

پیش‌بینی مقاومت فشاری بتن خودتراکم توسط شبکه عصبی مصنوعی المان همراه با دو مجموعه متفاوت از پارامترهای ورودی

عاطفه غلامزاده چیتگر^۱، جواد برنجیان^{۲*}

۱- دانشجوی کارشناسی ارشد مهندسی و مدیریت ساخت، موسسه آموزش عالی طبری بابل، بابل، ایران

۲- استادیار و رئیس موسسه آموزش عالی طبری بابل، بابل، ایران

چکیده

در سال‌های اخیر، شبکه‌های عصبی مصنوعی از یک رویکرد نظری به یک فن آوری باقابلیت استفاده گسترده همراه با برنامه‌های کاربردی موفق برای مسائل گوناگون تبدیل شده‌اند. در حقیقت، شبکه‌های عصبی مصنوعی یک ابزار محاسباتی قدرتمندی هستند که راه‌حل‌های مناسبی را برای حل مسائلی ارائه می‌دهند که با استفاده از روش‌های مرسوم و سنتی دشوار هستند. امروزه این شبکه‌ها که از سیستم عصبی زیستی الهام گرفته شده‌اند، به‌طور گسترده برای حل یک سطح وسیعی از مسائل پیچیده در مهندسی عمران نیز مورد استفاده قرار می‌گیرند. هدف از مطالعه حاضر، ارزیابی عملکرد شبکه‌های عصبی مصنوعی المان با در نظر گرفتن پارامترهای ورودی مختلف در پیش‌بینی مقاومت فشاری بتن خودتراکم می‌باشد. ازین‌رو، یک بار ۸ پارامتر تأثیرگذار و بار دیگر جهت نزدیک شدن هرچه بیشتر شرایط پیش‌بینی به شرایط آزمایشگاهی، ۱۴۰ پارامتر به‌عنوان ورودی وارد شبکه‌های عصبی المان شدند. نتایج نشان داد، شبکه‌های عصبی المان به‌عنوان ابزار قابل‌اعتمادی با صرفه‌جویی در زمان و هزینه دارای قدرت بالایی در پیش‌بینی مشخصه‌های موردنظر می‌باشند. به‌علاوه، در پیش‌بینی هر دو مقاومت فشاری ۷ و ۲۸ روزه، شبکه‌های ساخته‌شده با تعداد ۱۴۰ پارامتر به ترتیب به میزان ۷۴/۵۴ و ۷۰/۴۴ درصد بهبود در خطای تست نسبت به شبکه‌ها با ۸ پارامتر دارند که این اثرگذاری مستقیم پارامترهای مؤثر در نظر گرفته‌شده به‌عنوان ورودی را بر میزان خطای شبکه در پیش‌بینی خواص مدنظر نشان می‌دهد.

کلمات کلیدی: بتن خودتراکم، پیش‌بینی، مقاومت فشاری، شبکه‌ی عصبی، ورودی.

شناسه دیجیتال:		سابقه مقاله:				
10.22065/jsce.2017.83926.1161	چاپ	انتشار آنلاین	پذیرش	بازنگری	دریافت	
doi: 10.22065/jsce.2017.83926.1161	۱۳۹۷/۱۰/۳۰	۱۳۹۶/۰۸/۱۹	۱۳۹۶/۰۸/۱۹	۱۳۹۶/۰۶/۱۲	۱۳۹۶/۰۲/۱۲	
			جواد برنجیان		*نویسنده مسئول:	
			berenjian@nit.ac.ir		پست الکترونیکی:	

Predicting the compressive strength of self-compacting concrete using Elman artificial neural network with two different sets of input parameters

Atefeh GholamzadehChitgar¹, Javad Berenjian^{2*}

1- M.Sc. Student of Construction Engineering and Management, Department of Civil Engineering, Tabari Institute of Higher Education, Babol, Iran.

2- Assistant Professor and Head of the Tabari Institute of Higher Education, Babol, Iran

ABSTRACT

In recent years, artificial neural networks converted from a theoretical approach to the widely-used technology with successful applications to different problems. In fact, artificial neural networks are a powerful tool that give appropriate solutions to problems which are difficult to solve through conventional techniques. Nowadays, these networks, which are inspired by the biological nervous system, are also extensively used to solve a wide range of complex problems in civil engineering. The purpose of the current study is a performance evaluation of the Elman artificial neural networks with various input parameters in order to predict the compressive strength of Self Compacting Concrete (SCC). Therefore, once, 8 effective parameters and next, in order to simulate a real experimental conditions, 140 parameters were entered as inputs in the Elman neural networks. According to the results, Elman neural networks, as a reliable tool, have high strength for predicting the desired properties along with saving time and cost. In addition, in both 7 and 28-day compressive strength, the constructed networks with 140 input parameters compared to ones with 8, have 74.54 and 70.44 percent improvement respectively regarding their test errors. The effective inputs straightly affect the networks errors in the prediction of the desired properties.

All rights reserved to Iranian Society of Structural Engineering.

ARTICLE INFO

Received: 02/05/2017

Revised: 03/09/2017

Accepted: 10/09/2017

Keywords:

Self Compacting Concrete Prediction, Compressive Strength, Neural Network Input,

doi: 10.22065/jsce.2017.83926.1161

*Corresponding author: Javad Berenjian

Email address: berenjian@nit.ac.ir

۱- مقدمه

ساخت بتنی بدون نیاز به لرزاندن، هدف مهمی برای متخصصین بتن بوده است که بتوانند با استفاده از مواد افزودنی و تغییر در نسبت اختلاط اجزا، به این هدف دست یابند و نقص‌های بتن در اثر عملیات اجرایی تراکم را برطرف سازند. ابداع بتن خودتراکم^۱ ثمره‌ی این تلاش‌ها بوده است. مطابق با تعریف بارتوس^۲، بتن خودتراکم بتنی است که تحت وزن خود جاری می‌شود و بدون نیاز به هر نوع لرزاندن و حتی با وجود میلگرد گذاری‌های متراکم، قادر است به‌طور کامل قالب‌ها را پر کند و همگنی خود را حفظ نماید [۱]. این بتن در ابتدا به‌منظور دست یافتن به بتن سازه‌ای بادوام، بدون نیاز به عملیات ویبره و همچنین استفاده از کارگران ماهر در ژاپن گسترش یافت [۲]. از مزایای مهم این بتن می‌توان به حذف عملیات لرزاندن، سهولت بتن‌ریزی، افزایش سرعت اجرا، اطمینان از تراکم مناسب به‌ویژه در مقاطع تنگ همراه با میلگرد گذاری فشرده، مقاومت مطلوب در برابر جداشدگی سنگدانه، قابلیت ایجاد سطوح تمام‌شده صاف و زیبا و درنهایت تهیه طرح‌های متنوع معماری در نما و نیز کاهش آلودگی صوتی در محیط کار و محیط‌های شهری اشاره کرد [۳]. از این‌رو به دلیل کاربرد زیاد بتن خودتراکم به فکر مدل‌سازی آن با استفاده از شبکه‌های عصبی مصنوعی افتادند. دلیل انتخاب مدل شبکه عصبی مصنوعی این است که برخلاف روش‌های کلاسیکی که در تئوری‌های آماری موجود است، در این شبکه‌ها، به هیچ مدل یا تابع مشخصی به همراه فرضیات محدودکننده برای خطی کردن مسأله نیاز نمی‌باشد. این شبکه‌ها به‌عنوان ابزار قدرتمند و منحصر بفردی برای تحلیل‌های غیرمتعارف و یا غیرممکن محسوب می‌شوند. یکی از این موارد، تشخیص سیستم‌های غیرخطی است [۴]. در زمینه‌ی تکنولوژی بتن نیز می‌توان بیان نمود که تاکنون محققین زیادی با طراحی مدل‌های مختلفی از شبکه‌های عصبی مصنوعی به پیش‌بینی خواص مختلف بتن‌های گوناگون پرداختند. در سال ۲۰۰۶ اوزتاس^۳ [۵] و همکارانش، با استفاده از شبکه عصبی مصنوعی به پیش‌بینی مقاومت فشاری و اسلامپ بتن مقاومت بالا پرداختند. در سال ۲۰۰۷ دمیر^۴ [۶] از شبکه‌ی عصبی برای پیش‌بینی مدول الاستیسیته بتن نرمال و مقاومت بالا استفاده کرد. در سال ۲۰۱۲ باربوتا^۵ [۷] و همکارانش با به‌کارگیری شبکه‌های عصبی مصنوعی مقاومت فشاری و مقاومت خمشی بتن پلیمری حاوی خاکستر بادی را پیش‌بینی کردند. در سال ۲۰۱۶ سونبی^۶ [۸] و همکارانش به‌وسیله‌ی تکنیک شبکه عصبی خواص تازه بتن خودتراکم را مدل‌سازی کردند. در سال ۲۰۰۹ راقوپراساد^۷ [۹] و همکارانش مقاومت فشاری ۲۸ روزه بتن خودتراکم و بتن مقاومت بالا حاوی مقدار زیادی خاکستر بادی را با استفاده از شبکه عصبی مصنوعی پیش‌خور با در نظر گرفتن ۱۰ پارامتر ورودی به ترتیب با دقت ۰/۹۲ و ۰/۹۱ پیش‌بینی کردند. در سال ۲۰۱۴ مالاگولی^۸ [۱۰] و همکارانش با استفاده از ۱۶۹ طرح اختلاط و ۱۱ پارامتر ورودی شبکه عصبی پیش‌خوری را طراحی کردند که مقاومت فشاری ۲۸ روزه بتن خودتراکم حاوی افزودنی‌های شیمیایی و معدنی را با دقت ۰/۹۴ پیش‌بینی کرد.

