Semnan University

Journal of Modeling in Engineering

Journal homepage: https://modelling.semnan.ac.ir/

ISSN: 2783-2538



Research Article

Comparison of ANN and ANFIS Networks for Predicting the Compressive Strength of Silica Fume SCC Concrete

Ashkan Khodabandehlou[a*], Mahmoudreza Golshan[b], Farhad Avaznezhad[c]

[a] *Associate Professor, Department of Civil Engineering, Ur.C., Islamic Azad University, Urmia, Iran*
[b] *Department of Civil Engineering, Technical and Vocational University(TVU), Tehran, Iran*
[c] *Department of Architecture and Urban Planning, Technical and Vocational University(TVU), Tehran, Iran*

PAPER INFO

Paper history:

Received: 2022-03-13
Revised: 2022-05-12
Accepted: 2022-10-19

Keywords:
SCC concrete,
Artificial intelligence,
Silica fume,
ANN,
ANFIS.

ABSTRACT

Designing a mix for high-strength SCC concrete requires heightened precision and strict control over the quantities of constituent materials. Moreover, conducting compressive strength tests for concrete at various ages involves significant time and cost, generates waste, and causes environmental harm. In recent years, the use of innovative approaches in the concrete industry has expanded. With technological advancements, machine learning is now capable of solving complex problems; specifically, it can estimate the compressive strength of concrete based on the provided mix design. The learning process, however, is divided into various methods and categories depending on the expected output, many of which have become obsolete over time, with more accurate approaches being introduced. In this study, silica fume was incorporated in the production of SCC concrete, and various algorithms were employed to examine the influence of different material ratios on compressive strength. In this regard, Artificial Neural Networks (ANN) and Adaptive Neuro-Fuzzy Inference Systems (ANFIS) with 1 to 10 hidden layers were developed, and their results were compared. Findings from the first part of the study revealed that the ANFIS and ANN models with 10 and 6 hidden layers, respectively, achieved higher accuracy than the other models. In the second part, to validate the AI model results, six high-strength SCC concrete mix designs with various material proportions were prepared and tested experimentally, and the results were compared with the predictions of the ANFIS and ANN networks. The results indicated that the ANFIS network with ten hidden layers achieved, on average, an accuracy of 96% in estimating the compressive strength of high-strength SCC concrete.

DOI: https://doi.org/10.22075/jme.2024.31282.2495

© 2024 Published by Semnan University Press.
This is an open access article under the CC-BY 4.0 license.(https://creativecommons.org/licenses/by/4.0/)

*** Ashkan Khodabandehlou**
E-mail address: a.khodabandehlou@iau.ac.ir

How to cite this article:

UNCORRECTED PROOF

مقاله پژوهشی

مقایسه دو شبکه ANN و ANFIS جهت پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی دوده سیلیسی

اشکان خدابنده‌لو[۱*]، محمودرضا گلشن[۲] و فرهاد عوض‌نژاد[۳]

اطلاعات مقاله

دریافت مقاله: ۱۳۹۵/۰۳/۲۰
بازنگری مقاله: ۱۳۹۵/۰۶/۲۰
پذیرش مقاله: ۱۳۹۵/۰۷/۱۵

واژگان کلیدی:
بتن خودتراکم،
ماشین یادگیری،
دوده سیلیس،
عصبی مصنوعی،
استنتاج عصبی فازی تطبیقی.

چکیده

طراحی طرح مخلوط بتن خودتراکم با مقاومت بالا، نیازمند دقت و کنترل مضاعف بر مقادیر مصالح مصرفی است. همچنین انجام آزمایش‌های مقاومت فشاری بتن در سنین مختلف، منجر به صرف زمان و هزینه زیاد، تولید پسماند و آسیب به محیط زیست می‌شود. در سال‌های اخیر، استفاده از روش‌های نوین در صنعت بتن گسترش یافته است. با توسعه فناوری، اکنون ماشین یادگیری قادر است مسائل پیچیده را حل کند. به گونه‌ای که می‌تواند با دریافت طرح اختلاط بتن، مقاومت فشاری آن را محاسبه نماید. اما فرآیند یادگیری آن بسته به نوع خروجی مورد نظر، به روش‌ها و دسته‌های مختلفی تقسیم می‌شود که با گذشت زمان، بسیاری از آن‌ها منسوخ شده و روش‌های دقیق‌تری ارائه شده‌اند. در این تحقیق، برای ساخت بتن خودتراکم از دوده سیلیسی استفاده شد و جهت بررسی تأثیر نسبت‌های مختلف مصالح بر مقاومت فشاری، از الگوریتم مختلف استفاده شد. در این راستا، شبکه عصبی مصنوعی (ANN) و شبکه استنتاج فازی عصبی-تطبیقی (ANFIS) با ۱ تا ۱۰ لایه پنهان ساخته و نتایج آن‌ها با یکدیگر مقایسه شد. نتایج بخش اول تحقیق نشان داد که شبکه‌های ANFIS و ANN به ترتیب با ۱۰ و ۶ لایه پنهان از دقت بالاتری نسبت به سایر مدل‌ها برخوردار هستند. در بخش دوم تحقیق، برای صحت‌سنجی نتایج مدل‌های ماشین یادگیری، شش طرح مخلوط بتن خودتراکم با مقاومت بالا و نسبت‌های مختلف مصالح به صورت آزمایشگاهی ساخته و نتایج آن‌ها با مدل‌های ANFIS و ANN مقایسه شد. یافته‌ها نشان داد که شبکه ANFIS با ده لایه پنهان به طور میانگین دقتی معادل ۹۶٪ توانایی محاسبه مقاومت فشاری بتن خودتراکم با مقاومت بالا را دارد.

DOI: https://doi.org/10.22075/jme.2024.31282.2495

© 2024 Published by Semnan University Press.
This is an open access article under the CC-BY 4.0 license.(https://creativecommons.org/licenses/by/4.0/)

UNCORRECTED PROOF

* پست الکترونیک نویسنده مسئول: a.khodabandehlou@iau.ac.ir
۱. دانشیار، گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران
۲. مربی، گروه مهندسی عمران، دانشگاه فنی و حرفه‌ای، تهران، ایران
۳. مربی، گروه معماری و شهرسازی، دانشگاه فنی و حرفه‌ای، تهران، ایران

استناد به این مقاله: نحوه استناد فارسی در اینجا درج گردد.

۱-مقدمه

برای تولید بتن با مقاومت بیش از ۴۰ مگاپاسکال، اجرای کنترل کیفی دقیق و انتخاب مصالح و طرح اختلاط با دقت بالا شامل روان‌کننده‌ها، مواد افزودنی معدنی، نوع و اندازه سنگدانه‌ها ضرورت دارد[۱]. یکی از روش‌های متداول و اقتصادی برای ساخت بتن خودتراکم با مقامت بالا، استفاده از پوزولان‌هایی نظیر خاکستر بادی، دوده سیلیس یا زئولیت است[۲]. دوده سیلیسی، محصول فرعی فرآیند کوره‌های قوس الکتریکی در تولید آلیاژهای فروسیلیس بوده و ترکیب شیمیایی غالب آن دی‌اکسید سیلیسی است. این ذرات با اندازه‌ای در محدوده ۰/۰۵ تا ۰/۱۵ میکرون، ریزتر و نرم‌تر از ذرات سیمان بوده و به دلیل ماهیت بسیار ریزدانه، سطح واکنشی بالایی داشته و به منظور افزایش دوام و مقاومت به بتن افزوده می‌شوند. ورود دوده سیلیسی به مخلوط بتن، موجب واکنش دی‌اکسید سیلیسی با محلول هیدروکسید کلسیم آزاد در منافذ موئینه بتن شده و کریستال‌های نامحلول سیلیکات کلسیم را تشکیل می‌دهد که با افزایش تراکم خمیر سیمان، مقاومت فشاری بتن را بهبود می‌بخشند[۳]. این ماده همچنین دانسیته بتن را افزایش داده و کیفیت چسبندگی اجزای آن را ارتقا می‌دهد و به طور معمول در تولید بتن‌های با مقاومت فشاری بالا به کار گرفته می‌شود[۴]. نتایج تحقیقات پیشین نشان می‌دهد که افزودن ۵ تا ۱۵ درصد وزنی دوده سیلیسی نسبت به سیمان، می‌تواند مقاومت فشاری بتن را به میزان ۱۲ تا ۱۵ مگاپاسکال افزایش دهد[۶,۵]. در تولید بتن پرمقاومت، نسبت ترکیب مصالح و طراحی طرح مخلوط اهمیت بسزایی دارد و لازم است پیش از بتن‌ریزی، چندین طرح مخلوط مورد آزمایش و ارزیابی قرار گیرد. اما این فرآیند ممکن است منجر به اتلاف زمان، هزینه و آسیب به محیط زیست شود. ساخت و ارزیابی مقاومت فشاری بتن خودتراکم با مقاومت بالا معمولاً به نمونه‌گیری و انجام آزمایش نیاز دارد. اما این مقاومت می‌تواند تحت تأثیر عواملی همچون مقدار سنگدانه مصرفی، نسبت آب به سیمان، عیار سیمان و افزودنی‌های مختلف تغییر کند. استفاده از ماشین یادگیری در صنعت و فناوری بتن با هدف کاهش هزینه ساخت نمونه‌های آزمایشگاهی، صرفه‌جویی در مصرف سنگدانه و سیمان برای حفاظت از محیط زیست، کاهش پسماندهای ناشی از شکست نمونه، کوتاه کردن زمان فرآیند و حذف نیاز به عمل‌آوری در سنین مقرر انجام می‌گیرد. همچنین استفاده از این روش امکان محاسبه مقاومت فشاری بتن را بر اساس مقادیر مصالح مصرفی، بدون نیاز به نمونه‌گیری و صرف هزینه یا زمان اضافی فراهم می‌کند[۷]. این فناوری با تحلیل رابطه بین طرح مخلوط و مقاومت فشاری حاصل و اعمال تغییر در مقادیر مصالح، مقاومت متناظر را پیش‌بینی می‌کند. بدین منظور، تمام اطلاعات طرح‌های مخلوط در قالب یک پایگاه داده جامع به‌عنوان ورودی آموزش به شبکه ارائه شده تا ارتباط بین متغیرها شناسایی شود و پس از تکمیل فرآیند یادگیری، قابلیت پیش‌بینی مقاومت بر اساس طرح مخلوط پیشنهادی حاصل گردد[۸].

ماشین یادگیری شاخه‌ای از علوم مهندسی است که به صورت سخت‌افزاری یا نرم‌افزاری طراحی شده و بر اساس برنامه‌ریزی از پیش تعیین شده واکنش نشان می‌دهد. در برخی موارد، مجموعه‌ای از داده‌های ورودی اولیه به آن داده می‌شود تا با تحلیل آن‌ها، پاسخ مناسب ارائه دهد[۹]. معماری این فناوری از ساختار و عملکرد هوش انسانی الهام گرفته شده تا امکان انجام وظایف انسانی را با سرعت و دقت بیشتر فراهم کند[۱۰]. یکی از تقسیم‌بندی‌های رایج ماشین یادگیری، تفکیک آن به یادگیری محدود و یادگیری عمیق است که هر دو از الگوریتم‌هایی برای کاهش نیاز به دخالت مستقیم انسان بهره می‌گیرند[۱۱]. تفاوت اصلی این دو در پیچیدگی الگوریتم‌ها است. یادگیری عمیق با بهره‌گیری از لایه‌های متعدد شبکه‌های عصبی و الگوبرداری از فرآیند یادگیری ذهن انسان، در تحلیل داده‌های حجیم، شناسایی الگوها و انجام مدل‌سازی پیش‌بینی نقش کلیدی دارد[۱۲]. یادگیری عمیق در واقع بخشی پیشرفته از فرآیند یادگیری و ابزاری برای خودکارسازی تحلیل‌های پیش‌بینی است. در مقابل، یادگیری محدود تنها در حوزه‌ای خاص عمل کرده و وظایفی مشخص را، گاه با کارایی بالاتر از انسان، انجام می‌دهد[۱۳-۱۶].

