



University Of Qom



Predicting Compressive Behavior of Inorganic Matrix Composite Confined Columns Using Empirical and Machine Learning Methods

Atefeh Soleymani¹, Ali Mohammad Mohammadi², Hashem Jahangir³

1. Ph.D. in Civil Engineering, Department of Civil Engineering, University of Birjand, Birjand, Iran. E-mail: a.soleymani@birjand.ac.ir
2. MSc. Student, Department of Civil Engineering, University of Birjand, Birjand, Iran. E-mail: ali.m.mohammadi@birjand.ac.ir
3. Corresponding author, Assistant Professor, Department of Civil Engineering, Research Group of Novel Technologies in Civil Engineering, University of Birjand, Birjand, Iran. E-mail: h.jahangir@birjand.ac.ir

Article Info

Article type:
Research Article

Article history:
Received 15 Aug 2025
Revised 09 Sep 2025
Accepted 25 Sep 2025
Published 25 Sep 2025

Keywords:
Confined Columns,
Compressive Behavior,
Inorganic Matrix
Composite,
Empirical Models,
Machine Learning.

ABSTRACT

Inorganic matrix composites are considered an advanced method for structural retrofitting due to their low weight, high strength, rapid installation, and environmental compatibility. This study evaluates the confinement behavior of circular concrete columns wrapped with inorganic matrix composites. A database of 92 experimental specimens was compiled, considering key input parameters: column diameter, number of confinement layers, fiber elastic modulus, fiber thickness, ultimate strain, and unconfined compressive strength. Existing empirical models were found inadequate for accurately predicting strength enhancement. Consequently, an artificial neural network (ANN) with nine hidden neurons was developed, achieving high prediction accuracy ($R=0.9952$ and 0.9990 ; $MSE=0.000187$ and 0.0000069 ; $MAPE=1.6871\%$ and 0.6795% for training and testing, respectively). Among previous models, Triantafillou et al.'s formula showed the best performance. Sensitivity analysis quantitatively indicated that unconfined compressive strength (f_{co}) has the greatest influence on strength enhancement (92.20%), while the number of confinement layers has the least influence (5.81%). The proposed ANN model provides a reliable tool for accurate prediction and practical design of inorganic matrix composites -confined concrete columns.

Cite this article: Soleymani A, Mohammadi AM, Jahangir H. Predicting Compressive Behavior of Inorganic Matrix Composite Confined Columns Using Empirical and Machine Learning Methods. Civil Infrastructure Researches. 2025; 11(2): 117-140. <https://doi.org/10.22091/cer.2025.13648.1646>



Introduction

Rehabilitation and strengthening of structural elements to extend their service life is one of the key objectives in civil engineering. Fiber-reinforced composite systems play a significant role in achieving this goal. These systems, with their favorable mechanical properties, ease of installation, and high strength-to-weight ratio, require minimal curing time and can effectively meet structural performance requirements. Fiber-reinforced polymers (FRP) are the most common type of composite system used for structural strengthening and retrofitting. However, certain limitations in the mechanical properties of FRPs and their inadequate performance under various environmental conditions have attracted researchers' attention toward fiber reinforced inorganic matrix (FRIM) composites.

Despite previous studies, compared to columns confined with conventional FRP composites, significant gaps remain in understanding the behavior of elements confined with FRIM composites. In this study, the compressive behavior of circular concrete columns confined with FRIM composites was investigated. To this end, a database of 92 experimental specimens was compiled, and the predicted strength enhancements from several empirical models were compared with the experimental results. Subsequently, an artificial neural network model was developed to improve prediction accuracy, and the performance of the proposed ANN-based model was evaluated against the empirical methods. Finally, through sensitivity analysis, the most influential input parameters affecting the compressive strength enhancement of columns confined with FRIM composites were identified.