در تحقیق پیش‌رو اهداف زیر مدنظر می‌باشند:

۱- ارزیابی عملکرد شبکه عصبی دینامیکی المان در پیش‌بینی مقاومت فشاری بتن خودتراکم آن‌هم در شرایطی که گستردگی کار به‌واسطه‌ی وجود حجم وسیعی از پارمترها و طرح اختلاط‌های به کار گرفته‌شده، زیاد می‌باشد. این تحقیق پتانسیل بالا و قابلیت اعتماد بودن این شبکه را در امر پیش‌بینی به‌وضوح نشان می‌دهد.

۲- به تصویر کشیدن میزان تأثیر بهینه کردن شبکه (انجام مراحل صورت گرفته در تحقیق) برافزایش دقت حاصله در پیش‌بینی مشخصه‌ی مدنظر.

1 Self-Compacting Concrete (SCC)

2 Bartos

3 Oztas

4 Demir

5 Barbuta

6 Sonebi

7 RaghuPrasad

8 Malagavelli

۳- ساخت الگویی تقریباً جامع جهت پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم آن‌هم در شرایطی که مدل الگو دربردارنده‌ی طرح اختلاط‌های مختلفی از انواع بتن خودتراکم (نه صرفاً یک نوع بتن خودتراکم) می‌باشد. بیشترین تعداد پارامترهایی که در این تحقیق مقذور بود جمع‌آوری شد، تا تحقیق در شرایط جامع‌تری صورت گیرد.

۴- مقایسه عملکرد شبکه‌های ساخته‌شده در شرایطی که پارامترهای مؤثر در نظر گرفته‌شده به‌عنوان ورودی در آنها متفاوت باشند. از این‌رو، یک‌بار ۸ پارامتر و سپس به‌منظور شبیه‌سازی با شرایط آزمایشگاهی واقعی، ۱۴۰ پارامتر به‌عنوان ورودی وارد شبکه‌های المان می‌شوند. آنگاه بین نتایج به‌دست‌آمده از شبکه‌های بهینه با ۸ و ۱۴۰ ورودی مقایسه‌ای صورت خواهد گرفت که منجر به تعیین بهترین شبکه (شبکه منتخب) می‌شود. سرانجام، نتایج به دست آمده از شبکه‌های منتخب با نتایج آزمایشگاهی قیاس خواهند شد.

۲- مقاومت فشاری بتن

مقاومت فشاری یکی از مهم‌ترین خواص سخت شده‌ی بتن محسوب می‌شود. به‌عنوان یک ماده ساختمانی، بتن برای مقاومت در برابر تنش‌های فشاری مورد استفاده قرار می‌گیرد. هنگامی که در مکان‌هایی مقاومت کششی یا مقاومت برشی از اهمیت عمده برخوردار است، مقاومت فشاری جهت تخمین خواص موردنیاز استفاده می‌شود [۱۱]. به‌عبارت‌دیگر، بسیاری از خواص مختلف بتن از روی مقاومت فشاری بتن تعیین می‌شوند و به این مشخصه ارتباط دارند از جمله وزن مخصوص، نفوذپذیری، تا حدی دوام، مقاومت در برابر فرسایش، مقاومت در برابر سولفات‌ها، مقاومت کششی و برخی دیگر از خواص بتن [۱۲]. همانند بتن‌های دیگر، دست یافتن به مقاومت فشاری بتن خودتراکم نیز از طریق آزمایش‌های هزینه‌بر و وقت‌گیر امکان‌پذیر می‌باشد. به همین دلیل در این تحقیق جهت دست یافتن به این خاصیت مهم بتن خودتراکم، از تکنیک شبکه عصبی مصنوعی باهدف کاهش در انجام کارهای آزمایشگاهی بهره گرفته می‌شود.

۳- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی، پارادایم پردازش اطلاعات هستند که از سیستم بیولوژیکی عصبی، مانند مغز انسان الهام می‌گیرند و اطلاعات را پردازش می‌کنند. عنصر کلیدی این پارادایم، ساختار جدیدی از سیستم پردازش اطلاعات است [۱۳]. شبکه‌های عصبی مصنوعی مانند انسان‌ها با مثال می‌آموزند [۱۴]. اولین عصب مصنوعی در سال ۱۹۴۳ توسط وارن مک کلوج^۹ فیزیولوژیست عصبی و والتر پیترز^{۱۰} منطق‌شناس، معرفی شد، اما فناوری موجود اجازه کار بیشتر به آنها را نداد، تا اینکه شبکه‌های عصبی، در دهه‌ی ۵۰ به‌منظور ایجاد یک شبکه برای محاسبه‌ی وظایف منطقی و شناخت الگوها به کار گرفته شدند [۱۵ و ۱۶]. به‌طور کلی تاریخچه‌ی شبکه‌های عصبی مصنوعی به ۶ دوره تقسیم می‌شود [۱۴]:

- ۱- تلاش‌های اولیه: بعضی شبیه‌سازی‌های اولیه با استفاده از منطق رسمی انجام گرفت.
- ۲- فناوری در حال ظهور و پیشرفت: علاوه بر علم عصب، روانشناسان و مهندسان نیز در ایجاد و پیشرفت شبیه‌سازی شبکه‌های عصبی مصنوعی مشارکت داشتند.
- ۳- دوره نامیدی و بی‌احترامی: در سال ۱۹۶۹ مینسکی^{۱۱} و پیپرت^{۱۲} به محدودیت‌های تعمیم‌یافته پرسپترون تک لایه^{۱۳} به نظام‌های چندلایه اشاره کردند. نتیجه‌ی کار آنها، حذف وجوه و بودجه برای پژوهش در شبیه‌سازی‌های شبکه عصبی شد.
- ۴- ابداع و نوآوری: محققین کار خود را با بودجه حداقل برای ایجاد شکل خاص عصب بر اساس روش‌های محاسباتی برای مسائلی از قبیل تشخیص الگو ادامه دادند. از جمله گروسبرگ^{۱۴} شبکه‌های نظریه استدلال تطبیقی را بر اساس مدل‌های مشهور بیولوژیکی و کولف^{۱۵} در سال ۱۹۷۲، اساسی برای یادگیری در عصب‌های مصنوعی را ایجاد کردند.

⁹ Waren McClough

¹⁰ Walter Pitts

¹¹ Minsky

¹² Papert

¹³ A Single Layer Perceptron


¹⁴ Grossberg

¹⁵ Henry Kolpf

۵- ظهور مجدد: پیشرفت در طول اواخر دهه‌ی ۷۰ و اوایل دهه‌ی ۸۰ برای ظهور مجدد علائق در رشته‌ی شبکه عصبی از طریق نوشتن کتاب‌ها و برگزاری کنفرانس‌ها آغاز گردید.

۶- امروزه: امروزه نظریه‌ها و الگوریتم‌های یادگیری برای مدل‌های شبکه عصبی مصنوعی چندلایه توسعه یافته است. تراشه‌های مبتنی بر عصب، در حال ظهور بوده و به‌طور روشن، یک دوره‌ای از انتقال برای فناوری شبکه‌های عصبی مصنوعی است.


این شبکه‌ها از عناصر عملیاتی ساده‌ای که از سیستم‌های عصبی زیستی الهام گرفته شده‌اند ساخته می‌شوند که به‌صورت موازی در کنار هم عمل می‌کنند. در طبیعت، عملکرد شبکه‌های عصبی به‌واسطه‌ی نحوه اتصال بین اجزا تعیین می‌شود. بنابراین می‌توان یک ساختار مصنوعی به تبعیت از شبکه‌های طبیعی ساخت و با تنظیم مقادیر هر اتصال، تحت عنوان وزن اتصال، نحوه ارتباط بین اجزای آن را تعیین نمود. اصلی‌ترین قسمت یک شبکه عصبی، نرون‌ها و خطوط ارتباطی بین آنها می‌باشد. نرون‌ها در قالب لایه‌هایی قرار می‌گیرند که هر یک از لایه‌ها دارای تعدادی نرون با وظایف خاص خود می‌باشد و در نهایت، نوعی ارتباط بین ورودی‌ها و خروجی‌های موردنظر ایجاد می‌کند. ساده‌ترین نوع شبکه چندلایه از دولایه ورودی و خروجی تشکیل می‌شود که با اضافه کردن یک یا چندلایه مخفی به آنها ساختار شبکه بزرگ‌تر می‌شود. در شکل ۱ شماتیکی از ساختار شبکه عصبی مصنوعی با یک لایه ورودی، خروجی و پنهان آورده شده است. امروزه در رشته‌های مهندسی، استفاده از شبکه عصبی مصنوعی به دلیل به عدم فرمول‌بندی و پویا بودن، ایده خوبی برای تخمین و مدل‌سازی به شمار می‌رود. نقش مدل شبکه عصبی در حل مسائلی که پارامترهای بسیاری در فرآیند و نتایج آنها ممکن است تأثیرگذار باشند و نتایج دچار ابهام شده و به‌خوبی درک نگردند و همچنین در حالتی که داده‌های تجربی و تاریخی در دسترس هستند، بسیار حائز اهمیت می‌باشد [۱۷].



شکل ۱: نمونه‌ای از ساختار شبکه عصبی مصنوعی.

