Semnan University

Journal of Transportation Infrastructure Engineering

Journal homepage: https://jtie.semnan.ac.ir/?lang=en

ISSN: 2821-0549

Research Article

Investigation of the Effect of Copula Model on Improving the Accuracy of Neural Networks in Predicting the Compressive Strength of Concrete Used in Concrete Pavements

Sahar Alishahi[a], Seyed Ali Ziaee[b*] Hosein Mohammadi[c]

[a] Master of Science, Department of Civil Engineering, Faculty of Engineering, Ferdowsi University of Mashhad, Mashhad, I. R. Iran.

[b] Corresponding author, Associate Professor, Department of Civil Engineering, Faculty of Engineering, Ferdowsi University of Mashhad, Mashhad, I. R. Iran.

[c] Master of Science, Department of Civil Engineering, Faculty of Engineering, Ferdowsi University of Mashhad, Mashhad, I. R. Iran.

PAPER INFO

Paper history:

Received: 2026-05-10

Revised: 2026-07-02

Accepted: 2026-07-07

Keywords:

Concrete pavement,

High-strength concrete,

Artificial neural network,

Copula method.

ABSTRACT

In recent years, the use of machine learning methods for predicting the mechanical properties of concrete has received significant attention. Among these, accurate prediction of concrete compressive strength is considered as one of the most important design parameters in concrete pavements. However, limitation of experimental data is one of the main challenges in developing accurate machine learning models. In this study, a hybrid approach, based on the Gaussian copula model and artificial neural networks (Copula-ANN), is proposed to augment the training data and improve the accuracy of compressive strength prediction of concrete. The dataset used in this research was extracted from the standard Yeh dataset and includes concrete mix design variables and compressive strength. Performance of the proposed model was compared with a conventional neural network and linear regression. Results showed that using copula method significantly improved the performance of the neural network, increasing the coefficient of determination (R^2) from 0.914 to 0.976. To evaluate the generalization capability of the model, external validation was performed using experimental data of high-strength concrete reported in reliable studies. Results of this validation indicated a good agreement between predicted values and experimental data, confirming the accuracy and reliability of the proposed model. Finally, the results demonstrate the ability of the proposed model to improve the accuracy of concrete compressive strength prediction and enhance the generalization capability of machine learning models in concrete engineering problems.

*** Corresponding author.**
E-mail address: sa-ziaee@um.ac.ir

How to cite this article: Alishahi, S., Ziaee, S. A., & Mohammadi, H. (2026). Investigation of the effect of copula model on improving the accuracy of neural networks in predicting the compressive strength of concrete used in concrete pavements. *Journal of Transportation Infrastructure Engineering, 12(2), pp.63-107.*

DOI: https://doi.org/ 10.22075/jtie.2026.41156.1763

© 2026 The Author(s). Journal of Transportation Infrastructure Engineering 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/)

مجله زیرساخت های حمل و نقل

وبسایت نشریه : https://jtie.semnan.ac.ir/?lang=en

شاپا: 2821-0549

مقاله پژوهشی

بررسی تأثیر مدل کاپولا بر بهبود دقت شبکه‌های عصبی در پیش‌بینی مقاومت فشاری بتن مورد استفاده در روسازی‌های بتنی

سحر علیشاهی[۱]، سید علی ضیائی[۲*]، حسین محمدی[۳]

[۱] کارشناس ارشد، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران.

[۲] دانشیار، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران.

[۳] کارشناس ارشد، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران.

اطلاعات مقاله

دریافت مقاله: ۱۴۰۵/۰۲/۰۲

بازنگری مقاله: ۱۴۰۵/۰۳/۱۲

پذیرش مقاله: ۱۴۰۵/۰۳/۱۷

واژگان کلیدی:

روسازی بتنی،

بتن پرمقاومت،

شبکه عصبی مصنوعی،

روش کاپولا،

چکیده

در سال‌های اخیر، استفاده از روش‌های یادگیری ماشین برای پیش‌بینی خواص مکانیکی بتن به‌طور گسترده‌ای مورد توجه قرار گرفته است. در این میان، پیش‌بینی دقیق مقاومت فشاری بتن به‌عنوان یکی از مهم‌ترین پارامترهای طراحی در روسازی‌های بتنی مطرح می‌باشد. با این حال، محدودیت داده‌های آزمایشگاهی یکی از چالش‌های اصلی در توسعه مدل‌های دقیق یادگیری ماشین است. در این پژوهش، یک رویکرد ترکیبی مبتنی بر مدل کاپولا گوسی و شبکه عصبی مصنوعی (Copula-ANN) برای افزایش داده‌های آموزشی و بهبود دقت پیش‌بینی مقاومت فشاری بتن ارائه شده است. داده‌های مورد استفاده از مجموعه داده استاندارد Yeh استخراج شده و شامل متغیرهای طرح اختلاط بتن و مقاومت فشاری می‌باشد. عملکرد مدل پیشنهادی با شبکه عصبی معمولی و رگرسیون خطی مقایسه گردید. نتایج نشان داد که استفاده از روش کاپولا موجب بهبود قابل توجه عملکرد شبکه عصبی شده و مقدار ضریب تعیین از ۰/۹۱٤ به ۰/۹۷٦ افزایش یافته است. به منظور ارزیابی قابلیت تعمیم‌پذیری مدل، اعتبارسنجی خارجی با استفاده از داده‌های آزمایشگاهی بتن‌های پرمقاومت منتشرشده در مطالعات معتبر انجام شد. نتایج این اعتبارسنجی نشان داد که مقادیر پیش‌بینی‌شده توسط مدل پیشنهادی انطباق مناسبی با داده‌های آزمایشگاهی داشته و دقت و قابلیت اعتماد مدل را تأیید می‌کند. در نهایت، نتایج بیانگر توانایی مدل پیشنهادی در افزایش دقت پیش‌بینی مقاومت فشاری بتن و بهبود قابلیت تعمیم‌پذیری مدل‌های یادگیری ماشین در مسائل مهندسی بتن می‌باشد.

* پست الکترونیک نویسنده مسئول: sa-ziaee@um.ac.ir

استناد به این مقاله: علیشاهی ، سحر.، ضیائی، سید علی و محمدی، حسین. (۱٤۰۵). بررسی تأثیر مدل کاپولا بر بهبود دقت شبکه‌های عصبی در پیش‌بینی مقاومت فشاری بتن مورد استفاده در روسازی‌های بتنی. *مهندسی زیر ساخت‌های حمل و نقل*،۱۲ (۲) ،۶۳-۱۰۷.

DOI: https://doi.org/ 10.22075/jtie.2026.41156.1763

۱. مقدمه

روسازی‌های بتنی به عنوان یک جایگزین پایدار و بادوام برای روسازی‌های آسفالتی، به طور فزاینده‌ای مورد توجه قرار گرفته‌اند. مزیت‌های اقتصادی روسازی‌های بتنی شامل طول عمر بیشتر، نیاز کمتر به تعمیر و نگهداری، و در نتیجه کاهش هزینه‌های کلی چرخه عمر است (مظفری و عسکری، ۲۰۲٤). از نظر زیست‌محیطی، روسازی‌های بتنی به دلیل بازتاب بیشتر نور خورشید و کاهش اثر جزیره گرمایی شهری، و همچنین قابلیت بازیافت و استفاده مجدد، گزینه‌ای مطلوب‌تر محسوب می‌شوند. کاربرد روسازی‌های بتنی در جاده‌های اصلی، بزرگراه‌ها، فرودگاه‌ها و مناطق با ترافیک سنگین، نشان‌دهنده پتانسیل بالای این نوع روسازی در پاسخگویی به نیازهای حمل‌ونقل مدرن است

با پیشرفت فناوری، استفاده از روش‌های یادگیری ماشین، به ویژه شبکه‌های عصبی مصنوعی (ANN)، در تحلیل و پیش‌بینی رفتار روسازی‌ها، به طور چشمگیری افزایش یافته است. این روش‌ها با قابلیت یادگیری الگوهای پیچیده از داده‌ها، می‌توانند به کاهش حجم آزمایش‌های آزمایشگاهی پرهزینه و زمان‌بر کمک کنند و در عین حال، دقت نتایج را به طور قابل توجهی ارتقا بخشند. استفاده از ANN در پیش‌بینی مقاومت بتن، ارزیابی عملکرد روسازی، و بهینه‌سازی طراحی، می‌تواند منجر به بهبود کیفیت و کارایی روسازی‌ها شود (کوفل و همکاران، ۲۰۲۳).

برای بهبود عملکرد شبکه‌های عصبی و افزایش دقت پیش‌بینی‌ها، استفاده از روش‌های افزایش داده[1] و مدل‌های کاپولا[2] می‌تواند تأثیرگذار باشد. روش‌های افزایش داده به تولید داده‌های مصنوعی و متنوع کمک می‌کنند که این امر باعث می‌شود شبکه عصبی با تنوع بیشتری از شرایط مواجه شود و در نتیجه، عملکرد بهتری داشته باشد. مدل‌های کاپولا نیز با امکان مدل‌سازی وابستگی بین متغیرهای مختلف، به بهبود دقت پیش‌بینی‌ها و درک بهتر رفتار روسازی‌ها کمک می‌کنند (مایر و همکاران، ۲۰۲۱). این رویکرد ترکیبی، می‌تواند منجر به ایجاد مدل‌های پیش‌بینی دقیق‌تر و قابل اعتمادتری برای روسازی‌های بتنی شود.

در این پژوهش، از کاپولای گوسی[3] برای مدل‌سازی وابستگی آماری بین متغیرهای طرح اختلاط بتن استفاده شده است. انتخاب این مدل به دلیل توانایی آن در جداسازی ساختار وابستگی از توزیع‌های حاشیه‌ای متغیرها صورت گرفته است. این ویژگی امکان تولید داده‌های مصنوعی با حفظ ساختار همبستگی بین متغیرها را فراهم می‌سازد.

