچه این خطوط انطباق بیشتری داشته باشند، عملکرد



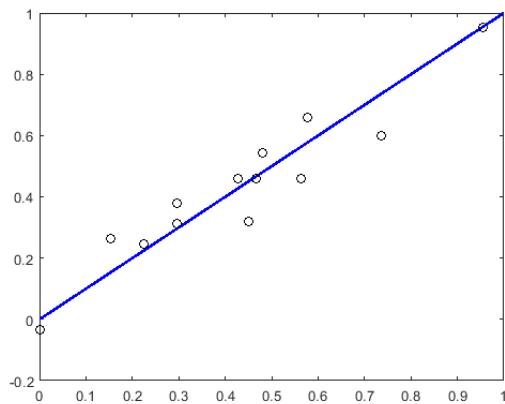
شکل ۲. نمودار انطباق نتایج واقعی و نتایج پیش‌بینی شده توسط شبکه عصبی cascadeforward در پیش‌بینی مقاومت فشاری

داده‌های آموزش و ۳۰ درصد داده‌های ارزیابی تشکیل می‌دهد. در شکل‌های زیر انطباق بین مقادیر پیش‌بینی شده و مقادیر متناظر آن برای مقاومت خمسی نمونه، بررسی شده است. در شکل ۳ محور افقی نشان‌دهنده داده‌های واقعی و

مقاومت خمسی
این مدل نیز بر اساس داده‌های ورودی و با توجه به تابع آموزش **trainlm** با ۵ لایه و ۱۰ نمون مورد ارزیابی قرار می‌گیرد. لازم به ذکر است که تقسیم بندی داده‌ها را ۷۰ درصد

بیشتر بین دو مقدار یاد شده است. مشاهده می‌شود که در شبکه عصبی منتخب وضعیت مناسبی به لحاظ قرارگیری دایره‌ها نزدیک خط وجود دارد.

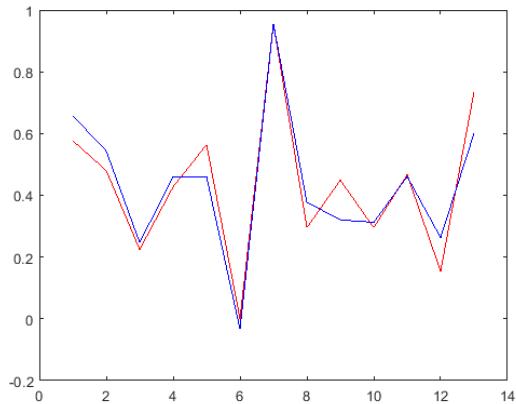
محور عمودی نشان دهنده داده‌های ارائه شده توسط شبکه عصبی منتخب است. هرچه نقاط دایره‌ای توخالی به خط آبی رنگ (خط با شیب ۱)، نزدیکتر باشند، نشان دهنده‌ی نزدیکی



شکل ۳. نمودار رگرسیون جهت پیش‌بینی مقاومت خمی

در پیش‌بینی داده‌ها بهتر بوده است. مشاهده می‌شود که در شبکه عصبی منتخب، در حالت کلی وضعیت مناسبی به لحاظ قرارگیری خطوط نزدیک هم وجود دارد.

در شکل ۴ خط قرمز رنگ نشان دهنده داده‌های واقعی و خط آبی نشان دهنده داده‌های ارائه شده توسط شبکه عصبی منتخب است. هرچه این خطوط انبساط بیشتری داشته باشند، عملکرد شبکه عصبی

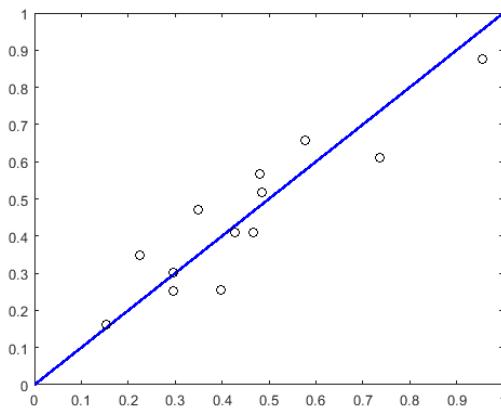


شکل ۴. نمودار انبساط نتایج واقعی و نتایج پیش‌بینی شده توسط شبکه عصبی cascadeforward در پیش‌بینی مقاومت خمی

مقاومت کششی

محور عمودی نشان دهنده داده‌های ارائه شده توسط شبکه عصبی منتخب است. هرچه نقاط دایره‌ای توخالی به خط آبی رنگ (خط با شیب ۱)، نزدیکتر باشند، نشان دهنده‌ی نزدیکی بیشتر بین دو مقدار یاد شده است. مشاهده می‌شود که در شبکه عصبی منتخب وضعیت مناسبی به لحاظ قرارگیری دایره‌ها نزدیک خط وجود دارد.