۴- شبکه عصبی بازگشتی المان^{۱۶}

شبکه عصبی مصنوعی المان یک شبکه بازگشتی می‌باشد که در ابتدا در سال ۱۹۹۰ توسط المان پیشنهاد شد [۱۸]. این شبکه نه تنها قادر به انتقال داده‌ها روبه‌جلو می‌باشد بلکه می‌تواند اطلاعات را به عقب هم انتقال دهد. این شبکه دارای حلقه بازخوردی از لایه پنهان به لایه ورودی می‌باشد. این حلقه بازخوردی به شبکه اجازه می‌دهد تا الگوهای زمانی گوناگونی را شکل دهد. شبکه عصبی المان معمولاً به‌عنوان نوع خاصی از شبکه پیش‌خور معرفی می‌شود که دارای حافظه اضافی و حلقه بازگشتی است [۱۹]. این شبکه‌ها اغلب برای شناسایی یا ایجاد خروجی‌های زمانی در سیستم‌های غیرخطی به‌کاربرده می‌شوند [۲۰]. در شکل ۲ شماتیکی از شبکه المان استفاده‌شده در این پژوهش به تصویر کشیده شده است.



شکل ۲: شماتیکی از شبکه المان (Elman).

۵- سری اول از پژوهش

۵-۱- آماده سازی داده ها

برای انجام پژوهش پیش رو، ۲۷۵ طرح اختلاط (زوج داده) برای مقاومت فشاری ۷ روزه و ۵۴۹ طرح اختلاط دیگر برای پیش بینی مقاومت ۲۸ روزه بتن خودتراکم از منابع معتبر خارجی و داخلی جمع آوری گردید [۲۱ تا ۳۲]. نکته‌ی قابل توجه این است که در ابتدا ۱۴۰ پارامتر تأثیرگذار بر مشخصات مقاومتی بتن خودتراکم به عنوان ورودی برای شبکه‌ها در نظر گرفته شدند.

دلیل این انتخاب این است که نویسنده سعی داشته است تا با در نظر گرفتن بخش عظیمی از عواملی که بر مقاومت فشاری بتن‌های خودتراکم دخیل هستند از یک سو هم مدل جامعی را تهیه کند که دربرگیرنده گونه‌های مختلف بتن خودتراکم باشد (نه صرفاً تنها یک نوع بتن خودتراکم را ارزیابی کند)، و هم از سوی دیگر شرایط پیش‌بینی را با در نظر گرفتن هر چه بیشتر جزئیات به شرایط آزمایشگاهی بسیار نزدیک کند تا از این طریق میزان دقت شبکه‌های ساخته شده را در پیش‌بینی مشخصه مدنظر بسنجد و در نهایت نتایج حاصله را باحالتی که شبکه تنها دارای تعداد محدودی از پارامترهای مؤثر باشد مقایسه کند. این پارامترها عبارتند از:

- مشخصات شن مصرفی از قبیل مقدار، حداکثر اندازه، وزن مخصوص، درصد جذب آب، دانه‌بندی، شکل مصرفی که شامل کاملاً گرد گوشه، گرد گوشه، نسبتاً گرد گوشه، تیز گوشه، نسبتاً تیز گوشه
- مشخصات ماسه مصرفی شامل پارامترهایی از قبیل مقدار، وزن مخصوص، درصد جذب آب، دانه‌بندی
- سبک دانه شامل دانه‌بندی، وزن مخصوص، مقدار، درصد جذب آب، حداکثر اندازه
- مصالح بازیافتی شامل مقدار، آنالیز شیمیایی مربوط، وزن مخصوص
- شرایط عمل‌آوری خشک و تر
- مشخصات سیمان مصرفی یعنی میزان سیمان، وزن مخصوص و آنالیز شیمیایی سیمان به کاررفته
- فوق روان کننده دربرگیرنده مقدار، PH، میزان ذرات جامد، وزن مخصوص
- پوزولان‌ها (خاکستر بادی، زئولیت طبیعی، متاکائولن، میکروسیلیس) شامل مقدار، وزن مخصوص و آنالیز شیمیایی مربوط به هر پوزولان
- مشخصات پودر سنگ‌آهک شامل مقدار، وزن مخصوص، آنالیز شیمیایی مربوطه
- مشخصات الیاف مصرفی شامل نوع، طول، قطر، مقاومت کششی، وزن مخصوص و شکل مربوطه
- نانو سیلیس شامل مقدار، وزن مخصوص و میزان مواد جامد
- میزان آب مصرفی

- مقدار عامل اصلاح کننده لزجت^{۱۷} و وزن مخصوص آن
- مقدار عامل کاهنده شدید آب^{۱۸} و وزن مخصوص آن
- دمای بهره‌برداری

لازم به ذکر است به منظور شناساندن اشکال مختلف شن، الیاف و همچنین شرایط عمل‌آوری مختلف به شبکه عصبی، اعدادی ثابت به صورت قراردادی مطابق با جدول ۱ برای هر شکل شن، الیاف و شرایط عمل‌آوری لحاظ گردید. همچنین توجه شود اگر متغیری از سری داده‌ها در مقاله‌ای دارای اطلاعات کامل نبود، از اطلاعات مقاله‌ی مشابه‌ای که دارای همان پارامتر بود استفاده شد. به عنوان مثال اگر وزن مخصوص سیمان مصرفی در مقاله‌ای ذکر نشده بود، از مقاله دیگری که دارای همان سیمان بود استفاده گردید و اطلاعات مورد نیاز تکمیل شد. در مورد نحوه‌ی شناسایی آنالیز شیمیایی مصالح نام‌برده به مدل نیز باید گفته شود که آنالیز شیمیایی ماده مربوطه در نرم‌افزار اکسل وارد می‌شود به طوری که هر عنصر در یک ستون از اکسل جای می‌گیرد و به عنوان ورودی به شبکه معرفی می‌شود. همین روند جهت شناسایی دانه‌بندی هم به کار گرفته شد با این تفاوت که به جای عنصر، شماره الک مربوطه در هر ستون وارد شد. به عنوان نمونه، در شکل ۳ نحوه شناسایی مشخصات سیمان به مدل نمایش داده شده است.

خروجی‌های مدنظر نیز مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم هستند که برحسب مگا پاسکال^{۱۹} می‌باشند. برای پیش‌بینی هر مقاومت، ۸۵ درصد از زوج داده‌ها برای آموزش شبکه و ۱۵ درصد دیگر برای آزمایش شبکه به کار گرفته شد. لازم به ذکر است که برای تعیین زوج داده‌های آموزشی و آزمایشی، در پنج سری داده‌ها به صورت تصادفی انتخاب شدند و میانگین اختلاف میانگین‌ها و میانگین اختلاف انحراف معیارهای هر سری حساب گردید و نهایتاً سری که کمترین اختلاف از هر دو نوع پارامترهای آماری ذکر شده را دارا بود به عنوان سری منتخب (نامزد)، وارد شبکه شد.

جدول ۱: شناساندن اشکال مختلف شن، الیاف و شرایط عمل‌آوری مختلف به شبکه‌ها

شرایط عمل‌آوری	الیاف	شن
شرایط خشک = ۰	الیاف با انتهای صاف = ۰/۵	کاملأ گرد گوشه = ۰
شرایط تر = ۱	الیاف با انتهای قلبی = ۱	گرد گوشه = ۰/۲۵
شرایط پوشیده شده = ۲	-	نسبتاً گرد گوشه = ۰/۵
-	-	نسبتاً تیز گوشه = ۰/۷۵
-	-	تیز گوشه = ۱

¹⁷ VMA

¹⁸ HWRA

¹⁹ Mps

شکل ۳: شناسایی مشخصات سیمان به مدل.

AW	AX	AY	AZ	BA	BB	BC	BD	BE	BF	BG
the amounts of cement	Chemical properties of cement									the specific gravity of cement
kg/m ³	sio ₂	al ₂ o ₃	fe ₂ o ₃	cao	mgo	so ₃	na ₂ o	k ₂ o	loi	g/cm ³
350	21.5	3.68	2.76	61.5	4.8	2.345	0.12	0.95	2.345	3.14
245	21.5	3.68	2.76	61.5	4.8	2.345	0.12	0.95	2.345	3.14
262.5	21.5	3.68	2.76	61.5	4.8	2.345	0.12	0.95	2.345	3.14
280	21.5	3.68	2.76	61.5	4.8	2.345	0.12	0.95	2.345	3.14
297.5	21.5	3.68	2.76	61.5	4.8	2.345	0.12	0.95	2.345	3.14
315	21.5	3.68	2.76	61.5	4.8	2.345	0.12	0.95	2.345	3.14

۵-۲- تنظیمات اولیه شبکه

۵-۲-۱- معماری شبکه، تابع خطا و ضریب همبستگی

در این تحقیق به منظور ساخت و آموزش شبکه‌های عصبی از جعبه‌ابزار^{۲۰} شبکه عصبی متلب استفاده شد. شبکه‌ی مورد نظر دارای یک لایه‌ی ورودی، یک لایه‌ی خروجی و یک لایه‌ی پنهان است. تعداد نرون‌ها در لایه‌ی ورودی برابر با تعداد پارامترهای ورودی یعنی ۱۴۰ نرون و در لایه‌ی خروجی برابر با تک پارامتر مورد نظر، یعنی مقاومت فشاری ۷ یا ۲۸ روزه می‌باشد. برای تعیین تعداد نرون‌ها در لایه پنهان قانون خاصی وجود ندارد و معمولاً از سعی و خطا استفاده می‌شود [۳۳]. برخی از پژوهشگران در تحقیق خود روابطی را برای تعیین تعداد نرون‌های لایه پنهان ارائه داده‌اند که نمونه‌هایی از این روابط در جدول ۲ آورده شده است که در آنها Ni، NO و NH به ترتیب برابر با تعداد نرون در لایه ورودی، خروجی و پنهان می‌باشد. در این تحقیق مطابق با دستورالعمل ارائه داده شده توسط کانولوپلاس و ویکینسون^{۲۱} [۳۴]، تعداد نرون‌ها در لایه پنهان حداقل تا دو برابر تعداد پارامترهای لایه‌ی ورودی در نظر گرفته شدند که این تعداد از ۳۰ نرون تا ۳۰۰ نرون به منظور تعیین تعداد نرون بهینه متغیر می‌باشند. الگوریتم آموزشی استفاده شده در شبکه، به دلیل گستردگی شبکه و تعداد زیاد نرون‌ها، برابر با الگوریتم^{۲۲} trainscg می‌باشد. تابع انتقال بین دو لایه، بر روی پیش فرض شبکه، یعنی tansig-tansig تنظیم شده است.