در زمینه تخمین مقاومت فشاری بتن، روش‌های متعددی با رویکردهای ریاضی و محاسباتی توسط پژوهشگران ارائه شده است. بسیاری از این روش‌ها بر پایه الگوریتم‌های سنتی مانند مدل‌های درختی، رگرسیون خطی و برگشتی توسعه یافته‌اند. شواهد نشان می‌دهد که روش‌های مبتنی بر ماشین یادگیری، از جمله منطق فازی و شبکه‌های عصبی مصنوعی، با دقت بالاتری قادر به تحلیل و محاسبه نتایج هستند[۱۸,۱۷]. مهم‌ترین مزیت این روش‌ها قابلیت

UNCORRECTED PROOF

یادگیری از داده‌ها و الگوهای آموزشی شامل ورودی‌ها و خروجی‌های پایگاه داده است. ترکیب سیستم‌های فازی مبتنی بر قواعد منطقی با شبکه‌های عصبی قادر به تحلیل روابط عددی، امکان مدل‌سازی و یادگیری بر اساس داده‌های ورودی را فراهم می‌سازد[۱۹-۲۱].

عرب‌زاده و همکاران (۲۰۲۱) با استفاده از شبکه ANFIS و مدل‌های رگرسیون غیرخطی بهینه، مدول الاستیسیته بتن را محاسبه و پیش‌بینی کردند. نتایج این مطالعه نشان داد که شبکه ANFIS از دقت بالاتری نسبت به رگرسیون غیرخطی برخوردار بوده و برای بتن‌های با مقاومت معمولی و بالا مناسب‌تر است[۲۲]. پیرمحمدی و همکاران (۲۰۲۱) خزش بتن خودتراکم را با استفاده از شبکه ANN مورد بررسی قرار دادند و ثابت کردند که این شبکه توانایی پیش‌بینی مناسب جمع‌شدگی را دارد[۲۳]. عمادی و همکاران (۲۰۱۷) عملکرد سه روش شبکه ANN، ANFIS و ماشین بردار پشتیبان را در پیش‌بینی خواص بتن غلتکی مقایسه کردند و دریافتند شبکه عصبی مصنوعی بیشترین تطابق را با داده‌های آزمایشگاهی دارد[۲۴]. گل‌افشانی و همکاران (۲۰۲۰) مقاومت فشاری ۲۸ روزه بتن را با کمک شبکه ANFIS و با ضریب R^2=0.8345 پیش‌بینی کردند که نشان‌دهنده دقت مناسب مدل است[۲۵]. صدرممتازی و همکاران (۲۰۱۸) انواع ساختارهای شبکه عصبی را در پیش‌بینی مقاومت بتن حاوی میکروسیلیس ارزیابی کردند و نشان دادند که الگوریتم ANN با دقت و همبستگی بالا بهترین عملکرد را ارائه می‌دهد[۲۶]. باقرزاده و همکاران (۲۰۱۹) نیز پیش‌بینی مقاومت فشاری بتن را با دو رویکرد ANN و ANFIS بررسی کرده و گزارش کردند که هر دو مدل عملکرد رضایت‌بخشی دارند[۲۷]. بهرامی و همکاران (۲۰۲۰) با مقایسه مدل‌های رگرسیون، ANN و ANFIS در محیط MATLAB دریافتند که ANN و ANFIS پیش‌بینی‌های دقیق‌تری نسبت به رگرسیون خطی برای مقاومت فشاری ۲۸ روزه بتن ارائه می‌کنند[۲۸]. بوگا و همکاران (۲۰۱۸) با تحلیل بتن حاوی زئولیت با استفاده از شبکه عصبی مصنوعی نشان دادند که این روش‌ها در صنعت بتن کارآمد بوده و می‌توانند مشکلات ناشی از زمان‌بر بودن یا پیچیدگی محاسبات عددی را برطرف کنند[۲۹]. بال و همکاران (۲۰۱۷) نیز نشان دادند که استفاده همزمان از دوده سیلیسی و سرباره در بتن خودتراکم موجب کاهش نفوذپذیری و افزایش مقاومت فشاری مخلوط می‌شود[۳۰].

مرور پیشینه تحقیق بیانگر آن است که استفاده از ماشین یادگیری در پیش‌بینی مقاومت فشاری انواع بتن رویکردی مؤثر به شمار می‌رود. بسیاری از پژوهش‌ها گزارش کرده‌اند که ایجاد یک پایگاه داده شامل ۵۰ تا ۱۰۰ طرح مخلوط می‌تواند فرآیند یادگیری را ممکن سازد و با افزایش تعداد طرح‌های مخلوط در این پایگاه داده، دقت پیش‌بینی نیز بهبود می‌یابد، مشروط بر آنکه گستره مقادیر مخلوط بسیار متفاوت نباشد تا از بروز اختلال در آموزش جلوگیری شود. همچنین توصیه شده است که فرآیند آموزش شبکه بیش از سه مرتبه تکرار نشود تا شبکه دچار مشکل در روند یادگیری نگردد[۲۲-۳۰]. تاکنون الگوریتم‌های متنوعی برای ایجاد مدل‌های ماشین یادگیری در پیش‌بینی مقاومت فشاری بتن معمولی، بتن خودتراکم، بتن غلتکی و سایر انواع بتن به کار گرفته شده است. در گذر زمان و با پیشرفت این حوزه، روش‌های نوینی با دقت و سرعت بالاتر معرفی شده‌اند که از جمله آن‌ها می‌توان به شبکه‌های ANN و ANFIS اشاره کرد. نتایج مطالعات پیشین نشان می‌دهد که در پیش‌بینی مقاومت فشاری بتن معمولی، مدل ANFIS و در پیش‌بینی مقاومت فشاری بتن غلتکی، مدل ANN دقت بالاتری ارائه می‌کنند[۳۱-۳۳]. در این تحقیق، تمرکز بر بررسی و مقایسه عملکرد دو شبکه ANFIS و ANN در محاسبه مقاومت فشاری بتن خودتراکم حاوی دوده سیلیسی است و در ادامه، نتایج مدل‌سازی با داده‌های آزمایشگاهی صحت‌سنجی می‌شود.

این تحقیق شامل سه مرحله می‌باشد:

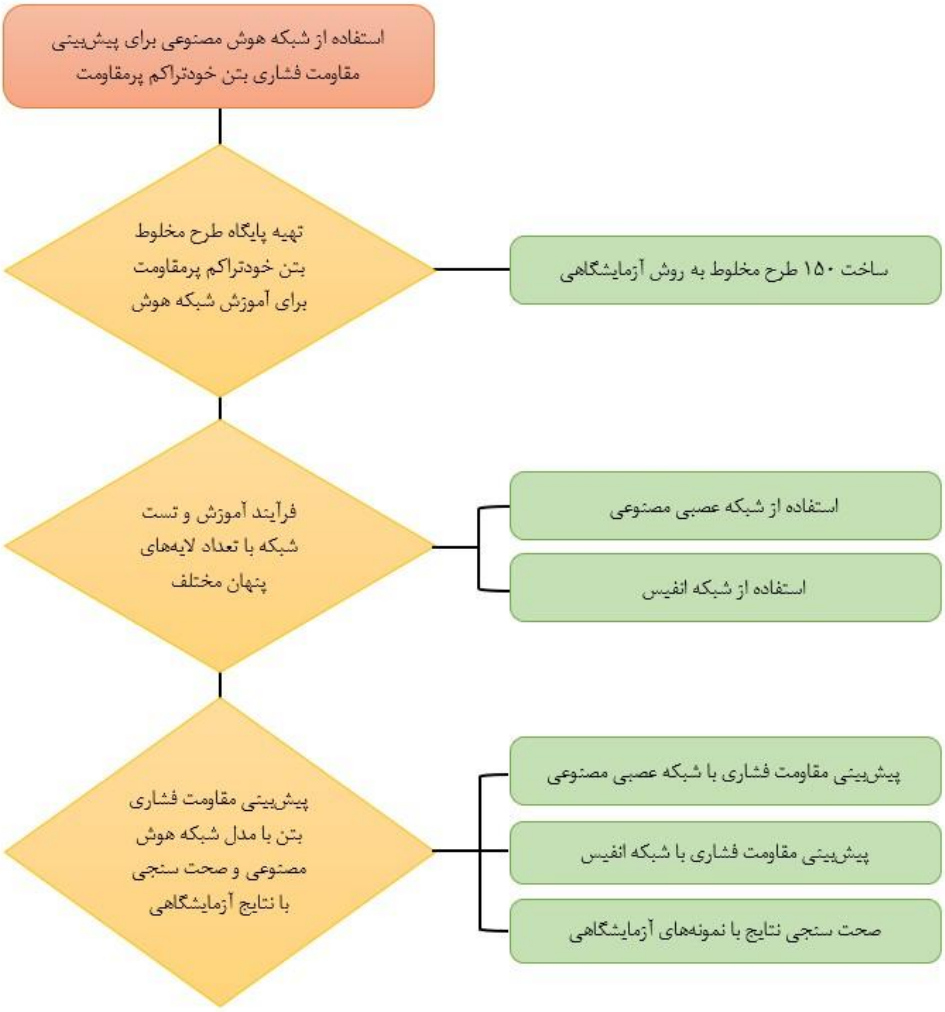
مرحله اول: تهیه اطلاعات آماری و ساخت پایگاه داده برای آموزش شبکه ماشین یادگیری.

مرحله دوم: فرآیند آموزش و تست ماشین یادگیری با تعداد لایه پنهان مختلف و انتخاب بهترین حالت عملکردی.

مرحله سوم: صحت سنجی نتایج بدست آمده از ماشین یادگیری با چند طرح اختلاط ابتکاری و مقایسه نتایج آزمایشگاهی و عددی با یکدیگر.

شکل شماره ۱ مراحل روند پیشرفت این تحقیق را نشان می‌دهد.

UNCORRECTED PROOF



شکل ۱ فلوچارت مراحل انجام تحقیق [ماخذ: نگارندگان]

۲-روش مدل‌سازی عددی

۲-۱-شبکه (ANN)

شبکه‌های عصبی که با نام شبکه عصبی مصنوعی (ANN)[۲] شناخته می‌شوند، یکی از زیرمجموعه‌های یادگیری ماشین بوده و در گروه الگوریتم‌های یادگیری عمیق قرار می‌گیرند. نام و ساختار این شبکه‌ها از مغز انسان الهام گرفته و فرآیند آن بر اساس الگوبرداری از نحوه ارسال سیگنال میان نورون‌های بیولوژیکی عمل می‌کند. به این ترتیب با دریافت اطلاعات ورودی، پردازش داده‌ها و تحلیل روابط، پاسخ متناسب را پیش‌بینی می‌نماید[۳۵]. در ساختار این شبکه‌ها، نورون‌ها داده‌های ورودی را دریافت کرده، با استفاده از وزن‌های مشخص آن‌ها را پردازش می‌کنند و خروجی به دست آمده را به نورون‌های لایه بعد انتقال می‌دهند. معماری ANN به‌صورت سلسله مراتب لایه‌ای شامل یک لایه ورودی، چندین لایه مخفی و یک لایه خروجی سازمان یافته است. هر لایه مخفی نسبت به لایه‌های پیشین محاسبات پیچیده‌تری انجام می‌دهد و با افزایش تعداد لایه‌ها، توانایی شبکه در تحلیل روابط غیرخطی و مسائل پیچیده‌تر تقویت می‌شود[۳۶]. کارایی ANN به طور عمده به کیفیت و گستره داده‌های آموزشی وابسته است. این شبکه با استفاده از الگوریتم پس انتشار خطا، وزن نورون‌ها را طی فرآیند یادگیری اصلاح کرده و به تدریج دقت پیش‌بینی را افزایش می‌دهد. ANN در حوزه‌هایی مانند پیش‌بینی، طبقه‌بندی و تحلیل داده‌ها دارای کاربرد گسترده است. در پیش‌بینی مقاومت فشاری

[2] Artificial Neural Networks

بتن، این شبکه قادر به مدل‌سازی روابط پیچیده میان متغیرهای طرح مخلوط بوده و مقاومت نهایی بتن را تخمین می‌زند. با این حال، عملکرد آن به شدت تحت تأثیر حجم داده‌های آموزشی قرار دارد و در شرایط محدود بودن داده‌ها، نتایج حاصل ممکن است با خطا همراه باشد[۳۷].