تخمین دقیق مقاومت فشاری روسازی‌های بتنی برای تضمین ایمنی و دوام زیرساخت‌های حمل و نقل از اهمیت بالایی برخوردار است. روش‌های سنتی پیش‌بینی، اغلب با عدم قطعیت‌های متعددی همراه بوده و دقت کافی را ارائه نمی‌دهند. در این راستا، استفاده از شبکه‌های عصبی مصنوعی (ANNs) به عنوان ابزاری قدرتمند برای مدل‌سازی روابط غیرخطی، پتانسیل بالایی دارد. با این حال، عملکرد این شبکه‌ها می‌تواند تحت تأثیر وابستگی‌های پیچیده بین متغیرهای ورودی قرار گیرد. هدف از این پژوهش، بررسی تأثیر مدل‌های کاپولا در بهبود دقت شبکه‌های عصبی در پیش‌بینی مقاومت فشاری روسازی‌های بتنی و ارزیابی اثربخشی این رویکرد ترکیبی در کاهش خطاها و افزایش قابلیت اطمینان پیش‌بینی‌ها است. لازم به ذکر است که مجموعه داده مورد استفاده در این پژوهش شامل متغیرهای طرح اختلاط بتن و مقاومت فشاری بوده و یک پایگاه داده استاندارد در حوزه مهندسی بتن محسوب می‌شود. این داده‌ها عمدتاً برای مدل‌سازی خواص مکانیکی بتن

1- Data Augmentation
2- Copula Models
3- Gaussian Copula

ساختمانی و بتن مورد استفاده در کاربردهای مهندسی، از جمله روسازی‌های بتنی، به کار می‌روند.

بنابراین، هدف این پژوهش، تحلیل سازه‌ای کامل روسازی شامل پارامترهایی نظیر ضخامت لایه‌ها و شرایط بستر یا بارگذاری ترافیکی نمی‌باشد، بلکه تمرکز اصلی بر مدل‌سازی و پیش‌بینی یکی از مهمترین خواص مکانیکی بتن، یعنی مقاومت فشاری، است.

از آنجا که مقاومت فشاری بتن یکی از پارامترهای کلیدی در طراحی روسازی‌های بتنی محسوب می‌شود، نتایج این مطالعه می‌تواند به عنوان یک ورودی مهم در مدل‌های طراحی روسازی مورد استفاده قرار گیرد.

در سالیان گذشته، پژوهش‌های زیادی روی تخمین مقاومت فشاری بتن و روسازی‌های بتنی انجام شده است. در پژوهشی، هوانگ و جین (۲۰۱۸) به ارائه چارچوبی برای بهینه‌سازی مبتنی بر روش مونت‌کارلو برای طراحی طرح اختلاط بتن پرداخته‌اند. این پژوهش با هدف دستیابی به ترکیب‌های بهینه بتن نفوذپذیر با مقاومت فشاری زیاد، از الگوریتم نمونه‌گیری گیبس برای تولید نمونه‌های وابسته و شبیه‌سازی استفاده کرده است. نتیجه این مطالعه، یک روش جدید برای طراحی بتن نفوذپذیر با در نظر گرفتن تعادل بین مقاومت و نفوذپذیری است. در پژوهشی دیگر، کالوپ و همکاران (۲۰۲۰) به بررسی مقاومت فشاری بتن با استفاده از روش گرادیان درخت پرداخته‌اند. تحلیل‌ها نشان داد که مدل ترکیبی اسپلاین تطبیقی و درخت تصمیم‌گیری، با دقت بالا (ضریب همبستگی ۰/۹٦۵ و خطای مطلق ۰/۰۳۷ مگاپاسکال)، قادر به برآورد مقاومت فشاری بتن با عملکرد بالا است. این روش، با تعیین اهمیت نسبی پارامترها، یک گزینه قابل اعتماد و کارآمد برای پیش‌بینی خواص بتن و بهینه‌سازی طرح اختلاط ارائه می‌دهد. در ادامه، عمران و همکاران (۲۰۲۳) به پیش‌بینی مقاومت فشاری بتن با استفاده از رویکردی ترکیبی با استفاده از روش‌های یادگیری ماشین و روش‌های فراابتکاری پرداخته‌اند. سیستم ترکیبی طراحی شده توسط آنها توانست با دقت بسیار زیاد (ضریب همبستگی ۰/۹۷٦ و ضریب تعیین ۰/۹۵۳) مقاومت فشاری بتن را پیش‌بینی کند. در ادامه، طهمورثی و همکاران (۲۰۲۳) به ارائه مدل عملکرد مبتنی بر شاخص وضعیت روسازی با استفاده از داده‌های عملکرد بلندمدت روسازی پرداخته‌اند. این تحقیق با هدف توسعه روشی برای محاسبه دقیق شاخص وضعیت روسازی (PCI) بر اساس داده‌های LTPP انجام شده است. مدل توسعه‌یافته با دقت بالا، قابل تعمیم به روسازی‌های بتنی بوده و می‌تواند در پیش‌بینی عملکرد شبکه روسازی مورد استفاده قرار گیرد. در ادامه، اوویدو و همکاران (۲۰۲٤) به پیش‌بینی مقاومت بتن و ارائه چارچوبی برای بهینه‌سازی آن پرداخته‌اند. این پژوهش نشان داد که ترکیب یادگیری ماشین و الگوریتم ژنتیک، با پیش‌بینی دقیق مقاومت فشاری و کاهش هزینه تولید بتن (۱۰ تا ۱۵ درصد)، یک روش قدرتمند و کاربردی برای طراحی بتن پایدار، اقتصادی و قابل اعتماد است که می‌تواند جایگزین روش‌های سنتی شود. در ادامه، لَن (۲۰۲۴) به پیش‌بینی دقیق مقاومت فشاری بتن با استفاده از روش‌های یادگیری ماشین و روش‌های فراابتکاری پرداخته است. نتایج به دست آمده نشان می‌دهد که استفاده از روش یادگیری ماشین توانسته مقاومت فشاری بتن را با ضریب همبستگی ۰/۹۹۸ و خطای مربعات ۰/۵ پیش‌بینی کند. آکباس (۲۰۲۵) به ارائه یک چارچوب بهینه‌سازی مبتنی بر عملکرد برای استفاده از سرباره فولادی در لایه زیرسازی راه‌ها پرداخته است. استفاده از الگوریتم ژنتیک در کنار شبکه عصبی مصنوعی بهترین عملکرد را در بین روش‌های مورد استفاده نشان داده است. در پژوهشی دیگر، تیپو و همکاران (۲۰۲۵) به ارائه یک رویکرد نوین با استفاده از روش شبکه عصبی مصنوعی عمیق و ازدحام ذرات چندهدفه برای طرح اختلاط بتن پرداخته‌اند. با استفاده از روش بهینه‌سازی، ترکیب‌های بتنی با مقاومت فشاری بیشتر از ۵۰

مگاپاسکال به دست آمدند که در آن‌ها مصرف سیمان تا ۲۵ درصد و هزینه تولید تا ۱۵ درصد نسبت به روش‌های معمول کاهش یافته است. در پژوهش بو و همکاران (۲۰۲۵a) به برآورد مقاومت فشاری بتن مبتنی بر داده با استفاده از روش‌های یادگیری ماشین پرداخته شده است. نتایج این پژوهش نشان داد که استفاده از روش‌های یادگیری ماشین می‌تواند منجر به پیش بینی دقیق مقاومت بتن شود. علاوه بر این، تحلیل حساسیت نشان داد که نسبت آب به سیمان و نسبت سنگدانه به سیمان بیشترین تأثیر را بر نتایج روش‌های یادگیری ماشین دارد.

در سال‌های اخیر، استفاده از روش‌های یادگیری ماشین در پیش‌بینی خواص مکانیکی بتن، به‌ویژه مقاومت فشاری، به دلیل توانایی بالا در مدل‌سازی روابط غیرخطی میان متغیرهای طرح اختلاط، به‌طور گسترده مورد توجه قرار گرفته است. مدل‌هایی نظیر شبکه عصبی مصنوعی، ماشین بردار پشتیبان، جنگل تصادفی و روش‌های مبتنی بر گرادیان بوستینگ از جمله رویکردهای رایج در این حوزه محسوب می‌شوند. در همین راستا، بصیر و علی (۲۰۲۵) به پیش‌بینی مقاومت فشاری بتن متخلخل مبتنی بر یادگیری ماشین پرداخته‌اند. این مطالعه نشان داد که مدل‌های یادگیری ماشین می‌توانند با استفاده از ترکیب طرح اختلاط و شرایط عمل‌آوری، مقاومت فشاری را با دقت مناسبی پیش‌بینی کرده و به عنوان ابزار تصمیم‌گیری اولیه در طراحی مخلوط بتن مورد استفاده قرار گیرند. قوامی و همکاران (۲۰۲۵) به پیش‌بینی بهبودیافته و مدل‌سازی عدم قطعیت ناهمواری روسازی با استفاده از روش‌های یادگیری ماشین و پیش‌بینی تقارنی پرداخته‌اند. این مقاله نشان داد که مدل‌های یادگیری ماشین، به‌ویژه LGboost، توانایی بالایی در پیش‌بینی شاخص ناهمواری روسازی (IRI) دارند و نسبت به ۱۰ روش دیگر عملکرد بهتری ارائه می‌دهند. در پژوهش قوامی و ناصری (۲۰۲۶) به بررسی تکنیک‌های پیشرفته یادگیری ماشین برای پیش‌بینی ویژگی‌های تراکم و مقاومت خاک‌های تثبیت‌شده با گردوغبار کوره سیمان پرداخته شده است. این مطالعه نشان داد که مدل‌های یادگیری ماشین پیشرفته مانند CatBoost، Random Forest و XGBoost توانایی بالایی در پیش‌بینی پارامترهای ژئوتکنیک خاک تثبیت‌شده با CKD شامل UCS، OMC و MDD دارند. پینتو و همکاران (۲۰۲۶) به مدل‌سازی رگرسیونی برای پیش‌بینی شیارشدگی روسازی انعطاف‌پذیر پرداخته‌اند. این مطالعه نشان داد که مدل رگرسیون خطی چندمتغیره توانایی قابل قبولی در پیش‌بینی عمق شیارشدگی در روسازی‌های انعطاف‌پذیر دارد و با دقت مناسبی (R^2 تا حدود ۰/۸۲) عملکرد سیستم روسازی را بر اساس عوامل سازه‌ای، ترافیکی و محیطی مدل‌سازی می‌کند.