جدول ۲: روابط پیشنهادی جهت تعیین تعداد نرون در لایه پنهان

مراجع	رابطه پیشنهادی
[۳۵]	$2Ni/3$
[۳۶]	$(No + Ni)/2$
[۳۷]	$N_H \leq 2N_i + 1$
[۳۴]	$2Ni$

20 Toolbox

21 Kanellopoulos & Wilkinson

22 Scaled Conjugate Gradient

تابع خطای مناسب و قابل استفاده در این پژوهش، تابع میانگین مربعات خطا^{۲۳} می باشد که معمول ترین تابع در بررسی کارایی شبکه های عصبی می باشد که در رابطه ی (۳) آورده شده است. همچنین از ضریب همبستگی^{۲۴} R جهت نشان دادن میزان ارتباط بین خروجی شبکه و مقادیر آزمایشگاهی استفاده شد که طبق رابطه ی (۴) به دست می آید.

$$MSE = \frac{1}{n} \sum_{i=1}^n (t_i - o_i)^2 \quad (3)$$

$$R = \frac{(n \sum t_i o_i - \sum t_i \sum o_i)}{\sqrt{(n \sum t_i^2 - (\sum t_i)^2)(n \sum o_i^2 - (\sum o_i)^2)}} \quad (4)$$

که در هر دو رابطه، t_i مقدار واقعی، o_i مقدار پیش بینی شده و n تعداد داده ها می باشد [۳۸]. اسمیت^{۲۵} بازه زیر را برای R این گونه بیان نمود [۳۹]:

- زمانی که $|R| \geq 0.8$ باشد ارتباط قوی بین دو مجموعه از متغیرها وجود دارد.
- زمانی که $0.2 < |R| < 0.8$ باشد ارتباط بین دو مجموعه از متغیرها وجود دارد.
- زمانی که $|R| \leq 0.2$ باشد ارتباط ضعیف بین دو مجموعه از متغیرها وجود دارد.

لازم به ذکر است جهت پیش بینی مقاومت فشاری توسط شبکه ی المان، مراحل خام، پیش پردازش حداقل حداکثر^{۲۶}، تعداد حداکثر سعی متوالی^{۲۷} و تعیین تابع انتقال بهینه انجام شد که در ادامه در قالب تنظیمات ثانویه شبکه شرح داده شده است.

۵-۳- تنظیمات ثانویه شبکه

۵-۳-۱- نرمال سازی داده ها

نرمالیزه کردن داده ها برای به حداقل رساندن تأثیر اختلاف مقیاس پارامترهای مختلف و اطمینان از یکسان بودن پارامترها می باشد [۳۳]. در واقع در صورتی که ورودی های بزرگی به شبکه ارائه داده شود، حتی با وجود نرون های کوچک در شبکه، جمع ورودی های وزن دار به نرون لایه بعد بزرگ خواهد شد و مشکل عدم انجام آموزش رخ خواهد داد. لذا برای انجام این پژوهش، نرمال سازی داده ها در بازه ی (۰-۱) با استفاده از دستور (۵) و (۶) صورت گرفت [۴۰]:

$$[pn, ps] = \text{mapminmax}(p, 0, 1) \quad (5)$$

$$[tn, ts] = \text{mapminmax}(t, 0, 1) \quad (6)$$

P ورودی شبکه و t هدف مطلوب شبکه می باشد. ورودی ها و اهداف نرمال شده به ترتیب در pn و tn برگردانده می شوند. ps و ts شامل پارامترهای تنظیمی این پیش پردازش می باشند و جهت بازگرداندن پارامترهای نرمال شده مجدداً به وضعیت اولیه خود از تابع reverse و apply استفاده می شود. توجه شود برای انجام این مرحله، به منظور نشان دادن میزان تأثیر پیش پردازش حداقل حداکثر بر میزان میانگین مربعات خطا در تعداد نرون های مختلف، یکبار زوج داده ها بدون پیش پردازش و به صورت خام و بار دیگر با اعمال پیش پردازش حداقل حداکثر وارد شبکه شدند. در جداول ۳ و ۴ نتایج شبکه ی المان برای هر دو حالت در هر دو مقاومت فشاری نشان داده شده است. همان طور

²³ Mean Square Error (MSE)

²⁴ Correlation Coefficient

²⁵ Smith

²⁶ Minimum-Maximum Preprocessing (MinMax)

²⁷ Maxfail

که مشاهده می‌شود در هر دو مقاومت فشاری، میزان میانگین مربعات خطا در حالتی که از پیش‌پردازش حداقل حداکثر استفاده شده است کم‌تر می‌باشد که نشانه‌ی بالاتر رفتن دقت شبکه به دلیل استفاده از این پیش‌پردازش می‌باشد. تعداد نرون بهینه با توجه به کم‌ترین میزان خطای MSE آزمایش به‌دست آمده برای هر مقاومت از بین حالت خام و حداقل حداکثر (برای هر دو مقاومت کم‌ترین مقدار خطا مربوط به حالت MinMax است) که در جدول مشخص شده است، برای مقاومت فشاری ۷ روزه برابر با ۱۸۰ نرون، و در ۲۸ روزه برابر با ۲۷۰ نرون است.

جدول ۳: نتایج حاصل از کاربرد پیش‌پردازش خام و حداقل حداکثر برای مقاومت فشاری ۷ روزه


مقاومت فشاری ۷ روزه	تعداد نرون	۳۰	۶۰	۹۰	۱۲۰	۱۵۰	۱۸۰	۲۱۰	۲۴۰	۲۷۰	۳۰۰
		MSE Test	خام	۵۸/۵۸	۵۱/۰۹	۳۰/۷۸	۳۱/۷۰	۲۹/۶۲	۴۵/۴۶	۷۷/۶۴	۴۹/۳۲
	MinMax	۵۸/۵۸	۵۱/۰۹	۳۲/۹۱	۳۱/۷۰	۲۹	۲۷/۵۲	۷۷/۶۴	۴۹/۳۲	۴۰/۹۷	۴۷/۳۰
MSE Train	خام	۴۳/۵۱	۴۱/۳۲	۲۷/۰۹	۳۱/۵۶	۳۲/۹۶	۳۵/۹۲	۶۲/۱۶	۴۲/۰۴	۳۶/۹۴	۴۷/۸۲
	MinMax	۴۳/۵۱	۴۱/۳۲	۲۷/۷۹	۳۱/۵۶	۳۱/۰۳	۲۶/۲۹	۶۲/۱۶	۴۲/۰۴	۳۶/۹۴	۴۷/۸۲
R Test	خام	۰/۷۸	۰/۸۱	۰/۸۹	۰/۸۹	۰/۸۹	۰/۸۴	۰/۷	۰/۸۲	۰/۸۵	۰/۸۳
	MinMax	۰/۷۸	۰/۸۱	۰/۸۸	۰/۸۹	۰/۸۹	۰/۹۰	۰/۷	۰/۸۲	۰/۸۵	۰/۸۳
R Train	خام	۰/۸۳	۰/۸۴	۰/۹۰	۰/۸۹	۰/۸۷	۰/۸۶	۰/۷۶	۰/۸۴	۰/۸۶	۰/۸۱
	MinMax	۰/۸۳	۰/۸۴	۰/۸۹	۰/۸۹	۰/۸۸	۰/۹۰	۰/۷۶	۰/۸۴	۰/۸۶	۰/۸۱

جدول ۴: نتایج حاصل از کاربرد پیش‌پردازش خام و حداقل حداکثر برای مقاومت فشاری ۲۸ روزه