۲-۲-شبکه (ANFIS)

سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)[3] ترکیبی از قابلیت‌های شبکه عصبی مصنوعی و سیستم‌های فازی است. این روش از منطق فازی برای مدل‌سازی ارتباطات مبهم میان متغیرها بهره می‌گیرد و امکان پردازش داده‌هایی را که دارای عدم قطعیت یا روابط غیرخطی پیچیده هستند فراهم می‌سازد[۳۸]. در ساختار ANFIS، قواعد فازی به صورت شرطی تعریف می‌شوند و نقش پایه تصمیم‌گیری شبکه را ایفا می‌کنند. سپس یک شبکه عصبی مصنوعی با اصلاح وزن این قواعد بر اساس داده‌های آموزشی، دقت پیش‌بینی مدل را افزایش می‌دهد. به عنوان نمونه، در پیش‌بینی مقاومت فشاری بتن، ANFIS ابتدا ارتباط میان پارامترهایی مانند عیار سیمان، نسبت آب به سیمان و مقدار دوده سیلیسی را شناسایی کرده و بر پایه قواعد فازی تحلیل می‌کند. در ادامه، شبکه عصبی وزن متغیرها را تنظیم کرده و مدل نهایی را تقویت می‌نماید. این روش به دلیل توانایی در مدیریت داده‌های محدود و وجود عدم قطعیت، نسبت به شبکه عصبی مصنوعی (ANN) انعطاف‌پذیری بیشتری دارد و بدون نیاز به مراحل متعدد اعتبارسنجی، قادر است مقاومت فشاری بتن را با دقت بالا برآورد کند. با این وجود، پیچیدگی در تنظیم قواعد فازی و زمان بیشتری که برای فرآیند آموزش نیاز دارد، از جمله چالش‌های کاربرد ANFIS محسوب می‌شود[۳۹].

۲-۳-مقایسه شبکه ANN با ANFIS

شبکه ANN زمانی بیشترین کارایی را نشان می‌دهد که داده‌های کافی برای فرآیند آموزش فراهم باشد. این مدل از داده‌های مشاهداتی قبلی برای آموزش شبکه استفاده می‌کند. از این‌رو کمبود اطلاعات و داده‌ها موجب کاهش کارایی سیستم می‌شود. علاوه بر این، به دلیل آنکه شبکه ANN مقادیر وزن خود را به‌صورت تصادفی در نظر می‌گیرد، ممکن است در طول فرآیند آموزش به خوبی آموزش ندیده و بازده لازم را نداشته باشد. در مقابل، شبکه ANFIS برای مدل‌سازی و آموزش به رابطه میان متغیرها متکی است. بنابراین در شرایطی که اطلاعات ناقص یا متناقض باشند، سیستم فازی قادر است خود را با شرایط تطبیق دهد. با توجه به اینکه روش رسمی و استانداردی برای انجام این کار وجود ندارد، این فرآیند معمولاً با استفاده از روش‌های ابتکاری انجام می‌شود و اصطلاحاً دارای قابلیت «خودترمیمی» در فرآیند آموزش است[۴۰]. با این حال، این فرآیند عموماً زمان‌بر بوده و احتمال بروز خطا در آن وجود دارد. به همین دلیل، شبکه ANFIS در شرایطی که پایگاه داده‌ای وسیع (از نظر تعداد داده‌ها) در دسترس نباشد، قادر است عملکرد مناسبی ارائه دهد و این ویژگی به‌عنوان یک مزیت محسوب می‌شود. همچنین، مدل‌سازی شبکه ANN مستلزم انجام سه مرحله شامل آموزش، اعتبارسنجی و تست است، در حالی که در شبکه ANFIS تنها دو مرحله آموزش و تست انجام می‌شود. حذف مرحله اعتبارسنجی در ANFIS سبب کاهش زمان محاسبات شده و این عامل، به‌عنوان برتری دیگر این شبکه مطرح می‌شود[۴۱-۴۳].

۳-روش کار

۳-۱-مدل‌سازی عددی

در این تحقیق، مدل‌سازی عددی شبکه‌های ANN و ANFIS با استفاده از نرم‌افزار MATLAB انجام شد. در مرحله نخست، فرآیند آموزش شبکه‌های ماشین یادگیری با بهره‌گیری از یک پایگاه داده ورودی متشکل از ۱۵۰ طرح مخلوط بتن خودتراکم با مقاومت بالا صورت گرفت. این پایگاه داده شامل هفت مؤلفه اصلی بود که شش مورد از آن‌ها به‌عنوان متغیر ورودی و یک مورد به عنوان متغیر خروجی تعریف شد. متغیرهای ورودی عبارت بودند از: میزان سیمان، مقدار دوده سیلیسی، مقادیر شن، ماسه، آب و روان‌کننده و متغیر خروجی نیز مقاومت فشاری ۲۸ روزه بتن خودتراکم بود. برای ارزیابی عملکرد مدل از پارامترهای ضریب تعیین (R^2)، میانگین مربعات خطا (MSE)، مجذور میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا

[3] Adaptive Neuro-Fuzzy Inference System

UNCORRECTED PROOF

(MAE)، مربع خطای نسبی (RSE)، واریانس تبیین شده (EVS) استفاده شد[۶].

در ادامه، به منظور صحت‌سنجی و بررسی میزان انطباق نتایج حاصل از شبکه ماشین یادگیری با داده‌های آزمایشگاهی، شش طرح مخلوط با مقادیر مختلف وزنی مصالح ولی در محدوده داده‌های ورودی ساخته شد و نتایج به‌دست آمده با یکدیگر مقایسه گردید.

۳-۲-ضریب تعیین

ضریب تعیین که با R^2 نمایش داده می‌شود، مقایسه‌ای بین مقادیر واقعی (آزمایشگاهی) و پیش‌بینی (محاسباتی) است که می‌تواند با استفاده از روش تجزیه و برازش بررسی شود. این ضریب بین صفر تا یک متغیر است که در بهترین حالت مقدار آن یک است و این حالت مربوط به زمانی است که در آن مقادیر محاسبه شده دقیقاً مشابه مقادیر واقعی باشد. اگر مقدار R^2 برابر یک باشد یعنی هیچ خطایی وجود ندارد. این ضریب از رابطه شماره ۱ محاسبه می‌شود[۱۸]:

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(x_{imeas} - x_{ipred})^2}{\sum_{i=1}^{n}(x_{imeas} - x)^2} \qquad (۱)$$

$x_{imeas}, x_{ipred}, \overline{x}$ به ترتیب برابر با مقدار میانگین متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده می‌باشد.

۳-۳-میانگین مربعات خطا

یکی از روش‌های برآورد میزان خطا در شبکه ماشین یادگیری که در واقع اختلاف بین مقادیر واقعی (آزمایشگاهی) و نتایج محاسباتی (پیش‌بینی) شده می‌باشد، میانگین مربعات خطا نامیده می‌شود. میانگین مربعات خطاب یا به اختصار MSE عمدتاً با مقدار مثبت بدست می‌آید (صفر نیست) این شاخص هرچقدر به صفر نزدیک‌تر باشد، نشان دهنده میزان کمتر خطا می‌باشد. این معیار از طریق رابطه شماره ۲ محاسبه می‌شود[۱۸]:

$$MSE = \frac{1}{n} \times \sum_{i=1}^{n}\left[(x_{imeas} - x_{ipred})^2\right] \qquad (۲)$$

x_{imeas}, x_{ipred}, n به ترتیب برابر با تعداد متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده می‌باشد.

۳-۴-ریشه میانگین مربعات خطا

ریشه‌ی میانگین مربعات خطا (RMSE) نیز یک تابع متناسب با تابع هدف است و در واقع مجذور شاخص میانگین مربعات خطا می‌باشد. این شاخص به عنوان معیاری از خطای مطلق بین متغیر شبیه‌سازی شده است. مقدار این شاخص بین صفر تا بی‌نهایت متغیر است. هر چه مقدار این شاخص کمتر باشد شبیه‌سازی بهتری صورت گرفته است. این معیار از طریق رابطه شماره ۳ محاسبه می‌شود[۱۸]:

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^{n}\left[(x_{imeas} - x_{ipred})^2\right]} \qquad (۳)$$

x_{imeas}, x_{ipred}, n به ترتیب برابر با تعداد متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده می‌باشد.

۳-۵- میانگین قدرمطلق خطا

میانگین قدر مطلق خطا بیانگر میانگین اختلاف بین مقدار محاسبه (پیش‌بینی) شده و مقدار واقعی (آزمایشگاهی) در تمام موارد آزمایش صورت گرفته می‌باشد. از این شاخص بعنوان خطای متوسط پیش‌بینی شده نیز یاد می‌شود. هر چه میزان این شاخص کمتر باشد (نزدیک صفر) پیش‌بینی شبکه ماشین یادگیری دقیق‌تر صورت گرفته. این معیار از طریق رابطه شماره ۴ محاسبه می‌شود[۱۸]:

$$MAE = \frac{1}{n} \times \sum_{i=1}^{n}\left|x_{imeas} - x_{ipred}\right| \qquad (٤)$$

x_{imeas}, x_{ipred}, n به ترتیب برابر با تعداد متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده می‌باشد.

۳-۶- مربع خطای نسبی

UNCORRECTED PROOF

مربع خطای نسبی یا RSE نشان‌دهنده‌ی عدم تناسب مدل محاسباتی با داده‌های واقعی است. به عبارت ساده‌تر، اگر مقدار RSE به صفر نزدیک باشد، مدل محاسباتی تطابق خوبی با داده‌های آزمایشگاهی دارد. این معیار از طریق رابطه شماره ۵ محاسبه می‌شود[۱۸]:

$$RSE = \frac{\sum_{i=1}^{n}(x_{ipred} - x_{imeas})^2}{\sum_{i=1}^{n}(\bar{x}_{meas} - x_{imeas})^2} \qquad (۵)$$

$x_{imeas}, x_{ipred}, \bar{x}$ به ترتیب برابر با مقدار میانگین متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده می‌باشد.

۳-۷- واریانس تبیین شده

در علم آمار واریانس تبیین شده به تناسب بین مدل محاسباتی برای تغییرات (پراکندگی) با مدل واقعی یک مجموعه معین گفته می‌شود. بهترین مقدار ممکن برای این معیار عدد یک است و مقادیر پایین‌تر دارای دقت کمتری می‌باشد. این معیار از طریق رابطه شماره ۶ محاسبه می‌شود[۱۸]:

$$EVS = 1 - \frac{Var\{x_{imeas} - x_{ipred}\}}{Var\{x_{imeas}\}} \qquad (۶)$$

$x_{imeas}, x_{ipred}, \bar{x}$ به ترتیب برابر با مقدار میانگین متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده می‌باشد.

۴-مصالح مصرفی

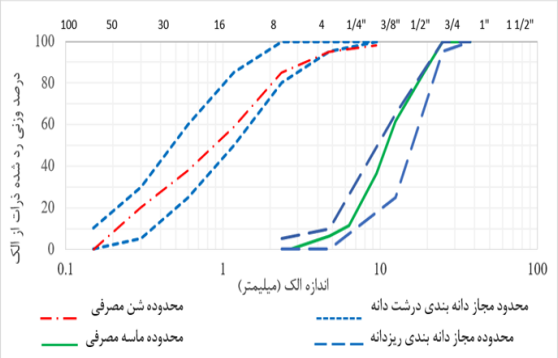
۴-۱-سنگدانه

سنگدانه مورد استفاده جهت ساخت بتن در این تحقیق، مخلوط نخودی و بادامی با حداکثر اندازه ۱۹ میلیمتر بود. مشخصات فیزیکی این سنگدانه مطابق با شرح جدول شماره ۱ می‌باشد. مدول نرمی ماسه مورد استفاده مطابق با استاندارد ASTM-C136 نیز ۲/۹ بدست آمد.

جدول ۱ مشخصات شن و ماسه مصرفی

نوع سنگدانه	حداکثر قطر سنگدانه	مدول نرمی	وزن مخصوص خشک	جذب آب
	mm		kg/m^3	٪
ماسه	۴/۷۵	۲/۹	۱۶۵۰	۱/۵۷
شن	۱۹	-	۱۳۵۰	۲/۳

در این تحقیق دانه‌بندی سنگدانه و طبقه‌بندی الک‌های شماره‌بندی شده، مطابق با استاندارد ASTM-C136 انجام و در شکل شماره ۱ نمایش داده شده است.



شکل ۲ دانه‌بندی سنگدانه و مقایسه با ASTM-C33

۴-۲-سیمان

سیمان مصرفی در این تحقیق، از نوع سیمان تیپ ۲ سپاهان می‌باشد. چگالی این سیمان ۳/۱۰ gr/cm^3 است. آنالیز شیمیایی این سیمان در جدول شماره ۲ که منطبق بر شناسه فنی شرکت سازنده این محصول می‌باشد ضمیمه شده است[۳۱].