Methodology

In this study, after compiling a database of 92 experimental confined concrete columns, including column diameter, number of confinement layers, elastic modulus, fiber thickness and ultimate strain, and unconfined compressive strength as input parameters,

some existing empirical equations were selected to estimate the compressive strength of confined concrete columns. Moreover, an artificial neural network (ANN) with single hidden layer was considered to predict the compressive strength of confined concrete columns. the number of neurons in the hidden layer was varied between 3 and 25. To select the optimal configuration, well-known statistical criteria, including the mean squared error (MSE), the linear correlation coefficient (R), and the mean absolute percentage error (MAPE), were employed. At the end, the sensitivity analysis was conducted to find the most influential input parameters which affect the compressive strength of confined concrete columns.

Results

The ANN with nine hidden neurons, achieving R values of 0.995–0.999, MSE values of 0.0000069–0.000187, and MAPE values of 0.68–1.69% in training and testing, was identified as the optimal model for predicting the compressive strength of confined concrete columns.

Evaluation of the results indicates that the compressive strength of confined concrete columns predicted by the ANN provides a much better fit compared to existing empirical models and codes. Among the previous models and standards, the methods rank from most to least accurate based on linear regression coefficients (R) as follows: Triantafillou et al. (R = 0.7372), Ombres and Mazzuca (R = 0.7160), Ortlepp (R = 0.7011), De Caso et al. (R = 0.5999), ACI (R = 0.5218), and Ombres (R = 0.3369).

The use of artificial neural networks requires that the network weights and biases in different layers be specified. Unlike most previous studies, which typically only present the network structure, this research provides the network weights and biases for each layer of the ANN used to predict the compressive strength of confined concrete columns.

A sensitivity analysis was conducted to evaluate the influence of each input parameter on the compressive strength of confined columns. The unconfined compressive

strength was found to have the greatest impact, accounting for 20.92% of the variation in confined compressive strength. Other influential parameters included the equivalent fiber thickness (19.67%), the ultimate fiber strain in the composite (19.30%), the fiber modulus of elasticity (17.31%), and the column diameter (16.97%). The number of confinement layers had the least effect, contributing only 5.81%—indicating it plays a relatively minor role in influencing the confined compressive strength.

Conclusion

Authors are advised to avoid unnecessary discussions and to focus on presenting their research contributions clearly and efficiently. The ultimate goal is to enhance the scientific value of submitted manuscripts and facilitate a streamlined peer-review process.

- The ANN with nine hidden neurons, was the optimal model for predicting the compressive strength of confined columns.
- The ANN predictions outperformed all existing empirical models and codes, with Triantafillou et al. model being the most accurate among conventional approaches.
- The sensitivity analysis showed that the unconfined compressive strength has the most effective input parameter, while the number of confinement layers had minimal influence.

Funding Statement

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

Declaration of Competing Interest

■ **No competing interests:** The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Authors' Contributions

Atefeh Soleymani:

Conceptualization; Data curation; Formal analysis; Investigation; Methodology; Project

administration; Resources; Software; Validation; Visualization; Roles/Writing – original draft; Writing – review & editing.

Ali Mohammad Mohammadi:

Data curation; Formal analysis; Investigation; Methodology; Resources; Software; Visualization; Roles/Writing – original draft.

Hashem Jahangir:

Conceptualization; Data curation; Formal analysis; Investigation; Methodology; Project administration; Resources; Software; Supervision; Validation; Visualization; Roles/Writing – original draft; Writing – review & editing.



واسنجی رفتار فشاری نمونه ستون‌های محصورشده با کامپوزیت‌های پایه‌معدنی به کمک رابطه‌های تجربی و روش‌های یادگیری ماشین

عاطفه سلیمانی^۱، علی محمد محمدی^۲، هاشم جهانگیر^۳

۱. دکتری مهندسی عمران، گروه مهندسی عمران، دانشگاه بیرجند، بیرجند، ایران. رایانامه: a.soleymani@birjand.ac.ir