مقاومت فشاری ۲۸ روزه	تعداد نرون	۳۰	۶۰	۹۰	۱۲۰	۱۵۰	۱۸۰	۲۱۰	۲۴۰	۲۷۰	۳۰۰
		MSE Test	خام	۸۸/۲۰	۱۱۰/۳۰	۷۵/۸۶	۵۳/۷۴	۵۵/۰۳	۱۲۹/۹۰	۴۵/۹۱	۱۷۳/۷۵
	MinMax	۵۳/۷۹	۱۱۰/۳۰	۷۵/۸۶	۵۱/۵۴	۵۵/۰۴	۱۲۹/۹۰	۴۵/۹۷	۱۷۳/۷۴	۴۲/۶۴	۹۴/۹۸
MSE Train	خام	۷۷/۴۰	۹۲/۹۷	۷۴/۱۹	۵۲/۷۰	۵۶/۰۲	۱۰۷/۲۴	۴۸/۶۳	۱۶۰/۱۳	۵۰/۱۸	۸۹/۸۲
	MinMax	۶۳/۷۶	۹۲/۹۷	۷۴/۱۹	۵۰/۵۸	۵۶/۱۴	۱۰۷/۲۴	۴۹/۷۳	۱۶۰/۱۳	۴۱/۷۳	۸۹/۸۲
R Test	خام	۰/۸۵	۰/۸۱	۰/۸۷	۰/۹۱	۰/۹۱	۰/۷۷	۰/۹۲	۰/۶۹	۰/۹۲	۰/۸۴
	MinMax	۰/۹۱	۰/۸۱	۰/۸۷	۰/۹۱	۰/۹۱	۰/۷۷	۰/۹۲	۰/۶۹	۰/۹۳	۰/۸۴
R Train	خام	۰/۸۷	۰/۸۵	۰/۸۸	۰/۹۱	۰/۹۱	۰/۸۲	۰/۹۲	۰/۷۳	۰/۹۲	۰/۸۵
	MinMax	۰/۸۹	۰/۸۵	۰/۸۸	۰/۹۲	۰/۹۱	۰/۸۲	۰/۹۲	۰/۷۳	۰/۹۳	۰/۸۵

۵-۳-۲ - تعیین حداکثر سعی متوالی

در دو مرحله‌ی خام و حداقل حداکثر، تعداد سعی متوالی بر روی پیش‌فرض شبکه یعنی ۶ تکرار تنظیم می‌باشد. در این مرحله میزان دقت شبکه بر روی ۱۰-۵۰-۱۰۰ و ۵۰۰ تکرار نیز ارزیابی شد. این اعداد به‌صورت تصادفی انتخاب شده‌اند و از قانون خاصی تبعیت نمی‌کنند. هدف از این کار، انتخاب تکراری است که در آن شبکه دارای کم‌ترین میزان میانگین مربعات خطا باشد. نتایج به‌دست آمده در شکل ۴ آورده شده‌اند. شبکه برای مقاومت فشاری ۷ روزه در تعداد تکرار ۵۰، و برای مقاومت فشاری ۲۸ روزه در تکرار ۱۰۰ دارای کم‌ترین میزان خطای تست که به ترتیب ۱۱/۶۹، ۱۸/۵۹ می‌باشد است.



شکل ۴: نمودار میزان خطای آزمایش برحسب حداکثر سعی متوالی مختلف در مقاومت فشاری ۷ و ۲۸ روزه.

۵-۳-۳ - تعیین تابع انتقال بهینه

تابع انتقال بین دولایه در این شبکه در تمامی مراحل خام، حداقل حداکثر و حداکثر سعی متوالی در ابتدا به صورت ثابت بر روی پیش فرض شبکه $\text{tansig} - \text{tansig}$ تنظیم می‌باشد، اما در این مرحله‌ی نهایی، ترکیبی از ۹ حالت ممکن از توابع انتقال purline ، tansig^{28} ، logsig^{29} جهت دست یافتن به تابع انتقال بهینه که کم‌ترین میانگین مربعات خطای تست را دارا باشد بررسی می‌شود. نتایج حاصل از به کار بردن توابع انتقال مختلف بین دولایه، و تأثیر آن بر میزان خطای شبکه در جدول ۵ آورده شده است. همان‌طور که مشاهده می‌شود شبکه‌ی عصبی المان در مقاومت فشاری ۷ و ۲۸ روزه با تابع انتقال $\text{Tansig} - \text{Tansig}$ بین دولایه، دارای بهترین دقت و متعاقباً کم‌ترین میزان میانگین مربعات خطا در حالت تست که به ترتیب ۱۱/۶۹ و ۱۸/۵۹ می‌باشد است.

جدول ۵: نتایج حاصل از تأثیر توابع انتقال مختلف بین دولایه در پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم

توابع انتقال بین دولایه		Tansig-Tansig	Tansig-Logsig	Tansig-Purelin	Purelin-Logsig	Purelin-Purelin	Purelin-Tansig	Logsig-Logsig	Logsig-Purelin	Logsig-Tansig
MSE Test	Fc7* ¹	۱۱/۶۹	۱۶۸/۱۴	۱۵/۳۱	۱۶۷/۸۲	۵۳۳/۲۵	۱۷۵/۱۰	۱۶۶/۸۴	۲۱/۸۳	۱۵/۱۰
	Fc28* ²	۱۸/۵۹	۲۵۳/۰۵	۳۱/۴۳	۳۲۸/۶۳	۲/۰۵E +۳	۴۵/۸۹	۲۵۳/۶۵	۴۱/۳۹	۸۳/۴۳
MSE Train	Fc7	۱۲/۵۷	۱۳۵/۸۰	۱۷/۲۷	۱۳۴/۱۰	۲۶۵/۵۹	۲۰۳/۷۸	۱۳۴/۵۴	۱۹/۳۶	۱۷/۸۶
	Fc28	۱۸/۵۹	۲۲۳/۷۹	۲۸/۲۲	۳۲۷/۸۶	۱/۳۲E +۳	۵۵/۵۰	۲۲۲/۹۷	۴۴/۵۳	۸۱/۳۵
R Test	Fc7	۰/۹۶	۰/۴۱	۰/۹۵	۰/۴۴	۰/۳۰	۰/۳۹	۰/۴۳	۰/۹۲	۰/۹۵
	Fc28	۰/۹۷	۰/۶۷	۰/۹۵	۶/۲E -۲۸	۰/۲۶	۰/۹۲	۰/۶۷	۰/۹۳	۰/۸۶
R Train	Fc7	۰/۹۵	۰/۴۷	۰/۹۳	۰/۴۸	۰/۵۵	۰/۳۴	۰/۴۸	۰/۹۳	۰/۹۳
	Fc28	۰/۹۷	۰/۷۰	۰/۹۵	-۱/۷۹E -۲۶	۰/۴۰	۰/۹۱	۰/۷۰	۰/۹۳	۰/۸۶

*^۱: مقاومت فشاری ۷ روزه؛ *^۲: مقاومت فشاری ۲۸ روزه.

۶- سری دوم از پژوهش

در سری دوم از پژوهش، تعداد پارامترهای ورودی به شبکه‌ها به طرز چشم‌گیری کاهش می‌یابد. به عبارت دیگر، به منظور تعیین میزان اثرگذاری پارامترهای ورودی انتخابی بر میزان خطای تست شبکه‌ها در پیش‌بینی مشخصه موردنظر، بخشی از عوامل مؤثر بر مقاومت فشاری بتن نادیده گرفته می‌شود و دیگر تمامی جزئیات موردبررسی قرار نمی‌گیرد و تنها ۸ پارامتر کلی‌تر که اغلب در اکثر مقالات برای

²⁸ Tangent Sigmoid Transfer Function

²⁹ Log Sigmoid Transfer function

پیش‌بینی مقاومت بتن‌های مختلف استفاده می‌شوند جهت مدل‌سازی به کار می‌رود. این پارامترها که به‌واسطه‌ی تجربیات آزمایشگاهی و نیز بهره‌گیری از نتایج مقالات مرتبط به‌کاررفته در این زمینه انتخاب شدند شامل موارد زیر می‌باشند:

۱- مقدار شن مصرفی، ۲- وزن مخصوص شن، ۳- مقدار ماسه مصرفی، ۴- وزن مخصوص ماسه، ۵- مقدار سیمان مصرفی، ۶- وزن مخصوص سیمان، ۷- مقدار فوق روان‌کننده مصرفی، ۸- نسبت آب به سیمان.

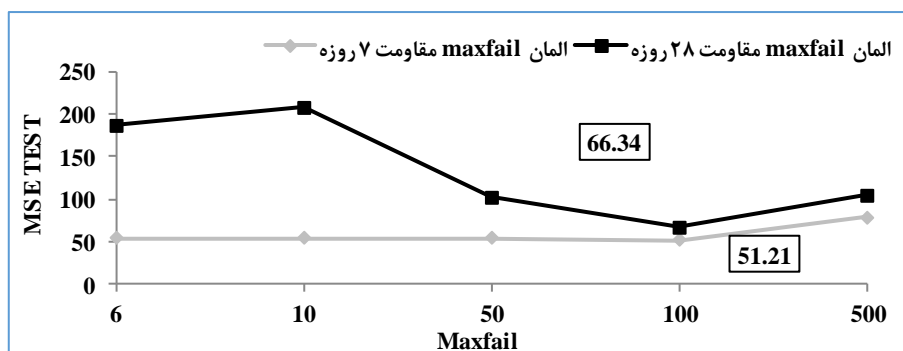
تعداد نرون‌ها در لایه ورودی برابر با تعداد پارامترهای ورودی شبکه یعنی ۸ نرون، و تعداد نرون در لایه‌ی خروجی برابر با تک پارامتر خروجی یعنی مقاومت فشاری ۷ یا ۲۸ روزه و تعداد نرون در لایه پنهان تا ۲ برابر تعداد نرون‌ها در لایه ورودی (از ۴ تا ۱۶ نرون) متغیر می‌باشد. لازم به ذکر است که تمامی مراحل همانند سری اول می‌باشد که در اینجا تنها نتایج هر مرحله آورده می‌شود. در جداول ۶ و ۷ نتایج حاصل از کاربرد پیش‌پردازش خام و حداقل حداکثر به ترتیب برای مقاومت فشاری ۷ و ۲۸ روزه آورده شده است. همان‌طور که مشاهده می‌شود مانند سری اول هر دو مقاومت با اعمال پیش‌پردازش حداقل حداکثر دارای بهبود در میزان خطای تست می‌باشند. تعداد نرون بهینه در مقاومت فشاری ۷ روزه برابر با ۱۶ نرون و در مقاومت ۲۸ روزه برابر با ۱۲ نرون می‌باشد. در ادامه در شکل ۵ میزان میانگین مربعات خطای آزمایش شبکه در تعداد حداکثر سعی متوالی مختلف مشاهده می‌شود که طبق نمودار، شبکه‌ی المان در پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه در تعداد تکرار ۱۰۰ دارای کم‌ترین میزان میانگین مربعات خطای تست می‌باشد. در جدول ۸ نتایج حاصل از تأثیر تغییر توابع انتقال بین دولایه در پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم آورده شده است که مشخص شد در پیش‌بینی هر دو مقاومت فشاری شبکه المان با تابع انتقال بین دولایه Logsig-Purelin دارای کم‌ترین میزان خطای تست می‌باشد که تعیین‌کننده تابع انتقال بهینه می‌باشد.