جدول ۲ ساختار شیمیایی سیمان مصرفی

SiO_2	٪ ۲/۹۰
AL_2O_3	٪ ۴/۷۰
FE_2O_3	٪ ۳/۹۵
MgO	٪ ۲/۲۰
SO_3	٪ ۱/۳۵
CaO	٪ ۶۰/۴۶
C_3S	٪ ۲۲/۶۸

۴-۴-فوق روان‌کننده

UNCORRECTED PROOF

از آنجا که دوده سیلیسی خاصیت جاذب آب دارد، لازم است نسبت آب به سیمان در مخلوط افزایش یابد. افزایش این نسبت می‌تواند موجب کاهش مقاومت بتن شود. در صورتی که اجزای تشکیل دهنده بتن به‌طور کامل و یکنواخت مخلوط نشوند، ذرات دوده سیلیسی دچار کلوخه‌شدگی گردیده و کیفیت و دوام بتن را تحت تأثیر قرار می‌دهد. به همین دلیل استفاده از مواد کاهنده آب، مانند انواع روان‌کننده‌ها، برای حفظ روانی و کیفیت بتن ضروری است[۳۵]. در این تحقیق به منظور دستیابی به توزیع یکنواخت افزودنی و حفظ روانی بتن، از فوق روان‌کننده PC5000 با پایه پلی‌کربوکسیلات استفاده شد. مشخصات فیزیکی این محصول مطابق جدول شماره ۳ است.

جدول ۳ مشخصات فیزیکی فوق روان کننده مصرفی [۲۹]

وزن مخصوص	استاندارد	یون کلر	pH	حالت فیزیکی	مقدار جایگزینی
۱/۱ gr/cm3	ASTM C1017	٪ ۰/۱	۵/۵۸	مایع	٪ ۰/۱ تا ۳ وزن سیمان

۴-۵-دوده سیلیسی

دوده سیلیسی یک ماده پوزولانی با ساختار آمورف است که به‌عنوان محصول جانبی در فرآیند تولید آلیاژهای سیلیکون و فروسیلیس در کوره‌های قوس الکتریکی به‌دست می‌آید. این ماده دارای درصد بالایی از دی‌اکسید سیلیسیوم بوده و سطح مقطع ذرات آن به شکل کروی است. دوده سیلیسی با الزامات مندرج در استاندارد ASTM-C1240 انطباق کامل دارد. مشخصات کامل فیزیکی و شیمیایی این ماده در جداول شماره ۴ و ۵ ارائه شده است[۱۶].

جدول ۴ مشخصات فیزیکی دوده سیلیس مصرفی

پودر خاکستری رنگ	حالت و رنگ
کروی غیرکریستاله	ساختار
۲/۱	وزن مخصوص (gr/cm3)
خنثی	pH
µ ۱۵	حداکثر اندازه اسمی
# ۸۰۰	اندازه اسمی (مش)

جدول ۵ ساختار شیمیایی دوده سیلیس مصرفی

اکسید آلومینیوم	AL_2O_3	۱/۳۲
اکسید آهن	Fe_2O_3	۰/۳۷
اکسید منیزیم	Mgo	۰/۹۷
اکسید سیلیس	SiO_2	۹۴/۵
اکسید کلسیم	CaO	۰/۵۴
اکسید پتاسیم	K_2O	۱
اکسید سدیم	Na_2O	۰/۳
کربن	C	۰/۳
سیلیسیم کاربید	SiC	۰/۵

۵-ساخت پایگاه داده

در این تحقیق، به منظور جلوگیری از کاهش کیفیت فرآیند آموزش و افت دقت پیش‌بینی ماشین یادگیری، از به‌کارگیری داده‌های حاصل از تحقیقات پیشین اجتناب شد. زیرا تنوع در شرایط آزمایشگاهی، ویژگی‌های مصالح مصرفی می‌تواند بر مقاومت فشاری بتن اثرگذار باشد. این تفاوت‌ها شامل دانه‌بندی سنگدانه‌ها، نوع و کیفیت سنگدانه‌ها از نظر شکل ظاهری، احتمال خطا در نتایج ناشی از عدم کالیبراسیون دستگاه‌های اندازه‌گیری و تفاوت در روش‌های مراقبت و عمل‌آوری نمونه‌های بتنی است. بر این اساس، هرچه میزان پراکندگی بین طرح‌های موجود در پایگاه داده کمتر باشد، احتمال بروز خطا در شبکه کاهش یافته و دقت پیش‌بینی نتایج توسط ماشین یادگیری افزایش می‌یابد[۱۲,۷].

به‌منظور آغاز فرآیند آموزش و آزمون شبکه ماشین یادگیری، پایگاه داده‌ای شامل ۱۵۰ طرح مخلوط بتن خودتراکم حاوی دوده سیلیسی تهیه گردید که اطلاعاتی از جمله اوزان مصالح مصرفی و مقاومت فشاری ۲۸ روزه نمونه‌های مکعبی با ابعاد ۱۵ سانتی‌متر را شامل می‌شد. دامنه تغییرات حداقل و حداکثر مصالح مصرفی این پایگاه داده در جدول شماره ۶ ارائه شده است. حداقل و حداکثر مقادیر مصالح بر اساس استانداردهای معتبر، داده‌های پژوهش‌های پیشین و نتایج آزمایشگاهی تعیین شد تا هم دامنه متداول بتن خودتراکم پوشش داده شود و هم از ورود داده‌های غیرواقعی یا خارج از محدوده پایدار جلوگیری گردد. این پایگاه داده توسط نرم‌افزار MTLAB نسخه R2020 بوسیله رایانه دارای پردازنده intel-4810MQ و ۲۰ گیگابایت حافظه RAM ddr3 بارگذاری شد.

UNCORRECTED PROOF

برای ساخت نمونه‌های بتن، تمامی سنگدانه‌ها به طور کامل خشک شدند تا آب موجود در حفرات آن‌ها تبخیر گردد. سپس شن، ماسه و نیمی از آب درون مخلوط‌کن ریخته شده و به مدت ۶۰ ثانیه مخلوط شدند. پس از آن، سیمان و دوده سیلیسی اضافه و عملیات اختلاط به مدت ۶۰ ثانیه دیگر ادامه یافت. در مرحله بعد، آب باقیمانده و محلول فوق روان‌کننده به آرامی به مخلوط اضافه گردید و کلیه مصالح به مدت ۳ دقیقه با یکدیگر مخلوط شدند. در پایان، آزمایش جریان اسلامپ به روش T_{50} بر روی کلیه طرح‌های مخلوط انجام گرفت. آزمایش جریان اسلامپ بر اساس استاندارد ASTM-C1611 و آزمایش مقاومت فشاری بر اساس استاندارد BS-EN-12350-3 صورت پذیرفت. پس از قالب‌گیری، نمونه‌ها به مدت ۲۸ روز در حوضچه آب با دمای ۳±۲۳ درجه سانتی‌گراد عمل‌آوری شدند.

جدول ۶ گستره مصالح مصرفی در پایگاه داده ورودی جهت فرآیند آموزش و تست شبکه ماشین یادگیری

ردیف	پارامتر	متغیر	حداقل	حداکثر	محدوده تغییرات	مقدار میانگین
۱	X_1	سیمان	۳۰۰	۵۸۵	۲۸۵	۴۴۲
۲	X_2	ماسه	۵۲۰	۱۰۴۰	۵۲۰	۷۸۰
۳	X_3	شن	۵۹۰	۱۲۰۰	۶۱۰	۸۹۵
۴	X_4	دوده سیلیس	۱۰	۱۸۰	۱۴۰	۸۰
۵	X_5	آب	۱۲۰	۲۴۰	۱۲۰	۱۸۰
۶	X_6	فوق روان‌کننده	۱	۲۵	۲۶	۱۳
۷	Y	مقاومت فشاری	۲۵	۶۳	۳۸	۴۴

۶-مدل‌سازی عددی

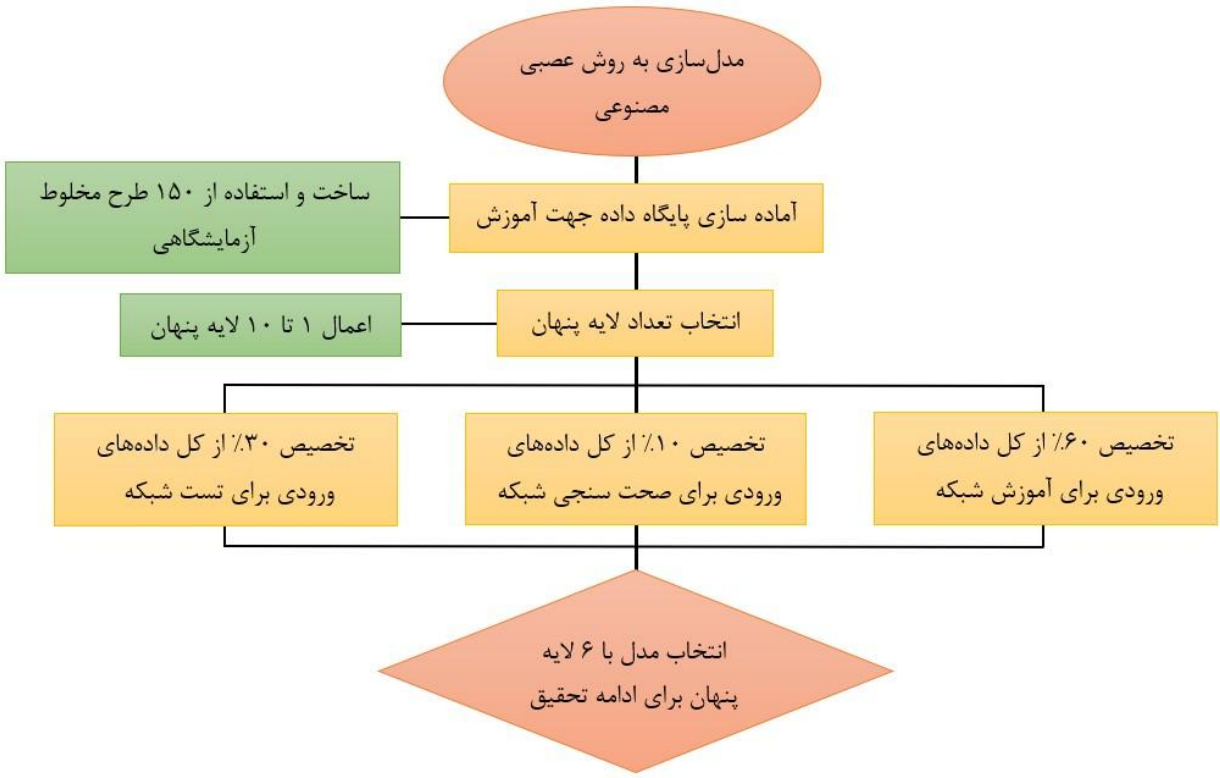
۶-۱-شبکه ANN

برای مدل‌سازی شبکه عصبی مصنوعی (ANN) از ساختار پرسپترون چندلایه استفاده شد. تعداد لایه‌های پنهان بین ۱ تا ۱۰ متغیر در نظر گرفته شد. در لایه‌های پنهان از تابع انتقال تانژانت سیگموئید و در لایه خروجی از تابع انتقال خطی بهره گرفته شد. فرآیند آموزش شبکه با الگوریتم Levenberg–Marquardt backpropagation به دلیل سرعت بالا و دقت مناسب انتخاب گردید. مجموعه داده‌ها به سه بخش شامل ۶۰٪ برای آموزش، ۱۰٪ برای اعتبارسنجی و ۳۰٪ برای آزمون تقسیم‌بندی گردید و وزن‌ها و بایاس‌ها به‌صورت تصادفی انتخاب شدند. نتایج حاصل که در جدول شماره ۷ نشان داده شده است، بیانگر آن است که شبکه مدل ANN6 با ۶ لایه پنهان در مقایسه با سایر پیکربندی‌های ایجادشده، بالاترین دقت را در پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی دوده سیلیسی ارائه کرده است.