۲. دانشجوی کارشناسی ارشد، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه بیرجند، بیرجند، ایران. رایانامه:

ali.m.mohammadi@birjand.ac.ir

۳. نویسنده مسئول، استادیار، گروه مهندسی عمران، دانشکده مهندسی، گروه پژوهشی فناوری‌های نوین در مهندسی عمران، دانشگاه بیرجند، بیرجند، ایران. رایانامه:

h.jahangir@birjand.ac.ir

چکیده

کامپوزیت‌های پایه‌معدنی به‌علت وزن کم، مقاومت زیاد و سازگاری با محیط زیست، یکی از روش‌های نوین مقاوم‌سازی به‌شمار می‌رود. در این پژوهش، به ارزیابی رفتار محصورکنندگی این کامپوزیت‌ها پرداخته شده است. برای این منظور، با در نظر گرفتن عامل‌های ورودی اثرگذار شامل قطر نمونه ستون‌ها، تعداد لایه‌های محصورکننده، ضریب کشسانی، ضخامت و کرنش نهایی الیاف در کامپوزیت استفاده‌شده و مقاومت فشاری نمونه‌ستون در حالت محصورنشده، پایگاه داده‌ای دارای ۹۲ نمونه‌ستون بتنی با مقطع دایره‌ای محصورشده با کامپوزیت‌های پایه‌معدنی از پژوهش‌های آزمایشگاهی پیشین گردآوری شد و دقت رابطه‌های موجود برای تخمین مقاومت فشاری ستون‌های محصورشده ارزیابی شد. نتیجه‌ها نشان دادند که رابطه‌های موجود توانایی مناسبی برای تخمین مقاومت فشاری در ستون‌های محصورشده را ندارند. از این رو، با در نظر گرفتن ۸۰٪ داده‌ها برای مرحله آموزش و ۲۰٪ باقی‌مانده برای مرحله آزمون، شبکه عصبی مصنوعی با تعداد بهینه ۹ نورون در لایه پنهان ایجاد شد که توانست با مقدارهای R به‌ترتیب برابر با ۰/۹۹۵۲ و ۰/۹۹۹۰ و مقدارهای اندک خطای MSE به‌ترتیب برابر ۰/۰۰۰۱۸۷ و ۰/۰۰۰۰۰۶۹ و خطای MAPE به‌ترتیب برابر ۱/۶۸۷۱٪ و ۰/۶۷۹۵٪ در مرحله آموزش و آزمون، رابطه‌ای دقیق برای برآورد مقاومت فشاری ستون‌های محصورشده ارائه دهد. نتیجه‌ها نشان داد که از میان رابطه‌های موجود، رابطه ارائه‌شده در پژوهش Triantafillou و همکاران کارایی بهتری دارد. نتیجه‌های انجام تحلیل حساسیت نیز بیان‌گر این بودند که مقاومت فشاری ستون در حالت محصورنشده با نسبت اهمیت ۲۰/۹۲٪ بیشترین اثر و تعداد لایه‌های محصورکننده با نسبت اهمیت ۵/۸۱٪ کمترین اثر را بر افزایش مقاومت فشاری ستون‌های محصورشده داشته‌اند.

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۴/۰۵/۲۴

تاریخ بازنگری: ۱۴۰۴/۰۶/۱۸

تاریخ پذیرش: ۱۴۰۴/۰۷/۰۳

تاریخ انتشار: ۱۴۰۴/۰۷/۰۳

کلیدواژه‌ها:

ستون‌های محصورشده،
رفتار فشاری،
کامپوزیت پایه‌معدنی،
رابطه‌های تجربی،
یادگیری ماشین.

استناد: سلیمانی عاطفه، محمدی علی محمد، جهانگیر هاشم. واسنجی رفتار فشاری نمونه ستون‌های محصورشده با کامپوزیت‌های پایه‌معدنی به کمک رابطه‌های تجربی و روش‌های یادگیری ماشین. پژوهش‌های زیرساخت‌های عمرانی، ۱۴۰۴؛ ۱۱(۲): ۱۱۷-۱۴۰.