مطالعات اخیر نشان داده‌اند که گرچه این مدل‌ها توانایی بالایی در پیش‌بینی دارند، اما محدودیت اصلی آن‌ها وابستگی شدید به حجم و کیفیت داده‌های آموزشی است. در این راستا، روش‌های تولید داده مصنوعی و مدل‌سازی توزیع‌های مشترک مانند کاپولا به عنوان رویکردی نوین برای افزایش تنوع داده‌ها و بهبود تعمیم‌پذیری مدل‌ها معرفی شده‌اند.

با این وجود، کاربرد مدل‌های کاپولا در ترکیب با شبکه‌های عصبی برای پیش‌بینی مقاومت فشاری بتن، به‌ویژه در قالب داده‌های مبتنی بر طرح اختلاط، هنوز به‌طور کامل مورد بررسی قرار نگرفته است. این خلأ تحقیقاتی انگیزه اصلی انجام این پژوهش را تشکیل می‌دهد.

۲. روش‌شناسایی

در این پژوهش، با هدف تخمین مقاومت فشاری بتن مورد استفاده در روسازی‌های بتنی، از یک رویکرد ترکیبی شامل شبکه عصبی مصنوعی ANN و مدل کاپولا استفاده شده است. فرآیند تحقیق با جمع‌آوری و پاکسازی یک پایگاه داده معتبر آغاز شده و پس از

یکپارچه‌سازی داده‌ها، یک مدل ANN با استفاده از زبان برنامه‌نویسی Python توسعه داده شد و تحلیل گردید. ارزیابی اولیه دقت مدل ANN در تخمین مقاومت فشاری بتن، بدون اعمال افزایش مصنوعی داده‌ها صورت پذیرفت. در ادامه، با بهره‌گیری از مدل کاپولا که در پایتون پیاده‌سازی شده، داده‌ها به صورت مصنوعی افزایش یافته و سپس مدل ANN با استفاده از مجموعه داده‌ی گسترش‌یافته مجدداً تحلیل و دقت آن ارزیابی شد. در نهایت، نتایج حاصل از تخمین مقاومت فشاری در دو حالت (بدون افزایش داده و با افزایش داده) مقایسه و کارایی مدل کاپولا در بهبود عملکرد شبکه عصبی مصنوعی مورد بررسی قرار گرفت.

۲-۱. معرفی پایگاه داده

در این پژوهش از پایگاه داده‌ی یِه (۱۹۹۸) که یک منبع شناخته‌شده و معتبر بوده و در پژوهش‌های زیادی مورد استفاده قرار گرفته استفاده شده است. این پایگاه داده شامل ۱۰۲۷ طرح اختلاط مختلف و نتایج مقاومت فشاری نمونه‌های بتنی بوده است. متغیرهای ثبت شده در این پایگاه داده شامل ۸ داده کلیدی شامل: وزن سیمان، وزن آب، وزن ریزدانه، وزن درشت‌دانه، وزن سرباره کوره، وزن خاکستر بادی، وزن فوق‌روان‌کننده و مقاومت فشاری نمونه‌ها بوده که فراوانی آن در جدول ۱ ارائه شده است.

جدول ۱. فراوانی داده‌های آماری پایگاه داده یه

متغیرها	حداقل	حداکثر	میانگین	واریانس	انحراف معیار
وزن سیمان (کیلوگرم)	۱۰۲	۹۵۸	۳۳۱/۸۲	۱۱۹۸٦/۲۸	۱۰۹/٤۸
وزن ریزدانه (کیلوگرم)	٥۹٤	۱۷۱۲	۸۳۰/٦۷	۳۲۱۱۲/۸٥	۱۷۹/۲۰
وزن درشت‌دانه (کیلوگرم)	۰	۱۳۹۸	۹٦۲/٥۸	٦۱۹٤۸	۲٤۸/۸۹
وزن آب (کیلوگرم)	۱۱۰	٤۷٦	۱۷۹/٦۸	۱۱۱۹/٤۷	۳۳/٤٦
وزن سرباره کوره (کیلوگرم)	۰	۳٥۹/٤	۲۸/۱۹	٤۱۲۷/۰۱	٦٤/۲٤
وزن خاکستر بادی (کیلوگرم)	۰	۲۰۰/۱	۳٤/۹۸	۲٥٤٥/٦٦	٥۰/٤٥
وزن فوق‌روان‌کننده (کیلوگرم)	۰	۳۲/۲	۲/۳۷	۲۲/٦۹	٤/۷٦
مقاومت فشاری نمونه (مگاپاسکال)	۲/۳۳	۸۲/٦	۳٦/۹۳	۲۱۱/۳٥	۱٤/٥٤

۲-۲. شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی به‌عنوان یک ساختار محاسباتی طراحی‌شده، از مفهوم ساختار و عملکرد مغز انسان الهام گرفته‌اند و از یک سلسله نورون‌های مصنوعی در سطوح مختلف (ورودی، پنهان و خروجی) تشکیل شده‌اند. این سیستم‌ها با تنظیم تدریجی وزن‌های اتصالات بین نورون‌ها در فرآیند یادگیری، قادر به شناسایی و تحلیل روابط پیچیده و غیرخطی بین متغیرهای ورودی و خروجی هستند. به‌ویژه در زمینه‌هایی مانند پیش‌بینی، طبقه‌بندی و مدل‌سازی رفتارهای غیرخطی مواد ساختمانی، از جمله بتن‌های با مقاومت بالا، این مدل‌ها به‌عنوان ابزاری قدرتمند و پایدار شناخته می‌شوند که دقت بالایی در پیش‌بینی نتایج ارائه می‌دهند (سینگ و همکاران، ۲۰۱٦).

شبکه‌ی عصبی از چندین لایه تشکیل شده که هر کدام شامل تعدادی نورون و گره است. به طور کلی، یک شبکه عصبی چندلایه متشکل است از:

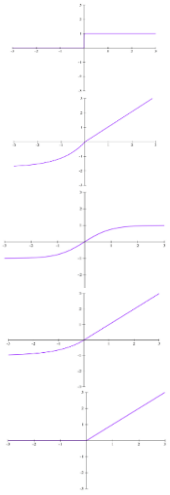
لایه ورودی: دریافت و ارسال داده‌های ورودی بر عهده این لایه است.

لایه‌های پنهان: یادگیری روابط پیچیده و استخراج ویژگی‌ها از وظایف این لایه است.

لایه خروجی: این لایه مسئول ارائه نتیجه نهایی شبکه بوده که می‌تواند شامل طبقه‌بندی، شناسایی نوع آسیب، پیش بینی مقاومت فشاری و غیره باشد.

توابع فعال‌سازی در شبکه‌های عصبی، با ایجاد تغییرات غیرخطی در خروجی، به یادگیری الگوهای پیچیده کمک می‌کنند. توابع رایجی مانند سیگموئید (خروجی صفر تا ۱)، تانژانت هیپربولیک (خروجی ۱- تا ۱ با تقارن بهتر) و ReLU (ساده، سریع و مؤثر در کاهش محوشدگی گرادیان) وجود دارند که هر کدام ویژگی‌ها و کاربردهای خاص خود را دارند و اطلاعات تکمیلی در جدول ۲ قابل دسترسی است (راساموليا و همکاران، ۲۰۲۰).

جدول ۲. توابع فعال‌سازی

Binary Step	$f(x)=\begin{cases}0 & x<0\\1 & x\geq 0\end{cases}$	
Sigmoid	$f(x)=\frac{1}{1+e^{-x}}$	
Tanh	$f(x)=\frac{e^{x}-e^{-x}}{e^{x}+e^{-x}}$	
Elu	$f(x)=\begin{cases}\alpha(e^{x}-1) & x\leq 0\\x & x>0\end{cases}$	
Relu	$f(x)=\begin{cases}0 & x\leq 0\\x & x>0\end{cases}$	

قبل از آموزش یک شبکه عصبی باید تنظیماتی به نام ابرپارامترها انجام شود. این تنظیمات، برخلاف پارامترهایی که در طول آموزش تغییر می‌کنند، ثابت هستند و بر نحوه یادگیری، سرعت و کارایی نهایی شبکه تأثیر می‌گذارند. انتخاب درست ابرپارامترها برای دستیابی به نتایج مطلوب حیاتی است و معمولاً با روش‌های مختلفی مانند آزمون و خطا یا الگوریتم‌های جستجوی خودکار انجام می‌شود (پاناکونگ و همکاران، ۲۰۲۲). این ابرپارامترها عبارتند از:

الف) نرخ یادگیری: تعیین میزان تغییر وزن‌ها در هر مرحله. نرخ بالا باعث ناپایداری و نرخ پایین باعث کندی آموزش می‌شود.

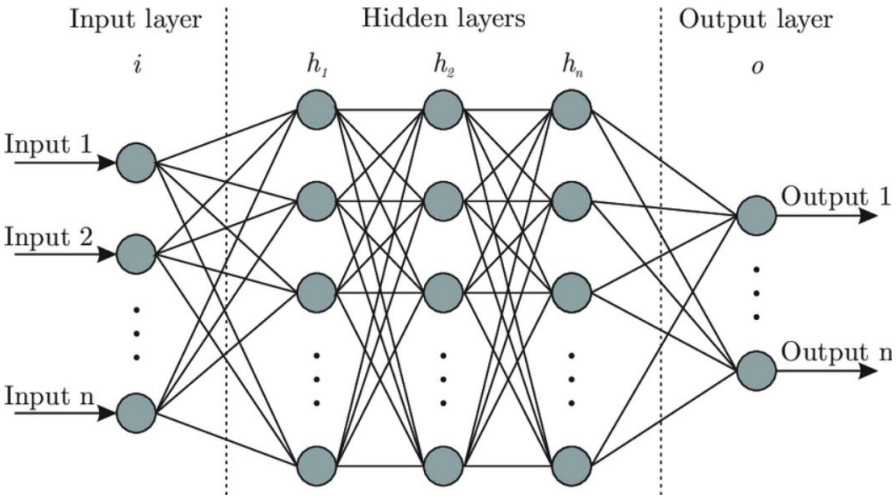
ب) تعداد دوره‌ها: تعداد دفعاتی که کل مجموعه داده آموزشی پردازش می‌شود. کم بودن آن باعث یادگیری ناکافی و زیاد بودن آن باعث بیش‌برازش می‌شود.