جدول ۷ معیارهای ارزیابی مدل شبکه ANN در مرحله آزمایش و تست

نام مدل	R^2	RMSE	MSE	MAE	RSE	EVS	TIME (S)
ANN1	۰/۷۴۰۴	۳/۵۶۴۷	۳۹/۵۳۴۲	۴/۹۸۸۷	۰/۸۵۶۵	۰/۱۰۳۲	۶/۵
ANN2	۰/۷۵۴۸	۳/۴۸۰۱	۳۷/۳۹۲۷	۴/۷۵۶۹	۰/۸۰۲۹	۰/۳۴۱۱	۷/۲
ANN3	۰/۷۰۱۶	۳/۸۱۱۰	۱۹/۵۰۴۷	۳/۵۸۲۲	۰/۴۲۵۱	۰/۳۴۹۹	۸/۴
ANN4	۰/۷۳۹۸	۴/۰۹۹۲	۲۵/۳۹۸۴	۴/۰۳۰۱	۰/۴۱۷۱	۰/۳۵۵۰	۹/۳
ANN5	۰/۴۱۳۶	۴/۹۵۳۸	۳۶/۲۳۸۲	۴/۵۷۸۴	۰/۹۱۸۴	۰/۰۵۳۷	۱۲/۴
ANN6	۰/۷۸۴۵	۳/۲۷۱۸	۱۴/۱۹۵۲	۲/۶۱۱۳	۰/۳۱۸۲	۰/۴۶۹۲	۱۵/۶
ANN7	۰/۶۵۷۵	۴/۲۲۷۸	۲۸/۹۱۵۰	۴/۱۹۷۷	۰/۵۸۷۷	۰/۲۴۴۲	۱۸/۹
ANN8	۰/۷۵۵۷	۳/۶۷۷۱	۲۵/۷۰۰۲	۳/۹۵۸۳	۰/۴۹۲۵	۰/۳۳۳۵	۲۰/۳
ANN9	۰/۶۲۴۹	۴/۱۶۱۶	۲۰/۳۶۴۱	۳/۷۰۱۸	۰/۴۶۷۸	۰/۳۵۱۱	۲۵/۴
ANN10	۰/۷۳۰۴	۳/۸۹۳۴	۳۵/۵۳۵۳	۵/۰۹۹۶	۰/۶۷۰۴	۰/۴۵۸۵	۳۰/۳

UNCORRECTED PROOF



شکل ۳ فلوچارت مدل‌سازی به روش عصبی مصنوعی جهت پیش‌بینی مقاومت فشاری [ماخذ: نگارندگان]

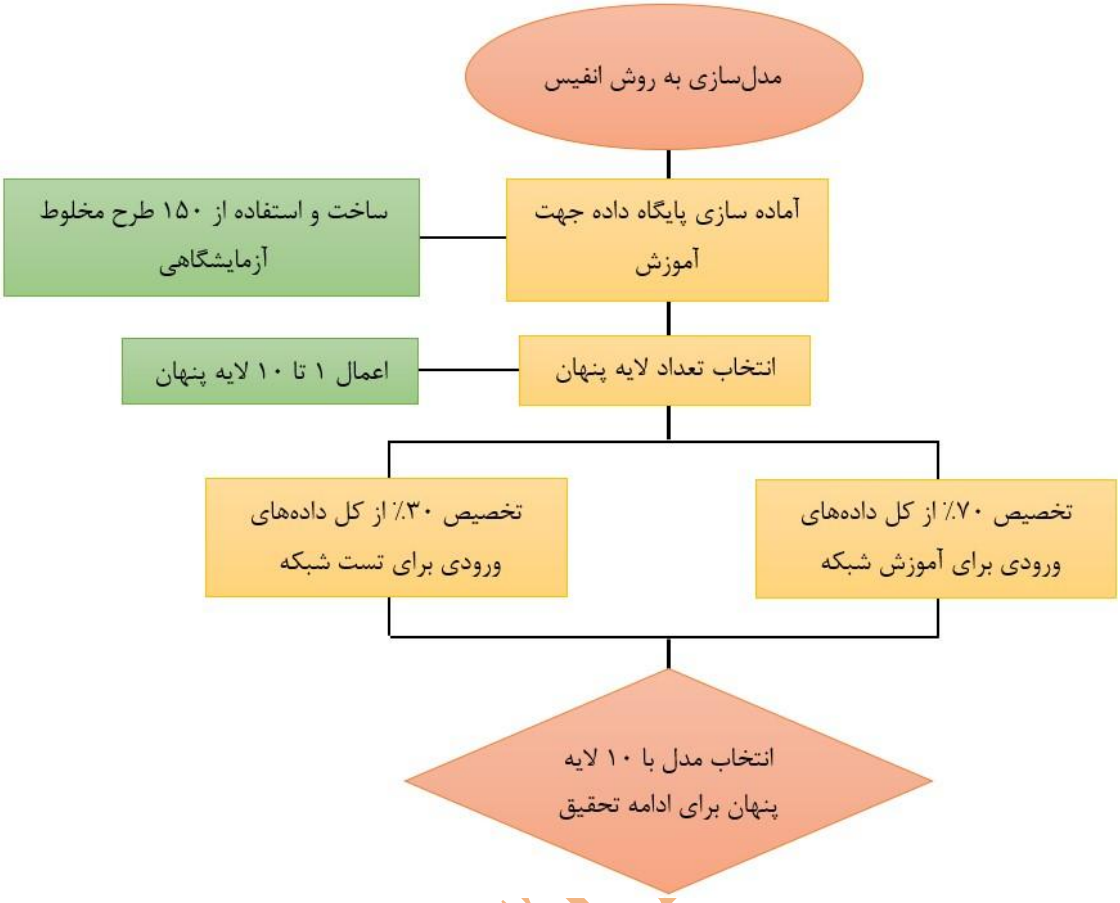
۶-۲-شبکه ANFIS

برای مدل‌سازی شبکه ANFIS از الگوریتم تاکاگی-سوگنو با روش خوشه‌بندی کاهشی و با ۱ تا ۱۰ لایه پنهان استفاده شد. توابع عضویت متغیرهای ورودی از نوع Gaussian انتخاب گردید. تعداد و پارامترهای توابع عضویت با استفاده از روش آموزش ترکیبی (Hybrid Learning Algorithm) شامل الگوریتم کمینه‌سازی مربعات خطا (Least Squares Estimation) در مرحله گذر رو به جلو و الگوریتم پس‌انتشار خطا (Backpropagation) در مرحله گذر رو به عقب بهینه‌سازی شدند. همچنین از مجموع کل پایگاه داده، ۷۰٪ آن برای آموزش ۳۰٪ برای تست مدل استفاده گردید. نتایج فرآیند آموزش این شبکه به شرح جدول شماره ۸ می‌باشد[۶]. طبق نتایج بدست آمده مشخص گردید که مدل با ۹ و ۱۰ لایه پنهان دارای بیشترین دقت در پیش‌بینی مقاومت فشاری می‌باشد. اما با اندکی اختلاف مدل با ۱۰ لایه پنهان (ANFIS10) بدلیل میزان خطای کمتر بعنوان مدل بهینه برای ادامه روند تحقیق انتخاب شد.

جدول ۸ معیارهای ارزیابی مدل شبکه ANFIS در مرحله آزمایش و تست

نام مدل	R^2	RMSE	MSE	MAE	RSE	EVS	TIME (S)
ANFIS1	۰/۷۸۲۵	۴/۴۶۱۴	۲۰/۵۰۲۱	۳/۴۳۸۰	۰/۲۳۸۱	۰/۵۳۳۵	۱/۶
ANFIS2	۰/۷۷۱۹	۳/۸۷۹۷	۱۸/۴۱۱۰	۳/۳۰۹۶	۰/۲۹۶۴	۰/۴۹۴۸	۲/۵
ANFIS3	۰/۷۱۴۸	۵/۲۶۳۶	۳۰/۴۵۶۰	۴/۴۶۵۹	۰/۳۳۳۱	۰/۴۶۲۹	۳/۳
ANFIS4	۰/۴۹۷۶	۶/۳۴۲۳	۴۱/۶۵۹۷	۵/۰۸۹۴	۰/۵۵۲۹	۰/۲۷۰۰	۴/۷
ANFIS5	۰/۵۴۳۶	۵/۴۵۵۳	۴۶/۴۱۵۰	۵/۲۲۰۱	۰/۷۵۶۳	۰/۳۰۹۹	۵/۵
ANFIS6	۰/۴۳۳۱	۷/۳۴۹۴	۱۰۸/۲۱۵۴	۸/۷۱۰۹	۱/۲۰۶۸	۰/۲۴۶۱	۶/۸
ANFIS7	۰/۳۱۶۸	۷/۵۶۸۲	۵۴/۰۸۹۷	۶/۱۱۸۳	۰/۶۸۵۵	۰/۱۷۳۱	۷/۷
ANFIS8	۰/۴۵۸۶	۶/۰۵۱۹	۱۰۳/۳۱۷۵	۸/۹۷۰۸	۱/۶۲۲۷	۰/۲۵۷۰	۹/۱
ANFIS9	۰/۸۷۱۴	۳/۲۱۸۷	۲۴/۲۸۷۴	۴/۲۵۶۴	۰/۳۲۰۴	۰/۶۴۱۲	۱۰/۳
ANFIS10	۰/۸۶۴۹	۳/۳۶۸۵	۱۷/۶۵۵۶	۳/۳۹۵۴	۰/۲۲۳۴	۰/۶۳۱۹	۱۱/۲

UNCORRECTED



شکل ۴ فلوچارت مدل‌سازی به روش انفیس جهت پیش‌بینی مقاومت فشاری [ماخذ: نگارندگان]

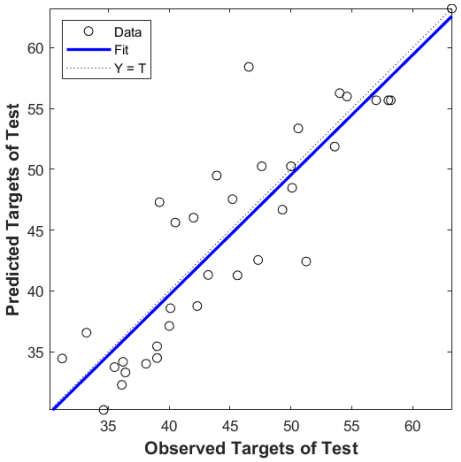
۶-۳-مقایسه نتایج مدل‌سازی عددی

به‌منظور انتخاب بهینه‌ترین مدل شبکه‌های ANN و ANFIS در پیش‌بینی مقاومت فشاری بتن خودتراکم با مقاومت بالا، مقایسه‌ای میان نتایج حاصل از مدل‌ها مطابق جدول شماره ۹ انجام شد. نتایج این مقایسه نشان داد که مدل ANFIS10 از دقت بالاتری نسبت به مدل ANN6 برخوردار است. شایان ذکر است که در نمودارهای تعیین، انطباق کامل خط رگرسیون مقاومت فشاری واقعی و محاسباتی بیانگر دقت بالای مدل در پیش‌بینی نتایج محسوب می‌شود. شکل‌های شماره ۶ تا ۹ میزان همبستگی متغیرها را در فرآیند آموزش و آزمون شبکه‌های ANN و ANFIS در محیط نرم‌افزار MATLAB نمایش می‌دهند.