<https://doi.org/10.22091/cer.2025.13648.1646>

۱- مقدمه

کامپوزیت‌ها شامل کربن، شیشه، فولاد و PBO^۴ هستند. الگوهای بافت این الیاف می‌تواند به صورت پارچه‌های یک‌سو یا دوسو طراحی و دسته‌بندی شود تا بهبود عملکرد مکانیکی و افزایش پیوستگی بین پایه معدنی و الیاف حاصل شود [۶].

در دهه اخیر، مطالعات متعددی به بررسی رفتار ستون‌های محصورشده با کامپوزیت‌های پلیمری تقویت‌شده با الیاف (FRP) پرداخته‌اند؛ با این حال، پژوهش‌های محدودی در خصوص استفاده از سامانه‌های کامپوزیتی پایه معدنی به عنوان فناوری محصورسازی انجام شده است [۷]. بررسی‌های مرتبط با کاربرد الیاف با بافت پارچه‌ای در تقویت المان‌های بتنی به دهه‌ی ۱۹۸۰ بازمی‌گردد [۸]؛ در حالی که در اواخر این دهه، مطالعات جامع‌تری پیرامون به‌کارگیری الیاف پوشش‌یافته با پایه‌های معدنی برای طراحی و مقاوم‌سازی المان‌های بتنی صورت گرفت [۹، ۱۰]. از نخستین نمونه‌های استفاده از ورق‌های الیاف کربنی پوشش‌یافته با ملات معدنی به عنوان محصورکننده المان‌های بتنی می‌توان به پژوهش Wu و Teng [۱۱] اشاره کرد. هم‌چنین، Triantafillou و همکارانش [۱۲] با بهره‌گیری از کامپوزیت‌های FRIM به عنوان جایگزین FRP در محصورسازی المان‌های بتنی نشان دادند که شکست در این نوع محصورسازی، برخلاف FRP، به صورت ناگهانی رخ نمی‌دهد. در مطالعه‌ی دیگر، Bournas و همکارانش [۱۳] با استفاده از سامانه‌های مشابه برای محصورکردن ستون‌های بتنی کوچک‌مقیاس دریافتند که کارایی FRIM در مقایسه با FRP حدود ۱۰٪ بیشتر است و با افزایش تعداد لایه‌ها، عملکرد آن‌ها حتی از سامانه‌های سنتی نیز فراتر می‌رود. Ombres [۱۴] عملکرد FRIM با الیاف کربنی را در محصورسازی ستون‌های بتنی با مقاطع دایره‌ای، مربعی و مستطیلی ارزیابی کرد و نشان داد که تغییر تعداد لایه‌های الیاف،

ترمیم و تقویت المان‌های سازه‌ای به منظور افزایش طول عمر مفید آن‌ها، از اهداف کلیدی در مهندسی عمران به شمار می‌رود. در این راستا، سامانه‌های کامپوزیتی تقویت‌شده با الیاف (FRCS)^۱ نقش مهمی در تحقق این هدف ایفا می‌کنند. این سامانه‌ها با برخورداری از ویژگی‌های مکانیکی مطلوب، سهولت نصب، نسبت مقاومت به وزن بالا و نیاز به زمان عمل‌آوری اندک، امکان بهره‌گیری مؤثر در پاسخ‌گویی به الزامات سازه‌ای را فراهم می‌آورند. در میان انواع این سامانه‌ها، پلیمرهای تقویت‌شده با الیاف (FRP)^۲ رایج‌ترین نوع هستند که به‌طور گسترده در تقویت و بهسازی کاربردهای سازه‌ای مورد استفاده قرار می‌گیرند. با این حال، برخی محدودیت‌ها در ویژگی‌های مکانیکی FRPها و عدم امکان اجرای آن‌ها در تمامی شرایط محیطی، سبب شده است تا توجه پژوهشگران به سمت سامانه‌های کامپوزیتی پایه معدنی (FRIM)^۳ جلب شود.