ج) اندازه دسته: تعداد نمونه‌های مورد استفاده در هر به‌روزرسانی وزن‌ها. دسته‌های کوچک‌تر دقیق‌ترند اما نیازمند منابع بیشتر، و دسته‌های بزرگ‌تر سریع‌ترند اما ممکن است دقت را کاهش دهند.

د) نرخ حذف تصادفی: تکنیکی برای جلوگیری از بیش‌برازش با غیرفعال کردن تصادفی نورون‌ها. معمولاً بین ۰/۲ تا ۰/۵ است.

ه) تعداد لایه‌ها و نورون‌ها: تعیین عمق و عرض شبکه. لایه‌های بیشتر برای مسائل پیچیده‌تر و نورون‌های بیشتر برای ظرفیت یادگیری بالاتر، اما با ریسک بیش‌برازش (یین و همکاران، ۲۰۰۳).

به طور کلی، ساختار یک شبکه عصبی مصنوعی چندلایه در شکل ۱ ارائه شده است.



شکل ۱. ساختار یک شبکه عصبی مصنوعی چند لایه (بِر و همکاران، ۲۰۱۸)

۲-۳. روش کاپولا

در این پژوهش، برای مدل‌سازی وابستگی بین متغیرهای طرح اختلاط بتن و تولید داده‌های مصنوعی واقع‌گرایانه، از مدل کاپولای گوسی[1] استفاده شده است. کاپولاها ابزارهای آماری هستند که امکان مدل‌سازی وابستگی بین متغیرهای تصادفی با توزیع‌های حاشیه‌ای متفاوت را فراهم می‌کنند، بدون آنکه ساختار توزیع تک‌متغیره آن‌ها محدود شود. در این حوزه، عواملی نظیر مقدار آب، سیمان، مواد افزودنی و سنگدانه‌ها به‌طور همزمان و با وابستگی‌های پیچیده، نامتقارن و گاهی مرتبط با رفتارهای حدی به هم مرتبط هستند. روش‌های سنتی افزایش داده، مانند شبیه‌سازی مونت‌کارلو یا بازنمونه‌گیری تصادفی، به‌طور معمول بر فرضیات ساده‌تری مانند استقلال یا همبستگی خطی متغیرها مبتنی هستند و قادر به بازسازی دقیق این وابستگی‌های چندمتغیره نیستند (پیوتروووسکی و همکاران، ۲۰۱۲).

مدل‌سازی کاپولا، با تفکیک توزیع‌های حاشیه‌ای از ساختار وابستگی متغیرها، به تولید داده‌های واقع‌گرایانه و دقیق کمک می‌کند (تائو و همکاران، ۲۰۲۵). این روش، برخلاف روش‌های سنتی، امکان حفظ ویژگی‌های آماری هر متغیر را در کنار بازسازی ساختار وابستگی پیچیده بین آن‌ها فراهم می‌کند. در زمینه مهندسی بتن، این ویژگی به ویژه برای اطمینان از صحت داده‌های مورد استفاده در مدل‌های یادگیری ماشین و سازگاری با رفتار فیزیکی بتن، حیاتی است (بنالی و همکاران، ۲۰۲۱).

در روش کاپولا، قضیه اسکولار بیان می‌کند که اگر بردار پیوستهٔ چندمتغیره $Z=(Z_1,...,Z_d)$ دارای توزیع تجمعی H و توزیع‌های حاشیه‌ای F_j باشد، آنگاه رابطه (۱) صدق می‌کند.

1- Gaussian Copula

$$H(Z_1,...,Z_d) = C(F_1(Z_1),...,F_d(Z_d)) \quad (۱)$$

در روش کاپولا، چگالی مشترک از رابطه (۲) محاسبه می‌شود.

$$h(z) = C(F_1(Z_1),...,F_d(Z_d))\prod_{j=1}^{d} f_j(z_j) \quad (۲)$$

در این رابطه، C بیانگر چگالی کاپولا است.

مدل‌سازی چندمتغیره را می‌توان با شکستن آن به دو بخش اصلی – توزیع حاشیه‌ای و ساختار وابستگی – به شیوه‌ای کارآمد انجام داد. این رویکرد، به دلیل تفکیک این دو جزء، امکان بازآفرینی دقیق‌تر و انعطاف‌پذیرتر رفتار آماری داده‌های واقعی را فراهم می‌آورد. برای هر متغیر Z_j، توزیع حاشیه‌ای با استفاده از روش پارامتریک و ناپارامتریک محاسبه می‌شود.

الف) روش پارامتریک براساس بیشینه درست‌نمایی و روابط (۳) و (٤) محاسبه می‌شود:

$$\gamma_j = \arg\max_{\gamma j} \prod_{i=1}^{n} f_j(z_{ij} : \gamma_j) \quad (۳)$$

در روش پارامتریک، انتخاب معیار AIC مد نظر است که از رابطه (٤) پیروی می‌کند:

$$AIC_j = 2k_j - 2\ln L_j(\gamma_j) \quad (٤)$$

ب) روش ناپارامتریک که بر اساس روابط (۵) و (٦) بیان می‌شود:

$$\tilde{f}_j(z) = \frac{1}{n+1}\sum_{i=1}^{n} 1\{z_{ij} \le z\} \quad (۵)$$

مشاهدات تبدیل‌شده به فضای کاپولا عبارتند از:

$$u_{ij} = \tilde{F}_j(z_{ij}) \quad (٦)$$

در این مطالعه، ابتدا برای متغیرهای ورودی و خروجی داده‌های مجموعه Yeh، تقریب مناسب از توزیع‌های حاشیه‌ای با استفاده از روش بیشینه درست‌نمایی انجام گردید. برای انتخاب مدل‌های مناسب، معیار AIC به‌عنوان یک شاخص تعادل بین دقت تطابق و پیچیدگی مدل به‌کار گرفته شد. پس از تعیین توزیع‌های حاشیه‌ای، داده‌ها به فضای یکنواخت کاپولا تبدیل یافتند و سپس مدل‌های مختلف کاپولا، از جمله گوسی و خانواده آرشمیدسی، به‌منظور تطبیق با داده‌ها مورد ارزیابی قرار گرفتند. نتایج به دست آمده نشان می‌دهد که روی پایگاه داده Yeh استفاده از کاپولای گوسی باعث توزیع یکنواخت‌تر نسبت به داده‌های واقعی شده است.

پس از برازش مدل کاپولا، از آن برای تولید نمونه‌های مصنوعی جدید استفاده شد تا فضای داده‌های آموزشی گسترش یابد و مشکل کمبود داده‌های آزمایشگاهی کاهش یابد. این داده‌های افزوده‌شده همراه با داده‌های اصلی برای آموزش شبکه عصبی مصنوعی مورد استفاده قرار گرفتند.

۳. طراحی شبکه عصبی مصنوعی

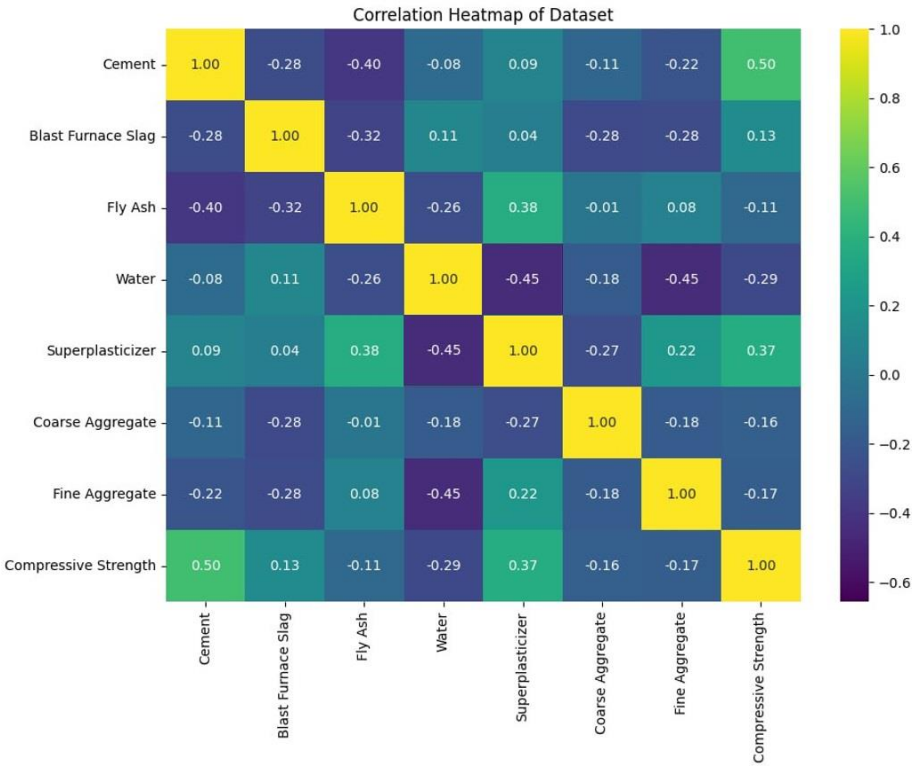
در این پژوهش، از شبکه عصبی مصنوعی چندلایه پرسپترون برای تخمین مقاومت فشاری بتن پرمقاومت مورد استفاده در روسازی لایه راه استفاده شده است. برای این کار، در ابتدا داده‌های مورد نیاز جمع‌آوری و پس از پاکسازی و یکپارچه‌سازی داده‌ها فرآیند طراحی شبکه عصبی در نرم‌افزار برنامه‌نویسی Python انجام شده است.

۳-۱. بررسی همبستگی ورودی‌ها

قبل از طراحی شبکه عصبی، بررسی میزان وابستگی بین متغیرهای ورودی به منظور ارزیابی ساختار همبستگی داده‌ها انجام شد. در این مطالعه، از ماتریس همبستگی پیرسون برای تحلیل روابط خطی بین متغیرها استفاده گردید. ضرایب همبستگی پیرسون مقادیری بین ۱- تا ۱ + اختیار می‌کنند که نشان‌دهنده شدت و جهت ارتباط خطی بین متغیرها است (مورتاق و هِک، ۲۰۱۲).