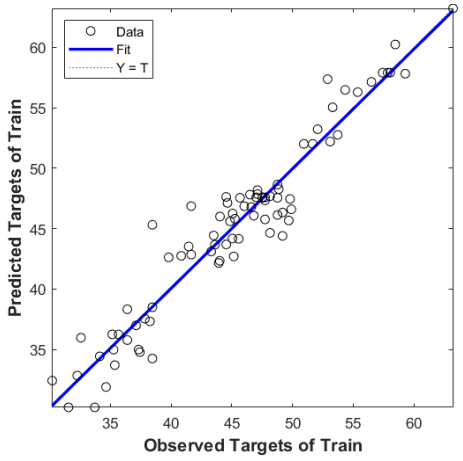
جدول ۹ مقایسه نتایج بدست آمده از مدل منتخب ANN و ANFIS

مدل	مرحله	R^2	RMSE	MSE	MAE	RSE	EVS
ANN6	آموزش	۰/۷۵۹۱	۳/۵۵۶۸	۱۹/۷۳۳۷	۳/۶۳۵۱	۰/۳۸۷۲	۰/۴۴۱۴
	اعتبارسنجی	۰/۷۶۴۴	۳/۸۹۱۳	۳۹/۶۶۷۴	۴/۲۴۴۱	۰/۷۴۰۸	۰/۲۵۳۸
	تست	۰/۷۶۸۰	۳/۸۷۸۷	۲۰/۰۴۰۲	۳/۸۱۳۲	۰/۳۲۷۸	۰/۴۳۵۰
ANFIS10	آموزش	۰/۹۲۳۹	۲/۰۲۵۸	۴/۲۵۰۲	۱/۵۴۶۱	۰/۰۸۰۹	۰/۷۱۵۶
	تست	۰/۸۶۴۹	۳/۳۶۸۵	۱۷/۶۵۵۶	۳/۳۹۵۴	۰/۲۲۳۴	۰/۶۳۱۹

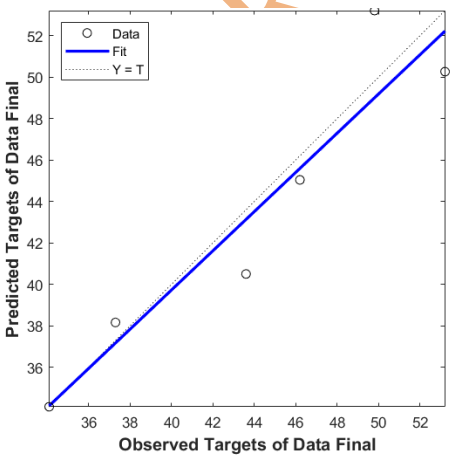
UNCORRECTED



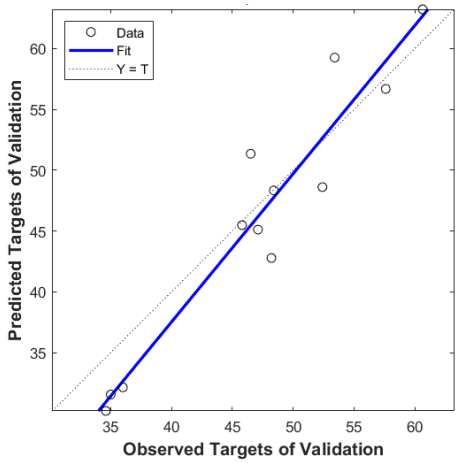
شکل ۶ نمودار همبستگی متغیرها در مدل ANFIS (فرآیند آموزش)



شکل ۵ نمودار همبستگی متغیرها در مدل ANN (فرآیند آموزش)



شکل ۸ نمودار همبستگی متغیرها در مدل ANFIS (فرآیند تست شبکه)



شکل ۷ نمودار همبستگی متغیرها در مدل ANN (فرآیند تست شبکه)

۷-صحت‌سنجی

۷-۱-برنامه آزمایشگاهی

به‌منظور کنترل و ارزیابی دقت نتایج حاصل از شبکه ماشین یادگیری، شش طرح مخلوط بتن با مقادیر وزنی متفاوت مصالح ساخته شد. برای اطمینان از صحت نتایج آزمایشگاهی، از هر طرح مخلوط دو نمونه تهیه گردید و میانگین مقاومت فشاری آن‌ها به‌عنوان مقاومت نهایی بتن منظور شد. تمامی نمونه‌ها به‌صورت مکعبی با ابعاد ۱۵ سانتی‌متر ساخته شده و در سن ۲۸ روزه تحت آزمایش مقاومت فشاری قرار گرفتند. کلیه طرح‌های مخلوط دارای عیار سیمان مصرفی بین ۳۵۰ kg/m^3 تا ۵۰۰ دوده سیلیسی به میزان ۵٪ تا ۲۰٪ وزنی سیمان و نسبت آب به سیمان بین ۰/۳۵ تا ۰/۴۵ در نظر گرفته شدند. همچنین، به منظور حفظ کارایی بتن خودتراکم، از فوق روان‌کننده بر پایه کربوکسیلات به میزان ۲٪ تا ۳٪ وزنی سیمان استفاده شد. مقادیر دقیق طرح‌های مخلوط به کار رفته در این تحقیق در جدول شماره ۱۰ ارائه شده است. لازم به ذکر است که طرح‌های مخلوط مذکور صرفاً با هدف راستی آزمایی نتایج شبکه ماشین یادگیری در تخمین مقاومت فشاری ۲۸ روزه بتن تهیه شده و بر مبنای هیچ استاندارد خاصی طراحی نشده‌اند. جدول شماره ۱۰ شامل اوزان مصرفی مصالح، مقادیر جریان اسلامپ و مقاومت فشاری طرح‌ها است.

بر اساس نتایج به‌دست‌آمده، یکی از دلایل افزایش مقاومت فشاری بتن، کاهش نفوذپذیری آن بر اثر استفاده از دوده سیلیسی است. افزودن دوده سیلیسی به مخلوط بتن موجب کاهش فضای متخلخل بین سنگدانه‌ها شده و در نتیجه مقاومت فشاری افزایش می‌یابد. همچنین، دوده سیلیس به دلیل دارا بودن مقدار قابل توجهی سیلیس در ساختار خود، سبب بهبود چسبندگی بین خمیره سیمان و سنگدانه‌ها در بتن می‌شود. یافته‌های سایر پژوهش‌ها نیز این موضوع را تأیید می‌کنند[۱۲,۳,۱]. از سوی دیگر، افزایش میزان دوده سیلیس در بتن موجب کاهش جریان اسلامپ بتن تازه می‌گردد، زیرا این ماده بخشی از آب موجود در مخلوط را جذب می‌کند. در چنین شرایطی، لازم است نسبت آب به سیمان و مقدار فوق روان‌کننده در طرح مخلوط بتن به‌طور متناسب اصلاح شود.

جدول ۱۰ طرح مخلوط، جریان اسلامپ و مقاومت فشاری ۲۸ روزه نمونه آزمایشگاهی جهت صحت سنجی نتایج

نام طرح مخلوط	سیمان	شن	ماسه	دوده سیلیس	آب	فوق روان کننده	جریان اسلامپ		مقاومت فشاری ۲۸ روزه		
	Kg/m^3	Kg/m^3	Kg/m^3	Kg/m^3	lit/m^3	kg/m^3	میانگین قطر mm	زمان Sec	نمونه اول MPa	نمونه دوم MPa	میانگین
SCC1	۳۰۰	۸۸۰	۹۸۰	۴۵	۱۳۵	۸	۶۱	۳/۶	۳۴/۸	۳۳/۴	۳۴/۱
SCC2	۳۵۰	۹۴۰	۹۲۰	۵۰	۱۶۰	۱۳	۶۴	۳/۲	۳۷/۹	۳۶/۷	۳۷/۳
SCC3	۴۰۰	۹۱۰	۸۲۰	۸۰	۲۰۰	۱۲	۶۵	۳/۲	۴۴/۴	۴۲/۸	۴۳/۶
SCC4	۴۵۰	۹۵۰	۸۳۰	۴۵	۲۱۰	۱۲	۶۳	۳/۴	۴۷/۳	۴۵/۱	۴۶/۲
SCC5	۵۰۰	۹۳۰	۷۵۰	۷۵	۲۲۰	۱۲	۶۸	۲/۹	۵۰/۷	۴۸/۹	۴۹/۸
SCC6	۵۵۰	۹۵۰	۷۸۰	۷۰	۲۳۰	۱۴	۶۵	۳/۱	۵۴	۵۲/۴	۵۳/۲



شکل ۹ مستنداتی از برخی آزمایشات این تحقیق

به ترتیب از چپ به راست: آزمایش جریان اسلامپ، آزمایش مقاومت فشاری و برخی از نمونه‌های شکسته شده

۷-۲-نتایج مدل‌سازی عددی

برای محاسبه و پیش‌بینی مقاومت فشاری طرح مخلوط‌های SCC-1,2,3,4,5,6 از مدل‌های ANN6 و ANFIS10 استفاده شد. بدین ترتیب مقادیر سیمان، شن، ماسه، آب، فوق‌روان‌کننده و دوده سیلیس بصورت پارامتری از X_1 تا X_6 وارد نرم‌افزار گردید. میزان مقاومت فشاری ۲۸ روزه محاسبه شده توسط شبکه ماشین یادگیری به شرح جدول شماره ۱۱ می‌باشد.

طبق نتایج بدست آمده میزان ضریب تعیین (R^2) مدل ANN6 در مقایسه با مدل ANFIS10، ۹۵٪ کاهش یافته است. همانطور که قبلاً ذکر شد هر چه میزان این ضریب به عدد یک نزدیک‌تر باشد دقت محاسبه ماشین یادگیری بیشتر خواهد بود. در ادامه میزان مجذور میانگین مربعات خطا (RMSE) در مدل ANFIS10، به میزان ۵۲٪ کمتر از مدل ANN6 تعیین شد. لازم به ذکر است که هر چه میزان این شاخص کمتر باشد یعنی محاسبه مقاومت فشاری با دقت بیشتری انجام گردیده. پارامتر بعدی مربوط به میانگین مربعات خطا (MSE) است که هر چه این عبارت به صفر نزدیک‌تر باشد بیانگر آن است که مدل عددی با خطای کمتری مواجه شده. میانگین مربعات خطا در مدل

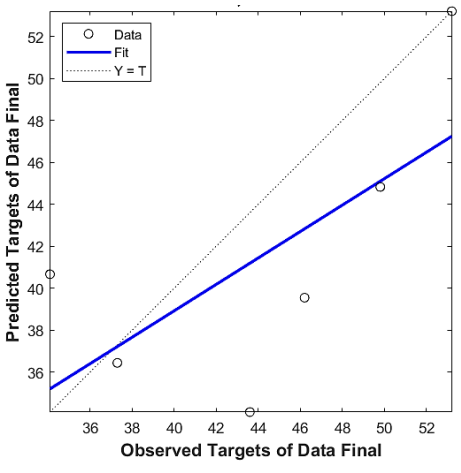
UNCORRECTED PROOF

ANN6، ۸۴٪ بیشتر از مدل ANFIS10 می‌باشد. همچنین میانگین قدر مطلق خطا (MAE) بیانگر میانگین اختلاف بین میزان مقاومت فشاری محاسبه شده توسط شبکه ماشین یادگیری با مقاومت فشاری واقعی (آزمایشگاه) می‌باشد. بطوریکه هر چه میزان این شاخص کمتر باشد، محاسبه شبکه ماشین یادگیری دقیق‌تر صورت گرفته است. نتایج نشان می‌دهد که میانگین قدر مطلق خطا در مدل ANN6 نسبت به مدل ANFIS10، ۵۹٪ کاهش یافته است. مربع خطای نسبی یا (RSE) بیانگر عدم تناسب مدل ماشین یادگیری با مدل آزمایشگاهی می‌باشد. بطوریکه هر چه این میزان به صفر نزدیک‌تر باشد تطابق بهتری بین نتایج مدل‌سازی ماشین یادگیری با نتایج آزمایشگاهی صورت گرفته. نتایج نشان می‌دهد که مدل ANFIS10 تا ۸۴٪ عملکرد بهتری در مقایسه با مدل ANN6 در این بخش داشته است. میزان انحراف معیار یکی از شاخص‌های پراکندگی است که نشان می‌دهد به طور میانگین نتایج مدل‌سازی ماشین یادگیری چه میزان از متوسط نتایج آزمایشگاهی فاصله دارند. اگر انحراف معیار مجموعه‌ای از داده‌ها نزدیک به عدد یک باشند، نشانه آن است که داده‌ها نزدیک به میانگین هستند و پراکندگی اندکی دارند. نتایج این تحقیق نشان داد که مدل ANFIS10 در مقایسه با مدل ANN6 بطور نسبی تا دو برابر از واریانس یا پراکندگی کمتری برخوردار است.

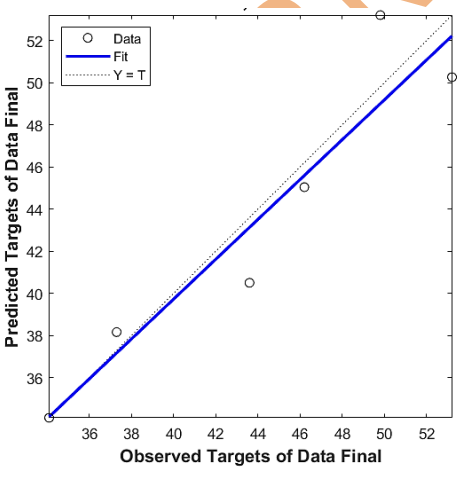
جدول ۱۱ معیارهای ارزیابی مدل‌های منتخب شبکه ANN و ANFIS در مرحله صحت سنجی

MODEL	R^2	RMSE	MSE	MAE	RSE	EVS
ANN6	۰/۴۵۴۰۸	۶/۰۲۷۲	۳۳/۸۴۴۷	۴/۷۵۷۸	۰/۷۶۲۹۲	۰/۲۱۶۲۹
ANFIS10	۰/۸۸۹۱۴	۲/۷۱۶	۵/۳۱۸۸	۱/۹۱۱۲	۰/۱۱۹۸۹	۰/۶۶۱۶۳

شکل شماره ۱۰ مربوط به نمودار همبستگی بین مقاومت فشاری نمونه آزمایشگاهی با مدل ANN6 و شکل شماره ۱۱ مربوط مدل ANFIS10 می‌باشد. طبق نتایج بدست آمده مشخص گردید که مدل ANFIS10 از همگرایی و دقت بیشتری در پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی دوده سیلیسی برخوردار می‌باشد. مطابق شکل شماره ۱۰ و ۱۱ اگر خط رگرسیون از تمام نقاط بگذرد توانایی معرفی همه متغیرها را دارد و هرچه از نقاط دورتر باشد نشان دهنده کاهش دقت مدل عددی می‌باشد[۱۸].