جدول ۶: نتایج حاصل از کاربرد پیش‌پردازش خام و حداقل حداکثر برای مقاومت فشاری ۷ روزه

مقاومت فشاری ۷ روزه	تعداد نرون	۴	۸	۱۲	۱۶
MSE Test	خام	۵۷/۴۰	۶۹/۷۱	۶۴/۰۸	۵۴/۷۶
	MinMax	۵۷/۳۹	۶۹/۷۱	۶۴/۰۸	۵۳/۶۷
MSE Train	خام	۸۳/۵۹	۸۹/۳۳	۸۶/۴۵	۸۳/۲۶
	MinMax	۸۳/۵۸	۸۹/۳۳	۸۶/۴۵	۸۲/۸۷
R Test	خام	۰/۸۶	۰/۸۲	۰/۸۲	۰/۸۶
	MinMax	۰/۸۶	۰/۸۲	۰/۸۲	۰/۸۵
R Train	خام	۰/۶۳	۰/۶۰	۰/۶۱	۰/۶۳
	MinMax	۰/۶۳	۰/۶۰	۰/۶۱	۰/۶۴

جدول ۷: نتایج حاصل از کاربرد پیش‌پردازش خام و حداقل حداکثر برای مقاومت فشاری ۲۸ روزه

مقاومت فشاری ۲۸ روزه	تعداد نرون	۴	۸	۱۲	۱۶
MSE Test	خام	۲۲۳/۵۵	۲۰۱/۳۱	۱۹۴/۹۹	۲۲۵/۰۶
	MinMax	۲۲۳/۵۵	۲۰۱/۳۱	۱۸۷/۴۴	۲۲۵/۰۶
MSE Train	خام	۲۲۴/۰۴	۲۰۸/۷۷	۲۱۰/۲۴	۲۲۶/۴۸
	MinMax	۲۲۴/۰۴	۲۰۸/۷۷	۲۱۰/۹۳	۲۲۶/۴۸
R Test	خام	۰/۶۱	۰/۶۶	۰/۶۸	۰/۶۰
	MinMax	۰/۶۱	۰/۶۶	۰/۶۸	۰/۶۰
R Train	خام	۰/۵۶	۰/۶۰	۰/۶۰	۰/۵۵
	MinMax	۰/۵۶	۰/۶۰	۰/۶۰	۰/۵۵



شکل ۵: میزان خطای آزمایش بر حسب حداکثر سعی متوالی مختلف در مقاومت فشاری ۷ و ۲۸ روزه.

جدول ۸: نتایج حاصل از تأثیر توابع انتقال مختلف بین دولاچه در پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم

توابع انتقال بین دولاچه	Tansig-Tansig	Tansig-Logsig	Tansig-Purelin	Purelin-Logsig	Purelin-Purelin	Purelin-Tansig	Logsig-Logsig	Logsig-Purelin	Logsig-Tansig	
MSE Test	Fc7* ¹	۵۱/۲۱	۱۵۲/۰۱	۵۶/۱۰	۲۰۸/۸۷	۵۹/۶۶	۵۹/۲۴	۱۴۴/۴۰	۴۵/۹۵	۵۱/۳۵
	Fc28* ²	۶۶/۳۴	۳۷۱/۵۶	۱۰۵/۵۷	۲۹۵/۵۶	۲۰۸/۸۷	۲۰۸/۲۶	۳۷۱/۵۶	۶۲/۹۱	۷۶/۹۸
MSE Train	Fc7	۳۵/۷۵	۱۲۸/۹۶	۵۵/۶۰	۱۷۲/۵۸	۸۷/۴۹	۹۵/۵۱	۱۲۳/۴۹	۶۳/۷۶	۷۱/۸۱
	Fc28	۴۷/۸۹	۳۳۹/۲۵	۱۰۵/۸۹	۲۹۰/۹۰	۲۱۸/۴۵	۲۲۲/۳۸	۳۳۹/۲۵	۵۹/۳۸	۵۶/۹۹
R Test	Fc7	-۰/۸۴	-۰/۶۷	-۰/۸۳	-۰/۱۶	-۰/۸۷	-۰/۸۳	-۰/۷۵	-۰/۸۷	-۰/۸۶
	Fc28	-۰/۹۰	-۰/۲۵	-۰/۸۴	-۰/۵۸	-۰/۶۵	-۰/۶۴	-۰/۱۷	-۰/۹۰	-۰/۸۸
R Train	Fc7	-۰/۸۶	-۰/۶۰	-۰/۷۷	-۰/۱۲	-۰/۶۱	-۰/۵۶	-۰/۷۰	-۰/۷۳	-۰/۶۹
	Fc28	-۰/۹۲	-۰/۱۳	-۰/۸۲	-۰/۴۷	-۰/۵۷	-۰/۵۷	-۰/۱۲	-۰/۹۰	-۰/۹۰

*^۱: مقاومت فشاری ۷ روزه؛ *^۲: مقاومت فشاری ۲۸ روزه.

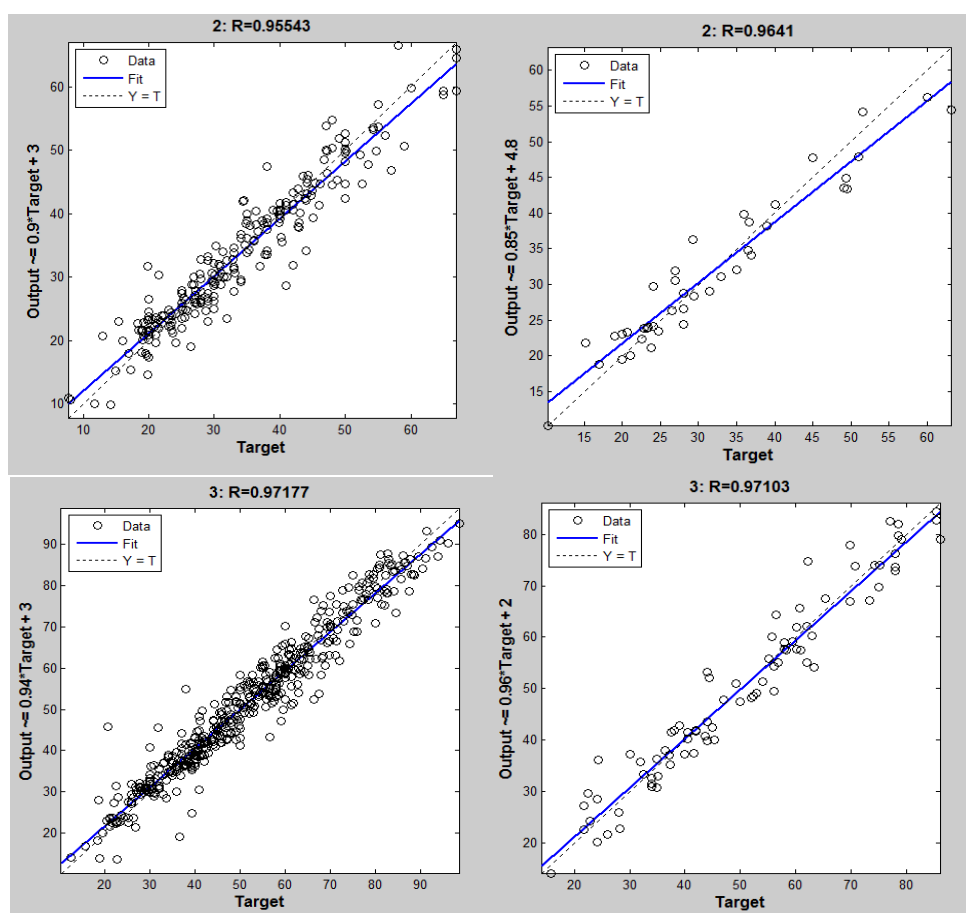
۷- مقایسه‌ی نتایج هر دو سری از پژوهش با شبکه‌ی المان در پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم

در جدول ۹ نتایج حاصل از پیش‌بینی مقاومت فشاری بتن خودتراکم برای هر دو سری از پژوهش با تعداد ۱۴۰ و ۸ پارامتر ورودی آورده شده است. نتایج گویای این است که در پیش‌بینی هر دو مقاومت فشاری، شبکه‌های المان با تعداد ۱۴۰ پارامتر ورودی دارای میانگین خطای تست کمتری در مقایسه با شبکه‌ها با ۸ ورودی می‌باشند که این نشان‌دهنده دقت بالاتر این شبکه‌ها در پیش‌بینی خروجی مدنظر است. به طوری که این میزان بهبود میانگین خطای تست شبکه که از اهمیت بالایی برخوردار است و هر چه کم‌تر باشد نشانه‌ی نزدیک بودن نتیجه‌ی به‌دست‌آمده از پیش‌بینی شبکه با حالت واقعیت (شرایط آزمایشگاهی) می‌باشد. در مقاومت فشاری ۷ روزه با ۱۴۰ ورودی ۷۴/۵۴ درصد و در مقاومت فشاری ۲۸ روزه ۷۰/۴۴ درصد نسبت به شبکه با ۸ ورودی می‌باشد.