در این پژوهش، آستانه ۰/۵ برای شناسایی همبستگی‌های قابل توجه مطابق با رویکردهای رایج در مطالعات یادگیری ماشین در نظر گرفته شده است. لازم به ذکر است که وجود همبستگی بین متغیرهای ورودی لزوماً به معنای وجود مشکل در مدل‌های مبتنی بر شبکه عصبی نیست، اما می‌تواند در برخی الگوریتم‌ها موجب افزایش هم‌خطی و کاهش پایداری مدل شود.

بر اساس نتایج به‌دست‌آمده از ماتریس همبستگی (شکل ۲)، هیچیک از متغیرهای ورودی دارای مقدار همبستگی بزرگ‌تر از ۰/۵ نبودند. بنابراین، تمامی متغیرهای ورودی از نظر ساختار آماری به‌عنوان متغیرهای مستقل برای استفاده در مدل شبکه عصبی در نظر گرفته شدند.



شکل ۲. ماتریس همبستگی متغیرهای ورودی

ماتریس همبستگی پیرسون ارائه شده در شکل ۲ به خوبی نشان می‌دهد تمامی مقادیر کمتر از ۰/۵ به دست آمده است.

۳-۲. بهینه‌سازی شبکه عصبی مصنوعی

برای بهینه‌سازی ساختار شبکه عصبی مصنوعی، از الگوریتم بهینه‌سازی Adam استفاده شد که به دلیل ترکیب ویژگی‌های مومنتوم و RMSProp، به سرعت و با ثبات به سمت راه‌حل‌های بهینه حرکت می‌کند (وانگ، ۲۰۱۷). به منظور یافتن بهترین ساختار شبکه و تنظیم دقیق پارامترهای مورد استفاده در شبکه عصبی، از ابزار Keras-Tuner Hyperband Optimizer بهره گرفته شد. این ابزار با روشی هوشمندانه و با تخصیص بهینه منابع محاسباتی و استفاده از توقف زودهنگام، به سرعت بهترین ترکیب لایه‌ها، تعداد نورون‌ها، نرخ یادگیری و سایر تنظیمات کلیدی را شناسایی می‌کند (ظهیر و شازیا، ۲۰۱۹).

Hyperband با الهام از ساختار مسابقات حذف حذفی، چندین مدل با تنظیمات تصادفی را برای ایپاکس‌های کوتاه آموزش داده و مدل‌های ضعیف را حذف می‌کند تا با کاهش تدریجی منابع، به سرعت به ترکیب بهینه برسد. این روش، زمان مورد نیاز برای تنظیم ساختار شبکه را به طور چشمگیری کاهش می‌دهد و امکان بهینه‌سازی هم ساختار لایه‌ها و نورون‌ها و هم ابرپارامترها را فراهم می‌آورد (گولی و پال، ۲۰۱۷).

۳-۳. ساختار شبکه عصبی مصنوعی

ساختار شبکه عصبی مصنوعی طراحی شده به صورت جدول ۳ ارائه شده است. شبکه عصبی مصنوعی مورد استفاده در این پژوهش شامل سه لایه (ورودی، پنهان و خروجی) بوده و از تابع فعال‌سازی SeLU در لایه‌های پنهان استفاده شده است. آموزش شبکه با استفاده از الگوریتم Adam و تابع هزینه میانگین مربعات خطا (MSE) انجام شده است.

در این پژوهش، تابع فعال‌ساز SeLU استفاده شده است. برخلاف توابع فعال‌سازی سنتی مانند ReLU، تابع SeLU به صورت خودکار خروجی‌ها را به سمت توزیع با میانگین صفر و واریانس واحد هدایت می‌کند، که این موضوع موجب افزایش پایداری آموزش در شبکه‌های عمیق و بهبود سرعت همگرایی مدل می‌شود.

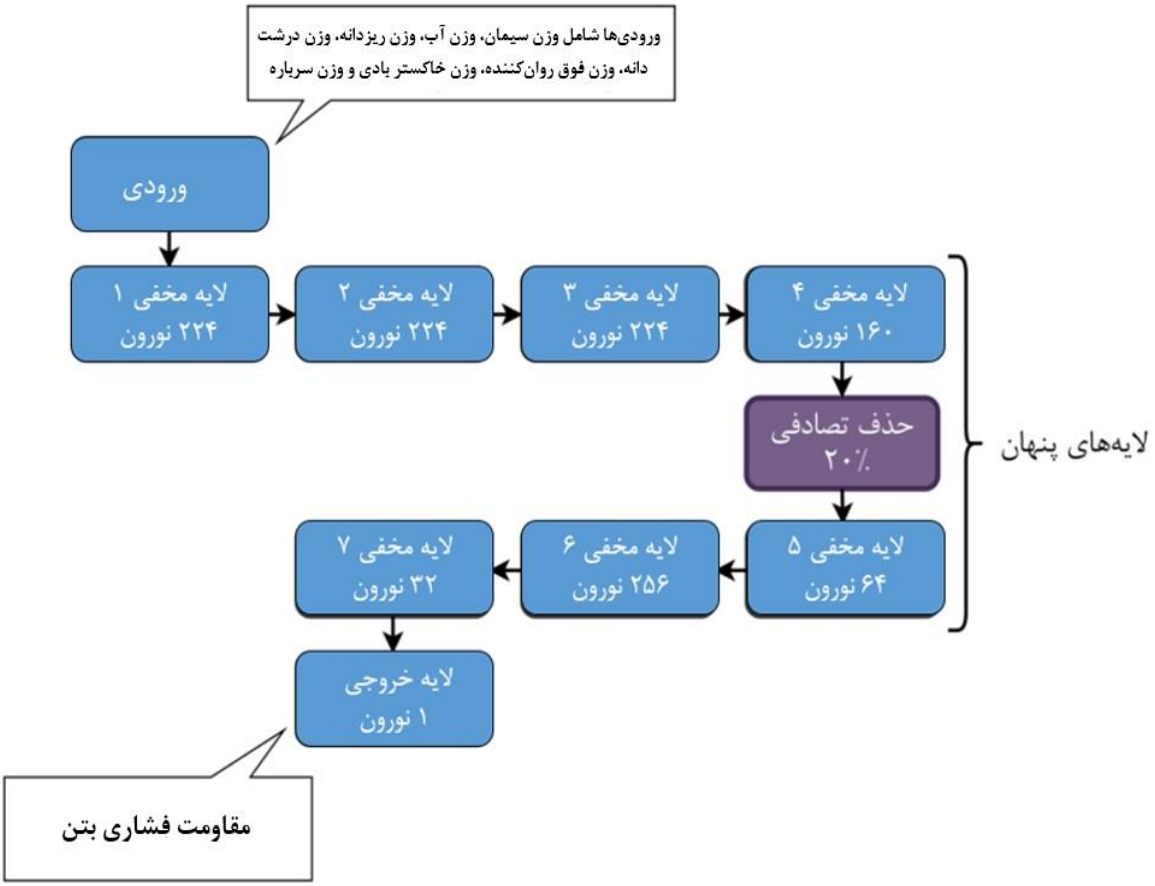
همچنین، استفاده از SeLU به ویژه در مسائل رگرسیونی پیچیده مانند پیش‌بینی مقاومت فشاری بتن، موجب بهبود قابلیت تعمیم‌پذیری مدل و کاهش حساسیت به مقداردهی اولیه وزن‌ها می‌گردد.

جدول ۳. ساختار شبکه عصبی مصنوعی

لایه	تعداد نورون	activation Function
ورودی	۷	Selu
۱	۲۲٤	Selu
۲	۲۲٤	Selu
۳	۲۲٤	Selu
۲۰ درصد داده‌ها برای جلوگیری از بیش برازش حذف می‌شوند		
٤	۱٦۰	Selu
٥	٦٤	Selu
٦	۲٥٦	Selu
۷	۳۲	Selu
خروجی	۱	Selu

پس از طراحی ساختار شبکه عصبی مصنوعی، روند اجرای شبکه عصبی در شکل ۳ ارائه شده است. ورودی‌های شبکه دارای ۸ متغییر بوده است. در لایه میانی از ۷ لایه پنهان استفاده شده و یک لایه برای حذف تصادفی ۲۰ درصد از ورودی‌ها برای جلوگیری از بیش-برازش شبکه استفاده شده است. لایه خروجی شبکه به صورت تخمین مقاومت فشاری بتن با مقاومت بالا است.

برای آموزش شبکه عصبی ۱۵ درصد داده‌ها از مجموع ۱۰۲۷ داده جمع‌آوری شده به عنوان تست، ۷۰ درصد برای آموزش و ۱۵ درصد داده‌ها به عنوان داده‌های اعتبارسنجی در نظر گرفته شده است. پس از اجرای شبکه عصبی نتایج اجرای شبکه در جدول ٤ ارائه شده است.