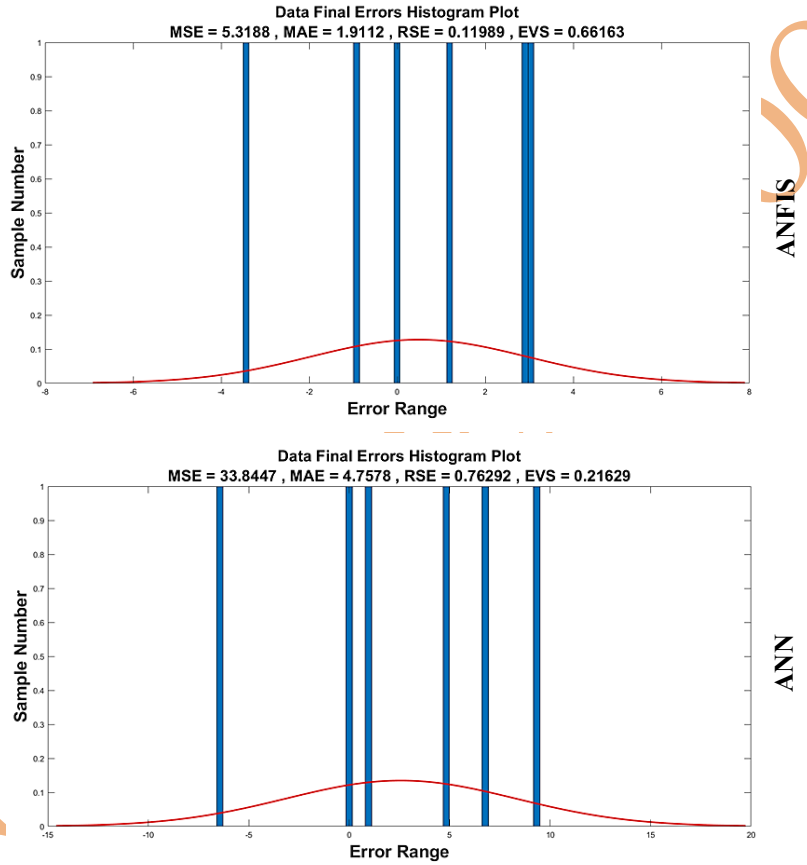
شکل ۱۰ نمودار همبستگی بین مقادیر آزمایشگاهی و محاسباتی مدل ANN6



شکل ۱۱ نمودار همبستگی بین مقادیر آزمایشگاهی و محاسباتی مدل ANFIS10

CORRECTED PROOF

شکل‌های فوق، هیستوگرام خطای بین مقادیر آزمایشگاهی و مقادیر پیش‌بینی‌شده توسط مدل‌های ANFIS و ANN را نمایش می‌دهند. همان‌گونه که مشاهده می‌شود، هیستوگرام ANFIS دارای دامنه توزیع خطای کوچکتر و تمرکز بیشتر خطاها در محدوده نزدیک به صفر است که این موضوع با مقادیر کمتر شاخص‌های آماری MSE، MAE و RSE در این مدل تأیید می‌شود. در مقابل، هیستوگرام ANN دامنه خطای وسیع‌تری را نشان می‌دهد که بیانگر وجود پیش‌بینی‌های با فاصله بیشتر از مقادیر واقعی در برخی نمونه‌ها است. تفاوت محسوس در مقادیر شاخص‌های آماری به‌ویژه کاهش حدودی ۸۴٪ معیار MSE در ANFIS نسبت به ANN حاکی از برتری روش ANFIS در دقت و پایداری پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی دوده سیلیسی است.



شکل ۱۲ هیستوگرام خطاهای بین میزان داده‌های آزمایشگاهی و پیش‌بینی شده توسط مدل ANFIS و ANN

نتایج بدست آمده نشان می‌دهد که معیار R^2 برای مدل ANFIS در تمام حالات بالاتر از ANN بوده و این مدل توانسته رابطه قوی‌تری بین داده‌های ورودی و خروجی ایجاد کند. همچنین مقادیر RMSE و MAE کمتر در ANFIS نشان می‌دهد که خطای میانگین پیش‌بینی این مدل خصوصاً در محدوده میانی مقاومت‌های فشاری نسبت به ANN کمتر است. این موضوع با مکانیزم استنتاج فازی و اعمال قواعد تطبیقی قابل توجیه است که باعث انعطاف‌پذیری بیشتر مدل در مواجهه با نقاط با الگوی غیرخطی می‌شود. همچنین درصد خطای نسبی ANFIS در اکثر حالات کمتر از مدل ANN بود. مقایسه شکل‌های مربوطه نشان می‌دهد که بخش عمده این اختلاف ناشی از حساسیت ANN به ترکیباتی است که ورودی‌های آن‌ها در لبه محدوده آموزشی قرار داشته‌اند. علاوه بر این، تحلیل همبستگی متقاطع بین معیارهای مختلف نشان داد که کاهش RMSE و MAE با بهبود R^2 همسو است.

UNC JOF

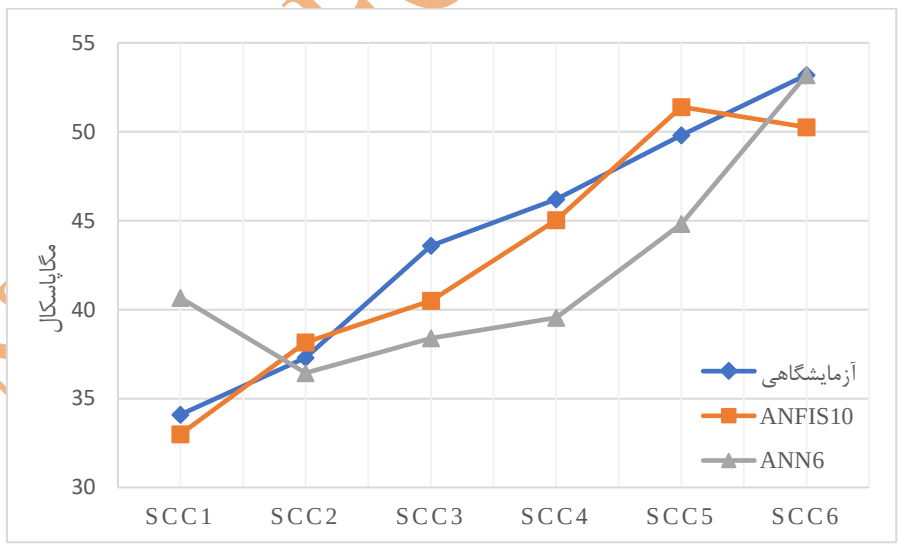
۷-۳-یافته‌های تحقیق

جدول شماره ۱۲ مربوط به مقایسه مقاومت فشاری محاسبه شده با مدل ANFIS10 و ANN6 با نمونه‌ی آزمایشگاهی می‌باشد. نتایج نشان می‌دهد که مدل ANFIS10 در مقایسه با مدل ANN6 از عملکرد بهتری در تخمین مقاومت فشاری بتن خودتراکم حاوی دوده سیلیسی برخوردار است. همچنین شکل شماره ۱۲ نشان می‌دهد که مقاومت فشاری محاسبه شده با مدل ANFIS10 همپوشانی بیشتری با مقاومت فشاری نمونه‌های آزمایشگاهی داشته است.

بطوریکه میزان مقاومت فشاری ۲۸ روزه نمونه‌های آزمایشگاهی طرح SCC-1,2,3,4,5,6 در شبکه ANN با دقت به ترتیب ۸۴٪، ۹۸٪، ۸۷٪، ۸۴٪، ۸۹٪ و در شبکه ANFIS با دقت به ترتیب ۹۷٪، ۹۸٪، ۹۳٪، ۹۸٪، ۹۷٪ و ۹۵٪ پیش‌بینی شده است. بطور میانگین دقت شبکه ماشین یادگیری در پیش‌بینی نتایج مقاومت فشاری ۲۸ روزه بتن خودتراکم حاوی دوده سیلیسی در شبکه ANN ۹۰٪ و در شبکه ANFIS ۹۶٪ می‌باشد.

جدول ۱۲ مقایسه نتایج مقاومت فشاری ۲۸ روزه بتن خودتراکم حاوی دوده سیلیسی در روش آزمایشگاهی و مدل منتخب روش ANN و ANFIS

طرح مخلوط	مقاومت فشاری ۲۸ روزه		
	آزمایشگاهی	ANFIS10	ANN6
SCC1	۳۴/۱	۳۳	۴۰/۶۶
SCC2	۳۷/۳	۳۸/۱۶	۳۶/۴۴
SCC3	۴۳/۶	۴۰/۵۰	۳۸/۴
SCC4	۴۶/۲	۴۵/۰۳	۳۹/۵۵
SCC5	۴۹/۸	۵۱/۴	۴۴/۸۲
SCC6	۵۳/۲	۵۰/۲۵	۵۳/۲



شکل ۱۳ مقایسه نتایج مقاومت فشاری ۲۸ روزه بتن خودتراکم حاوی دوده سیلیسی آزمایشگاهی و مدل منتخب شبکه ANN6 و ANFIS10

۸-بحث

شبکه ANN زمانی نتیجه بهتری از خود نشان می‌دهد که از اطلاعات و داده‌های کافی برای فرآیند آموزش آن استفاده شده باشد. زیرا شبکه ANN از پایگاه داده ورودی برای آموزش شبکه استفاده می‌کند. بنابراین کمبود اطلاعات و

UNCORRECTED PROOF

داده‌ها، دقت مدل را کاهش می‌دهد. همچنین به دلیل اینکه شبکه ANN اطلاعات پایگاه داده خود را به صورت تصادفی انتخاب می‌کند، ممکن است در طی فرآیند آموزش شبکه با همه احتمالات و حالت‌های مختلف مواجه نشود. بعنوان مثال طرح مخلوط مربوط به بتن با عیار ۳۵۰ در فرآیند آموزش شبکه لحاظ نشود. بنابراین این احتمال باعث می‌شود پیش‌بینی مقاومت بتن با عیار ۳۵۰ از دقت لازم برخوردار نباشد. همچنین بررسی تغییرات ضریب تعیین (R^2)در شبکه ANN با افزایش تعداد لایه‌های پنهان نشان می‌دهد که این پارامتر به تنهایی تضمین‌کننده بهبود یا تغییر معنادار عملکرد مدل نیست. علت این امر را می‌توان در وابستگی عملکرد شبکه به مجموعه‌ای از متغیرها نظیر حجم و کیفیت داده‌ها، تعداد نورون‌ها در هر لایه، نوع توابع فعال‌سازی، انتخاب الگوریتم یادگیری و همچنین وجود نویز در داده‌ها جستجو کرد. علاوه بر این، تقسیم‌بندی تصادفی داده‌ها در هر اجرا و ماهیت غیرخطی سطح خطا می‌تواند منجر به بروز نوسانات جزئی در R^2 شود. در حالیکه شبکه ANFIS به تحلیل ارتباط بین داده‌های ورودی و نتایج آن می‌پردازد. بنابراین اگر اطلاعات ناقص باشند، شبکه ANFIS قادر به ترمیم آن است. ولی از آنجایی که منطق خاصی برای این کار وجود ندارد، بنابراین با روش‌های ابتکاری این کار را انجام می‌دهد. اما این کار معمولاً وقت‌گیر و دارای خطا می‌باشد. نتایج بدست آمده نشان داد که مدل ANFIS10 می‌تواند برای پیش‌بینی مقاومت فشاری ۲۸ روزه بتن خودتراکم حاوی دوده سیلیسی با دقت قابل قبولی مورد استفاده قرار گیرد. از طرفی نتایج بدست آمده از سایر تحقیقات نشان می‌دهد که استفاده از شبکه ANFIS در پیش‌بینی مقاومت فشاری بتن به نسبت سایر الگوریتم‌ها از دقت بالاتری برخوردار است. این مهم در خصوص بتن‌های معمولی، بتن غلتکی و بتن خودتراکم حاوی الیاف ثابت شده است[۳۱-۳۳]. در این تحقیق نیز نتایج نشان داد که استفاده از شبکه ANFIS در پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی دوده سیلیسی نیز بیشترین دقت را در بر خواهد داشت. جمع‌بندی نتایج این تحقیق نشان می‌دهد که استفاده از ماشین یادگیری در پیش‌بینی مقاومت فشاری بتن با توجه به مزایای زیست محیطی و اقتصادی که دارد می‌تواند جایگزین روش آزمایشگاهی در پروژه‌هایی که اهمیت زیادی ندارند، شود.