جدول ۹: نتایج حاصل از پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم با تعداد ۱۴۰ و ۸ پارامتر ورودی

خرجی شبکه	تعداد ورودی	MSE (Test)	MSE (Train)	R (Test)	R (Train)	میزان بهبود MSE تست در شبکه با
						۱۴۰ ورودی نسبت به MSE تست شبکه با ۸ ورودی برحسب درصد
مقاومت فشاری ۷ روزه	۱۴۰	۱۱/۶۹	۱۲/۵۷	۰/۹۶	۰/۹۵	۷۴/۵۴
	۸	۴۵/۹۵	۶۳/۷۶	۰/۸۷	۰/۷۳	
مقاومت فشاری ۲۸ روزه	۱۴۰	۱۸/۵۹	۱۸/۵۹	۰/۹۷	۰/۹۷	۷۰/۴۴
	۸	۶۲/۹۱	۵۹/۳۸	۰/۹۰	۰/۹۰	

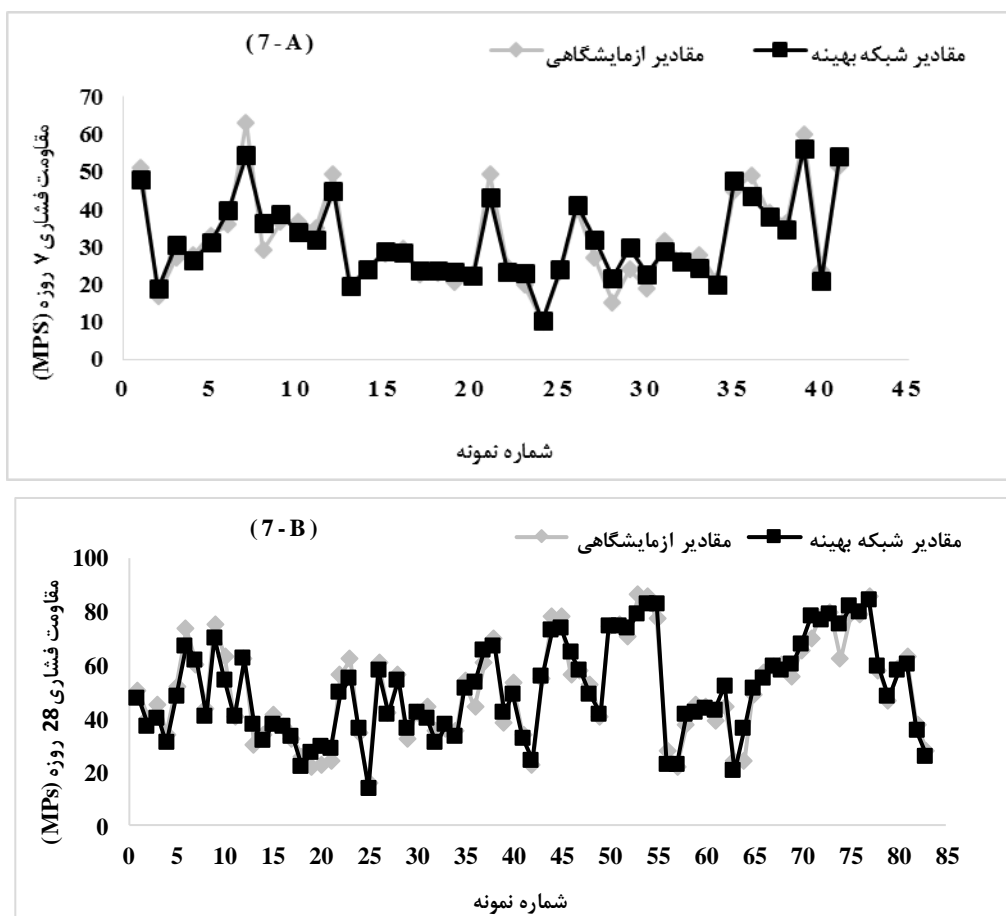
در شکل ۶ نمودار همبستگی داده‌های آزمایشگاهی با نتایج شبکه منتخب (منظور شبکه با میزان میانگین مربعات خطای تست کم‌تر است که در اینجا برای هر دو مقاومت، شبکه با ۱۴۰ ورودی می‌باشد) برای هر دو مقاومت آورده شده است که اشکال در سمت راست از بالا به پایین به ترتیب مربوط به مقاومت فشاری ۷ و ۲۸ روزه در حالت آزمایش شبکه، و در سمت چپ از بالا به پایین مربوط به حالت آموزش شبکه می‌باشند. همان‌طور که پیداست، مقادیر به‌دست‌آمده در طول آموزش و آزمایش شبکه‌های المان دارای همبستگی بالایی با مقادیر آزمایشگاهی می‌باشند که این نشان‌دهنده‌ی عملکرد مناسب شبکه‌های بهینه منتخب ساخته‌شده در پیش‌بینی خواص مدنظر است.



شکل ۶: نمودارهای همبستگی داده‌های آزمایشگاهی با نتایج شبکه منتخب به ترتیب برای مقاومت فشاری ۷ و ۲۸ روزه در حالت آزمایش (سمت راست از بالا به پایین) و آموزش (سمت چپ از بالا به پایین).

در شکل ۷ {7-B و 7-A} مقایسه‌ی نتایج حاصل از پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم توسط شبکه‌ی المان با ۱۴۰ ورودی به‌عنوان شبکه‌ی منتخب با داده‌های آزمایشگاهی در حالت واقعیت آورده شده است. همان‌طور که در نمودارها مشاهده می‌شود

نتایج حاصل از شبکه المان در پیش‌بینی مقاومت ۷ و ۲۸ روزه بتن خودتراکم بسیار نزدیک به نتایج حاصل در محیط آزمایشگاهی می‌باشد که این نشان‌دهنده دقت بسیار بالای شبکه المان بهینه‌شده و در نهایت قابل‌اعتماد بودنش در پیش‌بینی هر دو مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم می‌باشد. در جدول ۱۰ مشخصات کامل هر دو شبکه بهینه‌ی منتخب آورده شده است.



شکل ۷: {7-A و 7-B} میزان اختلاف مقاومت فشاری ۷ و ۲۸ روزه آزمایشگاهی با شبکه‌ی منتخب.

جدول ۱۰: مشخصات کامل شبکه‌های بهینه‌شده منتخب در پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم

	مقاومت فشاری ۷ روزه	مقاومت فشاری ۲۸ روزه
خروجی شبکه	المان با ۱۴۰ ورودی	المان با ۱۴۰ ورودی
تعداد نرون بهینه	۱۸۰	۲۷۰
تعداد سعی متوالی	۵۰	۱۰۰
تابع انتقال بهینه	Tansig-Tansig	Tansig-Tansig
الگوریتم آموزشی	SCG	SCG
MSE(Test)	۱۱/۶۹	۱۸/۵۹
MSE(Train)	۱۲/۵۷	۱۸/۵۹
R(Test)	۰/۹۶	۰/۹۷
R(Train)	۰/۹۵	۰/۹۷

۸ - نتیجه گیری

شبکه‌ی عصبی مورد استفاده در این تحقیق شبکه بازگشتی المان می‌باشد. به ترتیب ۲۷۵ و ۵۴۹ طرح اختلاط برای پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم از مقالات معتبر داخلی و خارجی جمع‌آوری گردید. پژوهش در دو سری انجام گرفت. در سری اول ۱۴۰ پارامتر تأثیرگذار بر مشخصه‌ی مقاومتی بتن به‌عنوان ورودی وارد شبکه‌ها شدند که در میان مقالات ارائه‌شده در زمینه‌ی پیش‌بینی خواص بتن، این تعداد منحصر بفرد می‌باشد. علت انتخاب این تعداد پارامتر، ساخت الگویی جامع برای بتن خودتراکم با گستردگی چشمگیر همراه با شبیه‌سازی هر چه بیشتر شرایط پیش‌بینی به شرایط آزمایشگاهی آن‌هم از طریق به کار بردن تعداد بیشتری از عوامل تأثیرگذاری که در حالت واقعیت در شرایط آزمایشگاهی موجود است و بر مشخصه‌ی مدنظر اثرگذار است، بیان شد. در سری دوم محقق به‌منظور بررسی میزان اثرگذاری پارامترهای ورودی انتخابی بر دقت شبکه در پیش‌بینی خواص مدنظر، پارامترها را به ۸ ورودی کاهش داد. در این تحقیق مشاهده شد که شبکه‌ی المان با وجود استفاده از منابع مختلف که انتظار می‌رود به دلیل گستردگی باعث بالا رفتن خطای شبکه شود، توانست با دقت بالایی مقاومت فشاری بتن خودتراکم را پیش‌بینی کند. از طرفی مشخص شد هنگامی که ورودی‌هایی که به شبکه وارد می‌شوند کامل‌تر و جامع‌تر باشند و دربردارنده‌ی بخش عظیمی از عوامل تأثیرگذار بر مشخصه‌ی مدنظر باشند، شبکه با دقت بالایی قادر به پیش‌بینی خاصیت موردنظر می‌باشد به‌طوری‌که در این پژوهش میزان خطای تست شبکه المان با ۱۴۰ ورودی برای مقاومت فشاری ۷ و ۲۸ روزه بتن خودتراکم به ترتیب ۱۱/۶۹ و ۱۸/۵۹، و برای شبکه با ۸ ورودی به ترتیب ۴۵/۹۵ و ۶۲/۹۱ به دست آمد که همان‌طور که در بالا محاسبه شد در شبکه‌های بهینه‌شده المان با ۱۴۰ ورودی نسبت به ۸ ورودی برای هر دو مقاومت به ترتیب به میزان ۷۴/۵۴ و ۷۰/۴۴ درصد بهبود در خطای تست مشاهده شد که علت آن جامع‌تر بودن پارامترهای ورودی و در نظر گرفتن جزئیات بیشتر در حین مدل‌سازی شبکه بهینه می‌باشد. طبق نتایج حاصل‌شده در این پژوهش، شبکه‌ی المان دارای پتانسیل بالایی در پیش‌بینی مقاومت فشاری بتن خودتراکم می‌باشد. همچنین هر چه پارامترهای تأثیرگذار ورودی داده‌شده به شبکه‌ی کامل‌تر باشند و به عبارتی دقت بیشتری در شناسایی و به کار گرفتن عوامل ورودی مؤثر بر خروجی موردنظر در هنگام ساخت شبکه صورت گیرد، نتایج حاصل از پیش‌بینی شبکه به نتایج به‌دست‌آمده از شرایط آزمایشگاهی نزدیک‌تر می‌شود و متعاقباً شبکه با خطای کم‌تر و دقت بالاتری خاصیت موردنظر را پیش‌بینی خواهد کرد.