شکل ۳. فلوچارت طراح شبکه عصبی مصنوعی

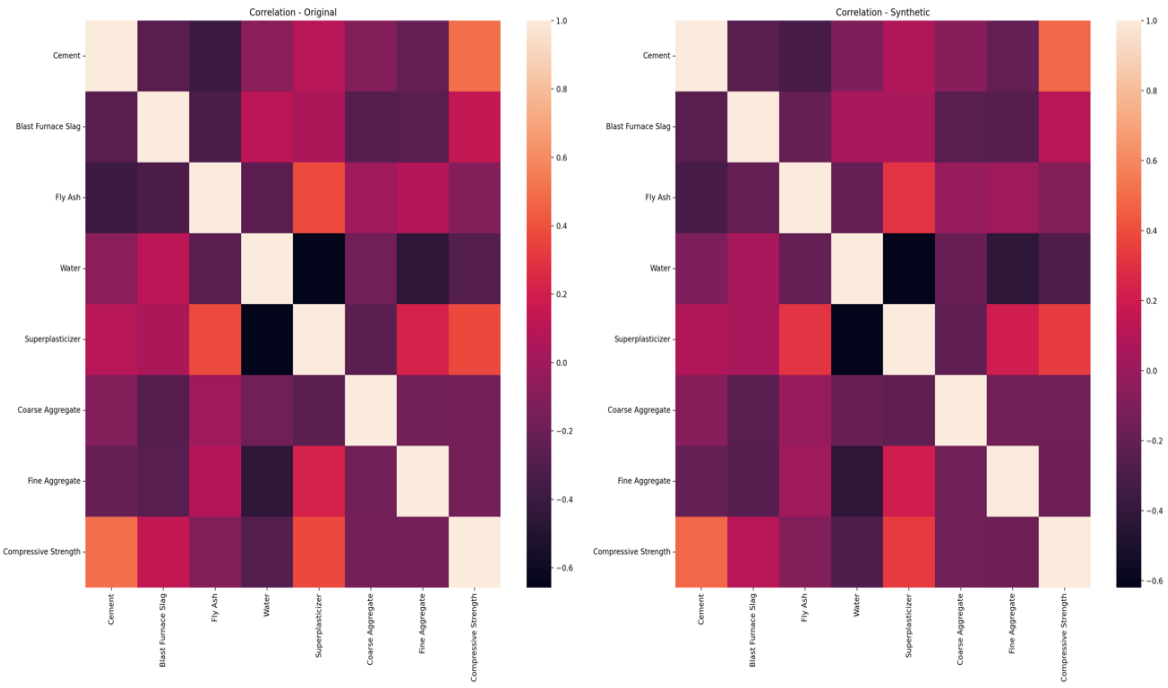
جدول ٤. نتایج شبکه عصبی مصنوعی بدون افزایش داده

داده‌های آموزش		داده‌های تست	
ضریب تعیین	۰/۹۲٦	ضریب تعیین	۰/۹۱٤
میانگین مربعات خطا	۰/۰۰۰۵۵۹	میانگین مربعات خطا	۰/۰۰۰٤۳۷
جذر میانگین مربعات خطا	۰/۰۲۳٦٤۳	جذر میانگین مربعات خطا	۰/۰۲۰۹۰٤
میانگین خطا	۰/۰۲۱٤۳۱	میانگین خطا	۰/۰۱٤۲۲۷

نتایج به دست آمده نشان می‌دهد که ضریب تعیین مدل شبکه در پیش‌بینی مقاومت فشاری بتن برای داده‌های آموزش برابر ۰/۹۲٦ و برای داده‌های تست برابر ۰/۹۱٤ است.

٤. افزایش داده با استفاده از روش کاپولا

در این پژوهش، بررسی تأثیر افزایش ساخت داده‌های مصنوعی به جهت افزایش دقت شبکه عصبی از روش کاپولا استفاده شده است. در ادامه، پس از طراحی روش کاپولا با استفاده از زبان برنامه نویسی Python، با نمونه‌گیری از توزیع کاپولا و اعمال معکوس توابع حاشیه‌ای، مجموعه داده‌های نهایی تولید شد که شامل ٤۰ هزار نمونه تصادفی بود. برای اطمینان از دقت داده‌های تولید شده، ماتریس همبستگی بین داده‌های اصلی و داده‌های مصنوعی محاسبه و در شکل٤ نمایش داده شد.



(الف) (ب)

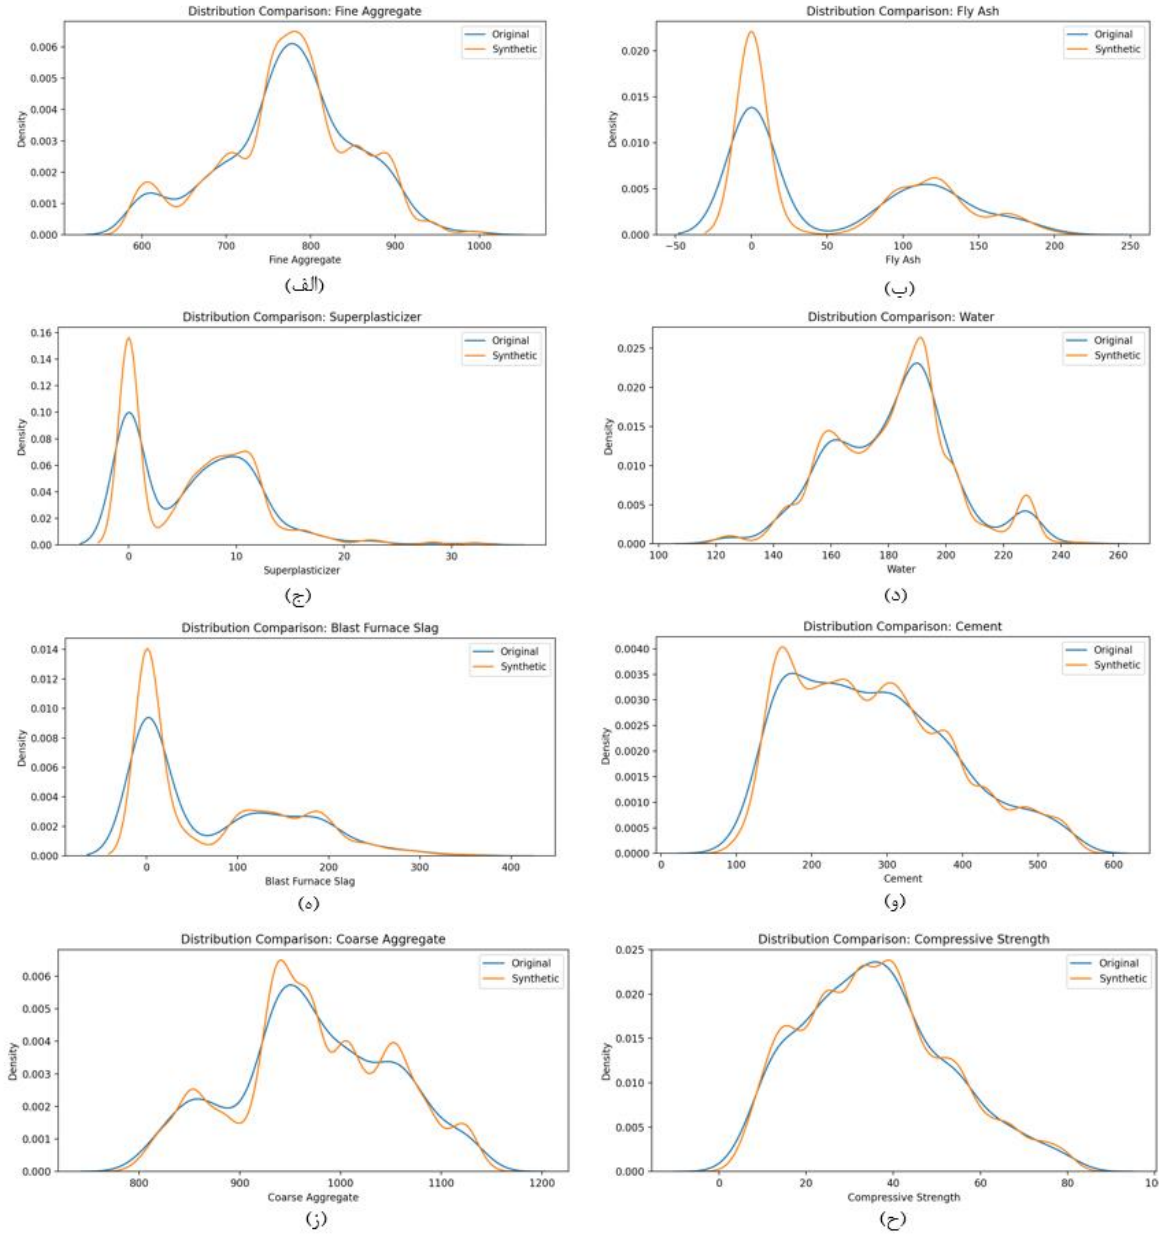
شکل ٤. ماتریس همبستگی: الف) داده‌های اصلی و ب) داده‌های مصنوعی

بررسی مقایسه‌ای ماتریس‌های همبستگی داده‌های اصلی و مصنوعی، نشان‌دهنده حفظ ساختار وابستگی بین متغیرها است. شدت و جهت همبستگی‌ها در متغیرهای کلیدی مانند سیمان، آب، فوق‌روان‌کننده و مقاومت فشاری، شباهت قابل توجهی دارند که با نقشه‌های حرارتی نیز تأیید می‌شود. این یافته‌ها حاکی از قابلیت اطمینان داده‌های مصنوعی برای جایگزینی داده‌های واقعی در فرآیند مدل‌سازی است.

کیفیت داده‌های مصنوعی از طریق مقایسه تابع چگالی احتمال (PDF) هر متغیر ورودی در داده‌های اصلی و مصنوعی ارزیابی شد. PDF توزیع مقادیر متغیرها را تصویر می‌کند و امکان بررسی تمرکز، پراکندگی و نقاط پرت را فراهم می‌آورد. شباهت منحنی‌های PDF در هر دو مجموعه داده، نشان‌دهنده حفظ ویژگی‌های آماری متغیرها است. برای ارائه یک مقایسه بصری و کمی واضح، نمودارهای PDF مربوط به ۸ متغیر کلیدی – شامل اجزای طرح اختلاط و مقاومت فشاری – در شکل ۵ ارائه شده است.

بررسی نمودارهای شکل ۵ نشان می‌دهد که توابع چگالی داده‌های مصنوعی، شباهت مناسبی با داده‌های واقعی دارند، به‌ویژه در متغیرهای مهمی مانند سیمان، آب و مقاومت فشاری. این تطابق آماری، توانایی روش کاپولا را در بازتولید ساختار توزیعی داده‌ها و تولید نمونه‌های قابل اعتماد برای کاربرد در شبکه‌های عصبی (ANN) تأیید می‌کند.

در ادامه، مقایسه مشخصات آماری داده‌های حقیقی و مصنوعی با استفاده از میانگین، واریانس و انحراف معیار داده‌های حقیقی و مصنوعی برای ۱۰۲۷ داده حقیقی و ٤۰۰۰۰ داده مصنوعی در جدول ۵ ارائه شده است.