۹-نتیجه‌گیری

۱. دوده سیلیسی به عنوان یک ماده پوزولانی با واکنش‌پذیری بالا، با تولید سیلیکات کلسیم نامحلول و افزایش تراکم خمیر سیمان، مقاومت فشاری و چسبندگی بین اجزای بتن خودتراکم (SCC) را بهبود می‌بخشد. این ماده با کاهش نفوذپذیری بتن، نقش کلیدی در افزایش دوام و استحکام سازه‌ای دارد.

۲. در ارزیابی نهایی، شبکه ANFIS با ۱۰ لایه پنهان توانست در پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی دوده سیلیسی عملکرد دقیق‌تری نسبت به شبکه ANN با ۶ لایه پنهان ارائه دهد. این برتری در تمام شاخص‌های ارزیابی عملکرد مشهود بود.

۳. مقدار میانگین ضریب تعیین (R^2) در مرحله راستی‌آزمایی، برای ANFIS برابر با ۰/۸۸۹۱۴ و برای ANN برابر با ۰/۴۵۴۰۸ بود. این اختلاف نشان‌دهنده توان بالاتر ANFIS در بازتولید روابط بین طرح اختلاط و مقاومت واقعی است.

٤. مقدار میانگین ریشه میانگین مربعات خطا (RMSE) در مرحله راستی‌آزمایی، برای ANFIS برابر ۲/۷۱۶ و در ANN برابر ۶/۰۲۷۲ محاسبه شد که معادل کاهش تقریبی ۳۸٪ در مقدار خطا به نفع ANFIS است.

٥. میانگین درصد خطا (MAE) در مرحله راستی‌آزمایی، برای ANFIS برابر با ۱/۹۱۱۲ و برای ANN برابر با ۴/۷۵۷۸ بود. این نتیجه بیانگر دقت بالاتر پیش‌بینی‌های ANFIS نسبت به ANN است.

٦. در مرحله صحت‌سنجی، میانگین اختلاف مقاومت پیش‌بینی شده و واقعی برای ANFIS برابر ۰/۹۸ مگاپاسکال و برای ANN برابر ۱/۸۶ مگاپاسکال می‌باشد که بیانگر بهبود ۴۷٪ در نزدیکی نتایج ANFIS به داده‌های واقعی است.

۷. حساسیت مدل ANN به تغییرات بالای نسبت آب به سیمان و ترکیبات در مرزهای خارج از مرکز پایگاه داده بیشتر از ANFIS بوده است و علت آن فقدان مکانیسم فازی و انعطاف‌پذیری در یادگیری قواعد است.

۸. مدل ANFIS در هنگام تغییر تعداد لایه‌های پنهان از ثبات نسبی بیشتری برخوردار بوده، در حالی که ANN نوسانات بیشتری در R^2 و خطاها نشان داده است.

UNCORRECTED PROOF

منابع

[1] Torabi Khodashahri N, Norouzinejad A, Aalami SJ. Functional and qualitative evaluation of resistance parameters of high-strength and self-compacting concrete. New Researches of Engineering Sciences. 2020;29(4):19-30. (in Persian)

[2] Taherkhani H. Investigating and comparing the properties of asphalt concrete containing brick and glass powder fillers. Research Journal of Transportation. 2014;12(2):[Serial 43]. Available from: https://sid.ir/paper/83587/fa. (in Persian)

[3] Malik Dost J, Javed, Madandost R, Ranjbar, Malik Mohammad. Investigating the homogeneity of concrete strength in walls made of self-compacting concrete containing nano-silica, silica fume and zeolite. Concrete Materials and Structures. 2016;1(1):42-58. (in Persian)

[4] Dehghan, Arzoomandi, Bahlouli F, Karimai Tabarestani S, Saadat Khosh M. Mechanical characteristics of concrete containing recycled rubber powder and silica fume. Modares Civil Engineering. 2021;21(3):107-118. (in Persian)

[5] Tajik Qashqai H, Faruhid, Amir Ismail. Comparing the results of linear regression and artificial neural network models to investigate the permeability of permeable concrete pavement. Road. 2023;31(114):205-216. (in Persian)

[6] Hammoudi A, Moussaceb K, Belebchouche C, Dahmoune F. Comparison of artificial neural network (ANN) and response surface methodology (RSM) prediction in compressive strength of recycled concrete aggregates. Constr Build Mater. 2019;209:425-436.

[7] You X, Yan G, Al-Masoudy MM, Kadimallah MA, Alkhalifah T, Alturise F, Ali HE. Application of novel hybrid machine learning approach for estimation of ultimate bond strength between ultra-high performance concrete and reinforced bar. Adv Eng Softw. 2023;180:103442.

[8] Zhou Q, Wang F, Zhu F. Estimation of compressive strength of hollow concrete masonry prisms using ANN and adaptive neuro-fuzzy inference systems. Constr Build Mater. 2016;125:417-426.

[9] Yuan Z, Wang LN, Ji X. Prediction of concrete compressive strength: Research on hybrid models genetic based algorithms and ANFIS. Adv Eng Softw. 2014;67:156-163.

[10] Nazar S, Yang J, Amin MN, Khan K, Ashraf M, Aslam F, et al. Machine learning interpretable-prediction models to evaluate the slump and strength of fly ash-based geopolymer. J Mater Res Technol. 2023;24:100-124.

[11] Aval SB, Ketabdari H, Gharebaghi SA. Estimating shear strength of short rectangular reinforced concrete columns using nonlinear regression and gene expression programming. Structures. 2017;12:13-23.

[12] Asif U, Javed MF, Abuhussain M, Ali M, Khan WA, Mohamed A. Predicting the mechanical properties of plastic concrete: An optimization method by using genetic programming and ensemble learners. Case Stud Constr Mater. 2024;20:e03135.

[13] Başyigit C, Akkurt I, Kilincarslan S, Beycioglu A. Prediction of compressive strength of heavyweight concrete by ANN and FL models. Neural Comput Appl. 2020;19:507-513.

[14] Beycioğlu A. Modelling the effects of industrıal wastes on properties of lıghtweıght concrete by fuzzy logıc method [MSc thesis]. Isparta: Süleyman Demirel University, Graduate School of Applied and Natural Science; 2019.

[15] Boğa AR, Öztürk M, Topcu IB. Using ANN and ANFIS to predict the mechanical and chloride permeability properties of concrete containing GGBFS and CNI. Compos Part B Eng. 2023;45(1):688-696.

[16] Cevik A, Guzelbey IH. Neural network modeling of strength enhancement for CFRP confined concrete cylinders. Build Environ. 2018;43:751-763.

[17] Charhate S, Subhedar M, Adsul N. Prediction of concrete properties using multiple linear regression and artificial neural network. J Soft Comput Civ Eng. 2018;2(3):27-38.

[18] Deshpande N, Londhe S, Kulkarni S. Modeling compressive strength of recycled aggregate concrete by Artificial Neural Network, Model Tree and Non-linear Regression. Int J Sustain Built Environ. 2024;3(2):187-198.

[19] Dunlop P, Smith S. Estimating key characteristics of the concrete delivery and placement process using linear regression analysis. Civ Eng Environ Syst. 2020;20(4):273-290.

[20] Gandomi AH, Sajedi S, Kiani B, Huang Q. Genetic programming for experimental big data mining: A case study on concrete creep formulation. Autom Constr. 2016;70:89-97.

UNCORRECTED PROOF

[21] Golafshani EM, Rahai A, Sebt MH. Artificial neural network and genetic programming for predicting the bond strength of GFRP bars in concrete. Mater Struct. 2020;48:1581-1602.
[22] Hammoudi A, Moussaceb K, Belebchouche C, Dahmoune F. Comparison of artificial neural network (ANN) and response surface methodology (RSM) prediction in compressive strength of recycled concrete aggregates. Constr Build Mater. 2019;209:425-436.
[23] Arabzadeh, Ahmadi. Investigating the mechanical properties of limestone-pozzolanic concrete containing silica fume, iron smelting furnace slag and zeolite. Modares Civil Engineering. 2022;22(3):20-27. (in Persian)
[24] Pirmohammadi Alisha, Jahandideh Shendi, Ahmad. Investigating the strength of concrete containing micro silica and fly ash using artificial neural network. Concrete Research. 2021;14(2):141-159. (in Persian)
[25] Emadi M, Madani, Seyed Hassam. Modeling the compressive strength of RCCP using artificial neural network, ANFIS and support vector machine. Transportation Infrastructure Engineering. 2017;3(3):55-78. (in Persian)
[26] Golafshani EM, Behnood A, Arashpour M. Predicting the compressive strength of normal and High-Performance Concretes using ANN and ANFIS hybridized with Grey Wolf Optimizer. Constr Build Mater. 2020;232:117266.
[27] Sadrmomtazi A, Sobhani J, Mirgozar MA. Modeling compressive strength of EPS lightweight concrete using regression, neural network and ANFIS. Constr Build Mater. 2018;42:205-216.
[28] Bahrami S. Estimation of compressive strength of concrete with waste rubber fibers using artificial neural network. Karafan Scientific Quarterly. 2021;18(1):81-98. (in Persian)
[29] Boğa AR, Öztürk M, Topcu IB. Using ANN and ANFIS to predict the mechanical and chloride permeability properties of concrete containing GGBFS and CNI. Compos Part B Eng. 2018;45(1):688-696.
[30] Bal L, Buyle-Bodin F. Artificial neural network for predicting drying shrinkage of concrete. Constr Build Mater. 2017;38:248-254.
[31] Hou T-H, Su C-H, Chang H-Z. Using neural networks and immune algorithms to find the optimal parameters for an IC wire bonding process. Expert Syst Appl. 2020;34:427-436.
[32] Iqbal MF, Liu QF, Azim I, Zhu X, Yang J, Javed MF, Rauf M. Prediction of mechanical properties of green concrete incorporating waste foundry sand based on gene expression programming. J Hazard Mater. 2020;384:121322.
[33] Javed MF, Amin MN, Shah MI, Khan K, Iftikhar B, Farooq F, et al. Applications of gene expression programming and regression techniques for estimating compressive strength of bagasse ash based concrete. Crystals. 2020;10(9):737.
[34] Jin R, Chen Q, Soboyejo AB. Non-linear and mixed regression models in predicting sustainable concrete strength. Constr Build Mater. 2018;170:142-152.
[35] Jumaa GB, Yousif AR. Predicting shear capacity of FRP-reinforced concrete beams without stirrups by artificial neural networks, gene expression programming, and regression analysis. Adv Civ Eng. 2018;2018(1):5157824.
[36] Khademi F, Behfarnia K. Evaluation of concrete compressive strength using artificial neural network and multiple linear regression models. [Journal name missing]. 2020.
[37] Lin CJ, Wu NJ. An ANN model for predicting the compressive strength of concrete. Appl Sci. 2021;11(9):3798.
[38] Mata J. Interpretation of concrete dam behaviour with artificial neural network and multiple linear regression models. Eng Struct. 2021;33(3):903-910.
[39] Özcan F, et al. Comparison of artificial neural network and fuzzy logic models for prediction of long-term compressive strength of silica fume concrete. Adv Eng Softw. 2020;40(9):856-863.
[40] Parichatprecha R, Nimityongskul P. Analysis of durability of high performance concrete using artificial neural networks. Constr Build Mater. 2019;23:910-917.
[41] Sarıdemir M, et al. Prediction of long-term effects of GGBFS on compressive strength of concrete by artificial neural networks and fuzzy logic. Constr Build Mater. 2019;23:1279-1286.
[42] Singh P, Adebanjo A, Shafiq N, Razak SNA, Kumar V, Farhan SA, Sergeevna MT. Development of performance-based models for green concrete using multiple linear regression and artificial neural network. Int J Interact Des Manuf. 2024;18(5):2945-2956.

UNCORRECTED PROOF