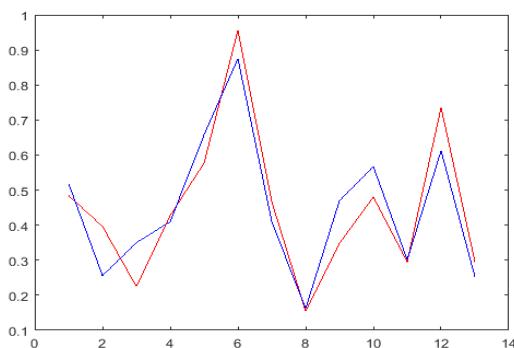
این مدل نیز بر اساس داده‌های ورودی و با توجه بهتابع آموزش trainlm با ۵ لایه و ۱۰ نرون مورد ارزیابی قرار می‌گیرد. لازم به ذکر است که تقسیم بندی داده‌ها را ۷۰ درصد داده‌های آموزش و ۳۰ درصد داده‌های ارزیابی تشکیل می‌دهد. در شکل‌های ۵ و ۶ انبساط بین مقادیر پیش‌بینی شده و مقادیر متناظر آن برای مقاومت کششی نمونه، بررسی شده است. در شکل ۵ محور افقی نشان دهنده داده‌های واقعی و



شکل ۵. نمودار رگرسیون جهت پیش‌بینی مقاومت کششی

شبکه عصبی در پیش‌بینی داده‌ها بهتر بوده است. مشاهده می‌شود که در شبکه عصبی منتخب، در حالت کلی وضعیت مناسبی به لحاظ قرارگیری خطوط نزدیک هم وجود دارد.

در شکل ۶ خط قرمزرنگ نشان‌دهنده داده‌های واقعی و خط آبی نشان‌دهنده داده‌های ارائه شده توسط شبکه عصبی منتخب است. هرچه این خطوط انتطباق بیشتری داشته باشند، عملکرد



شکل ۶. نمودار انتطباق نتایج واقعی و نتایج پیش‌بینی شده توسط شبکه عصبی cascadeforward در پیش‌بینی مقاومت کششی

۵- نتیجه‌گیری

است. در جداول، ردیف‌های سبزرنگ نشان‌دهنده بهترین ساختاری است که توانسته به خوبی مقاومت‌های بتن را پیش‌بینی کند. همچنین بهترین عملکرد (کمترین خطأ و بالاترین ضریب همبستگی) در پیش‌بینی همزمان انواع مقاومت‌ها با ارزیابی معماری‌های مختلف شبکه عصبی CFNN با تابع آموزشی LM که متشکل از ۵ لایه و ۱۰ نرون باشد، بهترین عملکرد را در تعیین دقیق نتایج دارد. نتایج مقاومت‌های فشاری و کششی، عموماً هم راستا بوده ولی مقاومت خمشی معمولاً نتایج متفاوتی را از خود نشان داده است.

در این پژوهش به منظور بررسی و تحلیل، از انواع شبکه‌های عصبی ممکن جهت پیش‌بینی انواع مقاومت فشاری خمشی و کششی استفاده شد. داده‌های بدست آمده را در اکسل بصورت ستونی که ستون‌های ورودی نمایانگر درصدهای مختلف خاکستر بادی، خرد لاستیک بازیافنی و نانوسیلیس بوده و ستون‌های خروجی معرف انواع مقاومت‌های یادشده هستند، ثبت می‌کنیم. در هر قسمت ساختار شبکه عصبی مورد استفاده به همراه جدول اطلاعات ورودی و نتایج خروجی آن شبکه آورده شده است. در هر نوع شبکه عصبی از تعداد لایه‌ها و تعداد نرون‌های مختلفی برای مدل‌سازی استفاده شده