مراجع

- [1] Bartos, P.J.M., Gibbs, J.C., Zhu, W. (2001). Uniformity of in Situ Properties of Self- Compacting Concrete in Full Scale Structural Elements. *Cement and Concrete Composites*, 23(1), 57-64.
- [2] Okamura, H., Ouchi, M. (2003). Self-compacting concrete. *Journal of Advanced Concrete Technology*, 1(1), 5-15.
- [3] Dehwah HAF. (2012). Mechanical properties of self-compacting concrete incorporating quarry dust powder, silica fume or fly ash. *Construction and Building Materials*, 26, 547-551.
- [4] Kasperkiewicz, J., Raczy, J., dubrawski, A. (1995). HPC Strength Prediction Using Artificial Neural Network. *Journal of Computing in Civil Engineering*, 9(4), 279-284.
- [5] Oztas, A., Pala, M., Ozbay, E., Kanca, E., Caglar, N., Bhatti, M.A. (2006). Predicting the compressive strength and slump of high strength concrete using neural network. *Construction and Building Materials*, 20(9), 769-775.
- [6] Demir, F. (2008). Prediction of elastic modulus of normal and high strength concrete by artificial neural networks. *Construction and Building Materials*, 22(7), 1428-1435.
- [7] Barbuta, M., Diaconescu, R.M., Harja, M. (2012). Using Neural Networks for Prediction of Properties of Polymer Concrete with Fly Ash. *Journal of Materials in Civil Engineering*, 24(5), 523-528.
- [8] Sonebi, M., Grünwald, S., Cevik, A., Walraven, J. (2016). Modelling fresh properties of self-compacting concrete using Neural network technique. *Computers and Concrete*, 18(4), 903-920.
- [9] Raghu Prasad, B.K., Eskandari, H., Venkatarama Reddy, B.V. (2009). Prediction of compressive strength of SCC and HPC with high volume fly ash using ANN. *Construction and Building Materials*, 23(1), 117-128.
- [10] Malagavelli, V., Manalel, P.A. (2014). Modeling of Compressive Strength of Admixture-based Self Compacting Concrete using Fuzzy Logic and Artificial Neural Networks. *Asian Journal of Applied Sciences*, 7, 536-551.
- [11] Abd, M., Elaty, A. (2014). Compressive strength prediction of Portland cement concrete with age using a new model. *HBRC Journal*, 10(2), 145-155.

- [12] Neville, A.M., Brooks, J.J. (2010). Concrete Technology. The Second Edition. Pennsylvania: Trans-Atlantic Publications, 1-464.
- [13] Minin, A. (2006). The Neural-Network Analysis Data Filters. 1-12.
- [14] Hassoun, M.H. (1995). Fundamentals of Artificial Neural Networks. Cambridge: A Bradford Book, 1-511.
- [15] McCulloch, W.S., Pitts, W.H. (1943). A logical calculus of the ideas immanent in neural nets. *Bulletin of Mathematical Biology*, 5, 115-133.
- [16] Rosenblatt, F. (1962). Principles of Neurodynamics: Perceptron and the Theory of Brain Mechanism. Washington: Spartan Books, 1-616.
- [17] Hubick, K. T. (1992). Artificial neural networks in Australia. Canberra: Department of Industry, Technology and Commerce, 1-132.
- [18] Elman, J.L. (1990). Finding structure in time, *Cognitive Science*, 14, 179-211.
- [19] Suzuki, K. (2011). Artificial Neural Networks: Methodological Advances and Biomedical Applications. Rijeka: InTech, 1-362.
- [20] Tang, Z.H., Li, R. (2011). An Improved Neural Network Model and Its Applications. *Journal of Information & Computational Science*, 10, 1881-1888.
- [21] Douglas, R.P. (2004). Properties of Self-Consolidating Concrete Containing Type F Fly Ash. Msc Thesis. Northwestern University, Evanston, Illinois.
- [22] Turk, K., Karatas, M. (2011). Abrasion Resistance and Mechanical Properties of Self-Compacting Concrete with Different Dosage of Fly Ash/Silica Fume. *Indian Journal of Engineering & Materials Sciences*, 18, 49-60.
- [23] Abdul Hameed, M. (2005). A study of mix design and durability of Self Compacting Concrete. Msc Thesis. King Fahd University of Petroleum & Minerals, Saudi Arabia.
- [24] Kumar, R., Madan, S.K., Devgan, N.P., Roshan, L. (2013). An Experimental Study on Performance of Self Compacting Concrete Containing Lime Stone Quarry Fines and Fly Ash. *Asian Journal of Civil Engineering (BHRC)*, 15(3), 421-433.
- [25] Corinaldesi, V., Moriconi, G. (2011). Characterization of self-compacting concretes prepared with different fibers and mineral additions. *Cement & Concrete Composites*, 33(5), 596-601.
- [26] Venkateswara Rao, S., Seshagiri Rao, M.V., Rathish Kumar, P. (2010). Effect of Size of Aggregate and Fines on Standard and High Strength Self Compacting Concrete. *Journal of Applied Sciences Research*, (5), 433-442.
- [27] Beigi, M., Berenjian, J., Lotfi Omran, O., Sadeghi Nik, A., Nikbin, I. (2013). An experimental survey on combined effects of fibers and nanosilica on the mechanical, rheological, and durability properties of self-compacting concrete. *Materials and Design*, 50, 1019-1029.
- [28] Guneyisi, E., Gesoglu, M., Ozbay, E. (2010). Strength and drying shrinkage properties of self-compacting concretes incorporating multi-system blended mineral admixtures. *Construction and Building Materials*, 24(10), 1878-1887.
- [29] Hossain, K.M.A., Lachemi, M., Sasmour, M., Sonebi, M. (2013). Strength and fracture energy characteristics of self-consolidating concrete incorporating polyvinyl alcohol, steel and hybrid fibers. *Construction and Building Materials*, 45, 20-29.
- [30] Sahmaran, M., Yurtseven, A., Ozgur Yaman, I. (2005). Workability of hybrid fiber reinforced self-compacting concrete. *Building and Environment*, 40(12), 1672-1677.
- [31] Aydin, A.C. (2007). Self compactability of high volume hybrid fiber reinforced concrete. *Construction and Building Materials*, 21(6), 1149-1154.
- [32] Patel, A., Bhuva, P., George, E., Bhatt, D. (2011). Compressive Strength and Modulus of Elasticity of Self-Compacting Concrete. In: National Conference on Recent Trends in Engineering & Technology, India.
- [33] Masters, T. (1993). Practical neural network recipes in C++. San Diego, California: Academic Press publication, 1-493.
- [34] Kanellopoulas, I., Wilkinson, G.G. (1997). Strategies and best practice for neural network image classification. *International Journal of Remote Sensing*, 18(4), 711-725.
- [35] Govindaraju, R.S. (2000). ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. *Journal of Hydrologic Engineering*, 5(2), 115-123.
- [36] Ripley, B.D. (1993). Statistical aspects of neural networks: Networks and chaos-statistical and probabilistic aspects. London: Chapman & Hall, 40-123.
- [37] Wang, C.A. (1994). Theory of generalization in learning machines with neural application. PhD Thesis. Pennsylvania University, USA.
- [38] Saridemir, M., Topcu, I.B., Ozcan, F., Severcan, M.H. (2009). Prediction of long-term effects of GGBFS on compressive strength of concrete by artificial neural networks and fuzzy logic. *Construction and Building Materials*, 23, 1279-1286.
- [39] Smith, M. (1993). Neural networks for statistical modelling. New York: Van Nostrand Reinhold, 1-235.
- [40] MATLAB Software, Neural Network Toolbox: mapminmax, R2013b, Version: (8.2.0.701), august 13 (2013).