کامپوزیت‌های پایه معدنی تقویت‌شده با الیاف (FRIM) نسل جدیدی از سامانه‌های کامپوزیتی به شمار می‌آیند که می‌توانند به عنوان جایگزینی کارآمد و مؤثر برای کامپوزیت‌های پلیمری تقویت‌شده با الیاف مورد استفاده قرار گیرند [۱]. در این سامانه‌ها، الیاف به صورت درهم‌تنیده به کار می‌روند و به جای چسب‌های اپوکسی، از مواد معدنی (غیرآلی) به عنوان پایه یا ماتریس استفاده می‌شود [۲، ۳]. ویژگی‌های شاخص مواد معدنی، هم‌چون مقاومت حرارتی بالا، پایداری در برابر تابش فرابنفش، انتشار حداقلی تشعشعات هنگام فرآیند تولید و نصب، و پیشینه کارآمد در کاربردهای پیشین [۴، ۵]، آن‌ها را به گزینه‌ای مناسب برای استفاده در پایه‌ی سامانه‌های FRIM تبدیل کرده است. الیاف مورد استفاده در این

¹ Fiber Reinforced Composite Sysytems

² Fiber Reinforced Polymer

³ Fiber Reinforced Inorganic Matrix

⁴ Phenylene Benzobis Oxazole

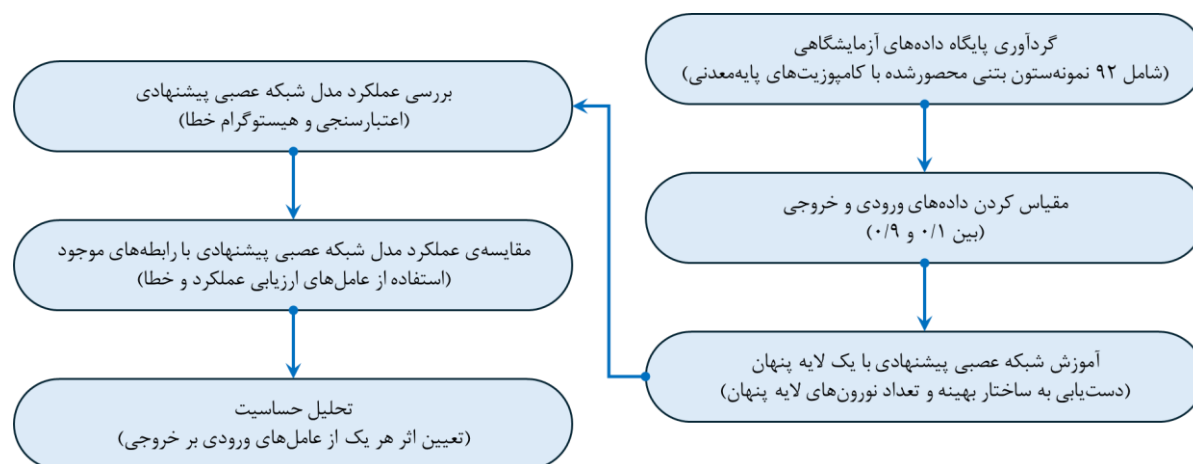
به‌طور مستقیم بر رفتار مکانیکی ستون‌ها اثرگذار است. Basalo و همکارانش [۱۵] اثر گونه‌های مختلف ملات معدنی و شکل هندسی الیاف را بررسی کردند و گزارش دادند که الیاف شیشه‌ای با چگالی کمتر، پیوستگی بهتری با پایه معدنی ایجاد می‌کند و نتیجه‌های مطلوب‌تری در محصورسازی المان‌های بتنی فراهم می‌آورد. Colajanni و همکارانش [۱۶ و ۱۷] با آزمایش ستون‌های بتنی کم‌مقاومت با مقاطع دایره‌ای و مربعی تحت بار فشاری یکنواخت، عملکرد FRIM حاوی الیاف PBO را مورد ارزیابی قرار دادند و مشاهده کردند که این نوع الیاف سبب افزایش چشمگیر مقاومت و شکل‌پذیری ستون‌ها می‌شود. با این وجود، نسبت کم الیاف در نمونه‌ها همواره امکان دستیابی به رفتار سخت‌شدگی تا لحظه‌ی شکست را فراهم نکرد. در مطالعه‌ای دیگر، Trapko [۱۸] کارایی الیاف PBO را در محصورسازی ستون‌های استوانه‌ای بتنی با تعداد لایه‌های مختلف بررسی کرد. نتیجه‌های این پژوهش نشان داد که به دلیل الگوی شکست متفاوت، FRIM اثر تقویتی کارآمدتری نسبت به FRP دارد. در حالی که نمونه‌های محصورشده با FRP در بیشتر موارد دچار شکست ترد لایه‌ی پوششی می‌شود و با افزایش لایه‌ها، خردشدگی بیشتر هسته‌ی بتنی رخ می‌دهد، در نمونه‌های FRIM آسیب لایه‌ی بیرونی به‌صورت موضعی ایجاد می‌شود و روند آن تا لحظه‌ی گسیختگی به‌تدریج پیش می‌رود.