شکل ۵. نمودارهای چگالی احتمال داده‌ها: الف) ریزدانه، ب)خاکستر بادی، ج) فوق روان‌کننده، د) آب، ه) سرباره کوره، و) سیمان، ز) درشت‌دانه و ح) مقاومت فشاری

جدول ۵. مقایسه آماری داده‌های حقیق و مصنوعی

متغیرها	میانگین		واریانس		انحراف معیار	
	حقیقی	مصنوعی	حقیقی	مصنوعی	حقیقی	مصنوعی
سیمان	۲۸۱/۱۶	۲۸۱/۳۶	۱۰۹۲۱/۷۳	۱۰۸۲۰/۲۰	۱۰۴/۵۰	۱۰۴/۲۱
سرباره کوره	۷۳/۹۱	۷۴/۲۵	۷۴۴۴/۰۷	۷۴۲۵/۶۳	۸۶/۲۷	۸۶/۲۸
خاکستر بادی	۵۴/۱۵	۵۳/۱۵	۴۰۹۵/۵۳	۴۰۷۱/۲۰	۶۴/۰۱	۶۳/۷۰
آب	۱۸۱/۵۴	۱۸۱/۲۹	۴۵۶/۰۷	۴۵۲/۰۰	۲۱/۳۷	۲۱/۲۵

متغیرها	میانگین		واریانس		انحراف معیار	
فوق روان‌کننده	٦/٢١	٦/١٥	٣٥/٦٦	٣٥/٢٥	٥/٩٦	٥/٨٣
درشت دانه	٩٧٢/٩١	٩٧٣/٠١	٦٠٤٥/٦٢	٥٩٨٠/٤٣	٧٧/٧٤	٧٧/٣٤
ریزدانه	٧٧٣/٧	٧٧٢/٠٥	٦٤٢٨/١١	٦٤٥٥/١٤	٨٠/١٩	٨٠/٢٦
مقاومت فشاری	٣٥/٨١	٣٥/٧٢	٢٧٤/٠٧	٢٨٤/٤٦	١٦/٧٠	١٦/٦١

داده‌های مصنوعی تولید شده با مدل کاپولا، از نظر میانگین، واریانس، انحراف معیار، چولگی و کشیدگی، شباهت بسیار خوبی با داده‌های اصلی دارند و به خوبی ویژگی‌های پیچیده توزیع داده‌ها را بازآفرینی می‌کنند. در ادامه، برای اطمینان بیشتر از نتایج صحت افزایش داده‌های مصنوعی آزمون‌ها، در ادامه، نتایج آزمون‌های آماری کولموگروف- اسمیرنوف (KS) و اندرسون- دارلینگ (AD) روی داده‌ها انجام شده و نتایج در جدول ٦ ارائه شده است.

جدول ٦. نتایج آزمون‌های آماری کولموگروف- اسمیرنوف و اندرسون- دارلینگ

متغیرها	مقدار p آزمون کولموگروف– اسمیرنوف	آماره آزمون اندرسون– دارلینگ	سطح معناداری آزمون اندرسون– دارلینگ
سیمان	٠/٩٩٢	١/٢٨١	٠/٢٥
سرباره کوره	٠/٩٩١	١/٢٧٢	٠/٢٥
خاکستر بادی	٠/٩٩٣	٠/٩٧١	٠/٢٥
آب	١/٠٠٠	١/١٧١	٠/٢٥
فوق روان‌کننده	٠/٩٨٢	١/٣٠٢	٠/٢٥
درشت دانه	١/٠٠٠	١/١٧١	٠/٢٥
ریزدانه	١/٠٠٠	١/٢٥٢	٠/٢٥
مقاومت فشاری	٠/٩٩٣	١/٢٢١	٠/٢٥

نتایج آزمون‌های آماری نرمال‌سازی و مقایسه توزیع‌ها نشان می‌دهند که داده‌های مصنوعی تولیدشده به‌طور قابل توجهی با داده‌های اصلی هم‌خوانی دارند. در آزمون کولموگروف–اسمیرنوف، مقدار p برای تمام متغیرها به حداکثر (١) نزدیک شده است، که ناشی از فرآیند تولید داده‌ها مبتنی بر کاپولا و حجم بالای نمونه‌ها است. این نتیجه به‌معنای یکسانی کامل داده‌ها نیست، بلکه نشان‌دهنده تطابق میان توزیع‌های حاشیه‌ای و ساختار وابستگی داده‌های مصنوعی با داده‌های واقعی است. همچنین، آزمون اندرسون– دارلینگ نتایجی منفی و کمتر از مقدار بحرانی گزارش کرده است، که نشان‌دهنده عدم تفاوت معنادار میان توزیع‌ها است. برای اطمینان از واقع‌گرایی داده‌های مصنوعی، تحلیل‌های گرافیکی مانند مقایسه توابع چگالی احتمال و ماتریس‌های همبستگی به‌طور هم‌زمان با آزمون‌های آماری استفاده شده‌اند. این رویکرد امکان تشخیص ناچیزترین تفاوت‌ها را فراهم کرده و از بیش‌برازش داده‌ها جلوگیری می‌نماید.

پس از تأیید داده‌های مصنوعی و اعتماد از صحت ٤٠٠٠٠ داده مصنوعی ساخته شده. شبکه عصبی طراحی شده براساس داده‌های مصنوعی تحلیل شده است. نتایج به دست آمده از تحلیل شبکه عصبی با استفاده از داده‌های تولید شده به روش کاپولا در جدول ۷ ارائه شده است.

جدول ۷. نتایج تحلیل شبکه عصبی مصنوعی با استفاده از داده‌های مصنوعی

داده‌های آموزش		داده‌های تست	
ضریب تعیین	۰/۹۷۹	ضریب تعیین	۰/۹۷٦
میانگین مربعات خطا	۰/۰۰۰٤٤۹	میانگین مربعات خطا	۰/۰۰۰۳۲۷
جذر میانگین مربعات خطا	۰/۰۲۱۱۸۹	جذر میانگین مربعات خطا	۰/۰۱۸۰۸۳
میانگین خطا	۰/۰۲۲٤۳۱	میانگین خطا	۰/۰۱٤۳۱۷

نتایج به دست آمده با استفاده از داده‌های تولید شده با استفاده از روش کاپولا در تخمین مقاومت فشاری بتن پرمقاومت مورد استفاده در روسازی‌های بتنی افزایش ۵/۳ درصدی در داده‌های آموزش و ٦/۲ درصدی در داده‌های تست را نشان می‌دهد و بیانگر تأثیر مثبت استفاده از روش کاپولا در افزایش دقت شبکه عصبی در تخمین مقاومت فشاری بتن پرمقاومت است.

٤-۱. اعتبارسنجی خارجی و مقایسه با مدل پایه

به منظور ارزیابی قابلیت تعمیم‌پذیری مدل پیشنهادی و بررسی عملکرد آن در شرایط واقعی، فرآیند اعتبارسنجی خارجی با استفاده از داده‌های آزمایشگاهی منتشرشده در مطالعه بو و همکاران (b ۲۰۲۵) انجام شد. در این مطالعه، داده‌های مربوط به بتن‌های فوق‌پُرمقاومت شامل مشخصات طرح اختلاط و مقاومت فشاری نمونه‌ها ارائه شده است. بخشی از این داده‌ها به عنوان مجموعه داده اعتبارسنجی خارجی انتخاب و به مدل‌های توسعه‌یافته وارد شدند. در این بخش، عملکرد مدل رگرسیون خطی چندمتغیره به عنوان مدل پایه، شبکه عصبی مصنوعی و مدل ترکیبی Copula+ANN مورد ارزیابی و مقایسه قرار گرفت. برای مقایسه عملکرد مدل‌ها از شاخص‌های R^2، RMSE، MAE استفاده شد. مقایسه بین مقادیر آزمایشگاهی و مقادیر پیش‌بینی‌شده توسط مدل رگرسیون خطی مقاله بو و همکاران، ANN و Copula+ANN در جدول ۸ ارائه شده است.

جدول ۸. مقایسه نتایج آزمایشگاهی و مقادیر پیش‌بینی‌شده بر اساس داده‌های بو و همکاران (b ۲۰۲۵)

نمونه	مقاومت فشاری نمونه آزمایشگاهی (Mpa)	رگرسیون خطی	ANN	Copula+ANN
۱	٤٤/۲	٤۰/۸	٤۱/۹	٤۳/۸
۲	۵۱/٦	٤۷/۲	٤۸/۹	۵۱/۱
۳	٦۳/٤	۵۸/٦	٦۰/۸	٦۲/۹
٤	۳۸/۷	۳۵/۵	۳۷/۲	۳۸/۱
۵	۷۱/۲	٦٦/۱	٦۷/٤	۷۰/٦
٦	۵۵/۸	۵۱/٦	۵۳/۱	۵۵/۱

نمونه	مقاومت فشاری نمونه آزمایشگاهی (Mpa)	رگرسیون خطی	ANN	Copula+ANN
۷	٤٧/٥	٤٣/٨	٤٥/١	٤٧/٠
۸	٦٠/٩	٥٦/٣	٥٨/١	٦٠/٢
۹	٣٢/٦	٢٩/٨	٣٠/٧	٣٢/١
١٠	٦٨/٥	٦٣/٢	٦٤/٤	٦٧/٨

به منظور ارزیابی کمی عملکرد مدل‌ها، شاخص‌های آماری مربوط به هر مدل در جدول ۹ ارائه شده است. نتایج جدول ۹ نشان می‌دهد که مدل ترکیبی Copula+ANN دارای بالاترین دقت و کمترین میزان خطا در پیش‌بینی مقاومت فشاری بتن است. استفاده از روش کاپولا برای افزایش مصنوعی داده‌ها موجب بهبود عملکرد شبکه عصبی در یادگیری روابط غیرخطی بین متغیرهای طرح اختلاط و مقاومت فشاری شده است.

همچنین، اختلاف اندک میان مقادیر واقعی و پیش‌بینی‌شده در جدول ۸ بیانگر قابلیت مناسب مدل پیشنهادی در بازتولید رفتار واقعی بتن‌های پرمقاومت است. در مقابل، مدل رگرسیون خطی به دلیل فرض خطی بودن روابط، دقت کمتری نسبت به روش‌های مبتنی بر یادگیری ماشین نشان داده است.