۶- مراجع

- Choi, W. C., & Yun, H. D., (2012), "Compressive behavior of reinforced concrete columns with recycled aggregate under uniaxial loading", *Engineering structures*, 41, pp.285-293.
- Gelardi, G., & Flatt, R. J., (2016), "Working mechanisms of water reducers and super plasticizers", In *Science and technology of concrete admixtures*, Woodhead Publishing, pp. 257-278.
- Hassan, A. M. T., Mahmud, G. H., Mohammed, A. S., & Jones, S. W., (2021), "The influence of normal curing temperature on the compressive strength development and flexural tensile behavior of UHPFRC with Vipulanandan model quantification", In *Structures*, Vol. 30, Elsevier, pp. 949-959.
- Kabantsev, O. V., Pesin, K. O., & Karlin, A. V., (2017), "analysis of stress-strain state of reinforced concrete plate around support zones" *International Journal for Computational Civil and Structural Engineering*, 13(1), pp.55-62.
- Kondratiev, A. V., Gaidachuk, V. E., & Kharchenko, M. E., (2019), "Relationships between the ultimate strengths of polymer composites in static bending, compression, and tension", *Mechanics of Composite Materials*, 55(2), pp.259-266.
- Lechner, P., & Konecny, P., (2015), "Analysis of Durability of High Performance and Ordinary Concrete Mixtures with Respect to Chlorides", *Applied Mechanics and Materials*, pp.769, 281.
- Sadinejad, I., Madandoust, R., & Ranjbar, M. M., (2018), "The mechanical and durability properties of concrete containing hybrid synthetic fibers", *Construction and Building Materials*, 178, pp.72-82.
- Silvestro, L., & Gleize, P. J. P., (2020), "Effect of carbon nanotubes on compressive, flexural and tensile strengths of Portland cement-based materials: A systematic literature review", *Construction and Building Materials*, pp.264-265.
- Sümer, Y., & Aktaş, M., (2015), "Defining parameters for concrete damage plasticity model", *Challenge Journal of Structural Mechanics*, 1(3), pp.149-155.
- اسکندری، ح. و ضیائی‌نیا، ع.، (۱۳۹۳)، "بتن توانمند، بهینه‌سازی پویا و تأثیرات خودگی"، دانشگاه تربیت معلم سبزوار، دانشکده مهندسی.
- شکری، ف. حقیقی، ف.، امیری، م. و اشرفیان، ع.، (۱۳۹۸)، "بررسی مدل سازی مقاومت فشاری بتن سیک فوم با استفاده از روش‌های شبکه عصبی مصنوعی و ماشین‌های بردار پشتیبانی"، چهارمین کنفرانس بین‌المللی پژوهش‌های نوین در عمران، معماری، مدیریت شهری و محیط زیست.
- غلامزاده، ع. و برنجیان، ج.، (۱۳۹۷)، "پیش‌بینی مقاومت فشاری بتن خودتراکم توسط شبکه عصبی مصنوعی المان همراه با دو مجموعه متفاوت از پارامترهای ورودی"، نشریه علمی - پژوهشی مهندسی سازه و ساخت، دوره ۵، شماره ۴، ص. ۱۶۲-۱۷۸.
- کلینیک بتن ایران، (۱۳۹۷)، "بررسی تاثیر میکروسیلیس بر مقاومت فشاری و کششی بتن سیک الیافی".
- مجتبی‌ی، س.ع. مسیبی، س.ح.ر.، بنی هاشمی، م.ر.، (۱۳۹۷)، "بررسی ارزیابی مشخصات مکانیکی بتن الیافی هیبریدی تقویت شده با الیاف فولادی و شیشه"، دومین کنفرانس ملی مهندسی عمران، معماری و شهرسازی.
- Badogiannis, E. G., Christidis, K. I., & Tzanetatos, G. E., (2019), "Evaluation of the mechanical behavior of pumice lightweight concrete reinforced with steel and polypropylene fibers", *Construction and Building Materials*, 196, pp.443-456.
- Chen, C. T., Chang, J. J., & Yeih, W. C., (2014), "The effects of specimen parameters on the resistivity of concrete", *Construction and Building Materials*, 71, pp.35-43.
- Chen, Y. Y., Chen, C. T., & Wang, H. Y., (2019), "Study on the influence of the average lubricant quantity of aggregates on the concrete engineering properties", *Construction and Building Materials*, 217, pp.321-330.

Search for the Best Architectural Models in Neural Network for Modeling Normalized Mechanical Parameters of Concrete

Seyed Amir Hosein Hashemi, Department of Civil Engineering, Qazvin Branch, Islamic Azad University, Qazvin, Iran.

Alireza Ameli, Department of Civil Engineering, Malard Branch, Islamic Azad University, Malard, Tehran, Iran.

Seyed Mohammad Javad Shafiei Shalke, Department of Civil Engineering, Qazvin Branch, Islamic Azad University, Qazvin, Iran.

Elahe Sadat Hashemi, Department of Civil Engineering and Architecture, Faculty of Engineering, Raja University, Qazvin, Iran.

E-mail: Amelii@gmail.com

Received: July 2021-Accepted: August 2021

ABSTRACT

In this study, in order to evaluate the performance of neural network, two models of MLP neural network and RBF neural network were used to predict flexural, tensile and compressive strengths. The data used are taken from the results of models fitted to the results of tests performed on roller concrete samples containing different amounts of recycled crumb rubber, fly ash and nanosilica based on compressive, flexural and tensile strength tests. Different types of artificial neural networks have been used to predict the types of concrete strength. In each section, the structure of the neural network used is given along with the table of input information and output results of that network. In each type of neural network, the number of layers and the number of different neurons have been used for modeling. In the tables, the green rows represent the best structure that has been able to predict the strength of concrete well. Also, the best result (lowest error and highest correlation coefficient) has been selected by considering the network performance in simultaneous prediction of resistance types. The results of compressive and tensile strengths are in the same direction and generally in the same direction, but flexural strength usually shows different results.

Keywords: Model, Architecture, Neural Network, Mechanical Parameters, Concrete