نتایج حاصل از اعتبارسنجی خارجی بیانگر آن است که استفاده از روش ترکیبی Copula+ANN می‌تواند به عنوان یک ابزار قابل اعتماد در پیش‌بینی مقاومت فشاری بتن‌های مورد استفاده در روسازی‌های بتنی و کاهش نیاز به آزمایش‌های پُرهزینه آزمایشگاهی به کار برده شود.

جدول ۹. مقایسه عملکرد مدل‌های مختلف در اعتبارسنجی خارجی

مدل	R^2	RMSE (Mpa)	MAE (Mpa)
رگرسیون خطی	٠/٨٤٢	٦/١٨	٤/٧١
ANN	٠/٩١٠	٤/٠٩	٣/٠٢
Copula+ANN	٠/٩٦٩	٢/٨٤	١/٩١

۵. نتیجه‌گیری

عملکرد مدل‌های توسعه‌یافته شامل: شبکه عصبی مصنوعی و مدل ترکیبی Copula-ANN با استفاده از شاخص‌های آماری R^2، RMSE و MAE مورد ارزیابی قرار گرفت. نتایج نشان داد که شبکه عصبی مصنوعی توانست روابط غیرخطی بین متغیرهای ورودی و خروجی را بهتر مدل‌سازی نماید و بهبود قابل توجهی در دقت پیش‌بینی نسبت به رگرسیون خطی نشان دهد. مدل ترکیبی Copula-ANN بهترین عملکرد را در میان مدل‌های بررسی‌شده ارائه داد. این مدل با استفاده از داده‌های افزوده‌شده مبتنی بر کاپولا، توانست فضای ویژگی‌ها را به‌طور مؤثر گسترش داده و موجب بهبود یادگیری شبکه عصبی شود.

لازم به ذکر است که به جای استفاده از معیار غیرعلمی دقت[1]، از شاخص‌های استاندارد رگرسیونی شامل R^2، RMSE و MAE برای ارزیابی عملکرد

1- Accuracy

استفاده شده است. بر این اساس، مقدار ضریب تعیین مدل پیشنهادی برابر با ۰/۹۷٦ به‌دست آمد که نشان‌دهنده همبستگی قوی بین مقادیر واقعی و پیش‌بینی‌شده است. همچنین، کاهش مقدار RMSE و MAE در مدل Copula-ANN نسبت به سایر مدل‌ها بیانگر کاهش خطای پیش‌بینی و افزایش دقت مدل در شرایط داده‌های پیچیده و غیرخطی می‌باشد..

با این حال، باید توجه داشت که این نتایج به معنای جایگزینی کامل مدل‌های سازه‌ای روسازی نمی‌باشد، بلکه نشان‌دهنده بهبود عملکرد یک مدل داده‌محور در پیش‌بینی مقاومت فشاری بتن است که می‌تواند به عنوان ورودی مهم در تحلیل‌های مهندسی روسازی مورد استفاده قرار گیرد.

٦. تقدیر و قدردانی

نویسندگان، مراتب سپاس و قدردانی بی‌شائبه خود را نثار همه پژوهشگران و متخصصانی می‌کنند که در پیشبرد این پژوهش یاریگرشان بوده‌اند. همچنین، از همراهی و همکاری تمامی همکاران پژوهشی که با ارائه‌ی بازخوردهای سازنده، گامی مؤثر در جهت ارتقای کیفیت این مطالعه برداشته‌اند، صمیمانه تشکر می‌شود.

۷. تأییدیه اخلاقی

نویسندگان تأیید می‌نمایند که این مقاله برآمده از پژوهش اصلی آنها بوده و پیشتر در هیچ مجله یا کنفرانسی منتشر نشده است. همچنین، این نوشتار همزمان برای داوری به مجله‌ی دیگری ارسال نگردیده است.

۸. مشارکت‌های نویسندگان

سحر علیشاهی: ایده‌پردازی، نگارش پیش‌نویس اصلی مقاله، طراحی الگوریتم و شبکه عصبی، تحلیل داده‌ها.
سید علی ضیائی: بازبینی و ویراستاری مقاله، اعتبارسنجی، نظارت کلی بر پژوهش.
حسین محمدی: مدیریت و هماهنگی پروژه، جمع‌آوری و آماده‌سازی داده‌ها، کُد نویسی، نظارت و راهنمایی کلی بر پژوهش.

۹. منابع مالی

این پژوهش هیچگونه بودجه‌ای از سوی نهادهای تأمین‌کننده‌ی مالی، چه در داخل و چه در خارج از کشور، دریافت ننموده است.

۱۰. تعارض منافع

نویسندگان مقاله تأیید می‌کنند که در مورد انتشار این مقاله تعارض منافع وجود ندارد.

۱۰. مراجع

Akbas, M. (2025). “Integrated GBR–NSGA-II optimization framework for sustainable utilization of steel slag in road base layers”. Appl. Sci., 15(15): 8516.

Baseer, H. A., & Ali, G. M. N. (2025). “Machine learning-based compressive strength prediction in pervious concrete”. Civ. Eng., 7(1): 3.

Benali, F., Bodénès, D., Labroche, N., & de Runz, C. (2021). “MTCopula: Synthetic complex data generation using copula”. 23rd International Workshop on Design, Optimization, Languages and Analytical Processing of Big Data (DOLAP).

Bre, F., Gimenez, J. M., & Fachinotti, V. D. (2018). “Prediction of wind pressure coefficients on building surfaces using artificial neural networks”. Energy Build., 158: 1429-1441.

Bu, Y., Cai, Z., Peng, J., Yu, Y., & Xu, J. (2025a). “Data-driven compressive strength estimation and mix optimization for ultra-high-performance concrete”. J. Build. Eng., 114: 114253.

Bu, Y., Cai, Z., Peng, J., Yu, Y., & Xu, J. (2025b). “”Data-driven compressive strength estimation and mix optimization for ultra-high-performance concrete”. J. Build. Eng., 114: 114253. https://doi.org/https://doi.org/10.1016/j.jobe.2025.114253

Ghavami, S., Naseri, H., & Safi Jahanshahi, F. (2025). “Enhanced prediction and uncertainty modeling of pavement roughness using machine learning and conformal prediction”. Infrastruct., 10(7): 166.

Ghavami, S., & Naseri, H. (2026). “Advanced machine learning techniques for predicting compaction and strength characteristics of cement kiln dust-stabilized soils”. Transport. Infrastruct. Geotech., 13(4): 84.

Gulli, A., & Pal, S. (2017). “Deep learning with Keras”. Packt Publishing Ltd.

Huang, J., & Jin, L. (2018). “Convergence analysis of a Markov Chain Monte Carlo based mix design optimization for high compressive strength pervious concrete”. IOP Conference Series: Materials Science and Engineering.

Imran, M., Khushnood, R. A., & Fawad, M. (2023). “A hybrid data-driven and metaheuristic optimization approach for the compressive strength prediction of high-performance concrete”. Case Stud. Constr. Mater., 18: e01890.

Kaloop, M. R., Kumar, D., Samui, P., Hu, J. W., & Kim, D. (2020). “Compressive strength prediction of high-performance concrete using gradient tree boosting machine”. Constr. Build. Mater., 264: 120198 .

Kufel, J., Bargieł-Łączek, K., Kocot, S., Koźlik, M., Bartnikowska, W., Janik, M., Czogalik, Ł., Dudek, P., Magiera, M., & Lis, A. (2023). “What is machine learning, artificial neural networks and deep learning? examples of practical applications in medicine”. Diagnostics, 13(15): 2582.

Lan, W. (2024). “Accurate compressive strength prediction using machine learning algorithms and optimization techniques”. J. Eng. Appl. Sci., 71(1): 1.

Meyer, D., Nagler, T., & Hogan, R. J. (2021). “Copula-based synthetic data augmentation for machine-learning emulators”. Geosci. Model Develop. 14(8): 5205-5215.

Murtagh, F., & Heck, A. (2012). “Multivariate data analysis”. Springer Science & Business Media.

Oviedo, A. I., Londoño, J. M., Vargas, J. F., Zuluaga, C., & Gómez, A. (2024). “Modeling and optimization of concrete mixtures using machine learning estimators and genetic algorithms”. Modell., 5(3): 642-658.

Pannakkong, W., Thiwa-Anont, K., Singthong, K., Parthanadee, P., & Buddhakulsomsiri, J. (2022). “Hyperparameter tuning of machine learning algorithms using response surface methodology: a case study of ANN, SVM, and DBN”. Math. Problems Eng., 2022(1): 8513719.

Pinto, M., Fadugba, O. G., & Sani, A. (2026). “Regression modeling to predict flexible pavement rutting on Uganda’s road from Ntungamo to Kabale”. DOI: 10.21203/rs.3.rs-8301192/v1

Piotrowski, T., Tefelski, D. B., Polański, A., & Skubalski, J. (2012). “Monte Carlo simulations for optimization of neutron shielding concrete”. Central Eur. J. Eng., 2(2): 296-303.

Rasamoelina, A. D., Adjailia, F., & Sinčák, P. (2020). “A review of activation function for artificial neural network”. IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI).

Singh, A., Thakur, N., & Sharma, A. (2016). “A review of supervised machine learning algorithms. 3rd International Conference on Computing for Sustainable Global Development (INDIACom).

Tao, J., Fu, X., Chu, L., & Song, Y. (2025). “Copula-based full probability conversion model for estimating concrete compressive strength”. Constr. Build. Mater., 504: 144555.

Tipu, R. K., Rathi, P., Pandya, K. S., & Panchal, V. R. (2025). “Optimizing sustainable blended concrete mixes using deep learning and multi-objective optimization”. Sci. Reports, 15(1): 16356.

Wang, X. (2017). “Optimization for training deep models”.

Yin, C., Rosendahl, L., & Luo, Z. (2003). “Methods to improve prediction performance of ANN models”. Simul. Modell. Pract. Theory, 11(3-4): 211-222.

Zaheer, R., & Shaziya, H. (2019). “A study of the optimization algorithms in deep learning”. Third International Conference on Inventive Systems and Control (ICISC).