در سال‌های اخیر، ستون‌های بتنی به‌عنوان عناصر سازه‌ای کلیدی، به‌ویژه از منظر روش‌های تقویت و بهسازی، محور توجه بسیاری از پژوهش‌ها قرار گرفته‌اند [۱۹]. اثرات محصورکنندگی سامانه‌های کامپوزیتی FRP و FRIM بر رفتار ستون‌های بتنی، در پژوهش‌های فراوانی مورد بررسی قرار گرفته است [۲۰، ۲۱]. بخشی از این تحقیقات به‌صورت آزمایشگاهی انجام شده‌اند و در آن‌ها ستون‌های بتنی محصورشده با FRP و FRIM تحت آزمون‌های مکانیکی قرار گرفته‌اند [۲۲-۲۴]. در مقابل،

برخی پژوهش‌ها رویکرد تحلیلی دارند و با ارایه مدل‌های پیش‌بینی‌کننده، به برآورد اثر محصورکنندگی این کامپوزیت‌ها پرداخته‌اند [۲۵-۲۹]. با این حال، تعداد مدل‌های تحلیلی موجود برای پیش‌بینی مقاومت فشاری ستون‌های محصورشده با FRIM به‌طور قابل‌توجهی کمتر از مدل‌های مربوط به ستون‌های محصورشده با FRP است [۳۰]. بنابراین، در بررسی پژوهش‌های پیشین مشاهده می‌شود که هرچند مطالعات متعددی به موضوع محصورسازی ستون‌های بتنی با کامپوزیت‌ها پرداخته‌اند، بخش عمده‌ای از این پژوهش‌ها بر کامپوزیت‌های پلیمری متمرکز هستند و بررسی کامپوزیت‌های پایه‌معدنی کمتر مورد توجه قرار گرفته است. افزون بر این، بسیاری از مدل‌های پیشنهادی گذشته بر داده‌های محدود و خاص مبتنی بوده‌اند و به همین دلیل از دقت و قابلیت تعمیم کافی برخوردار نیستند. محدودیت دیگر بیشتر پژوهش‌های پیشین، فقدان تحلیل حساسیت برای شناسایی عامل‌های کلیدی اثرگذار بر رفتار ستون‌های محصورشده است. این پژوهش با گردآوری یک پایگاه داده‌ی جامع، به‌کارگیری شبکه عصبی مصنوعی و انجام تحلیل حساسیت، درصدد پرکردن این شکاف‌ها و ارایه‌ی چارچوبی دقیق‌تر و شفاف‌تر برای برآورد میزان افزایش مقاومت فشاری ستون‌های محصورشده با کامپوزیت‌های پایه‌معدنی است.

در این پژوهش، رفتار فشاری ستون‌های بتنی با مقطع دایره‌ای شکل محصورشده با کامپوزیت‌های پایه‌معدنی مورد بررسی قرار گرفته است. برای این منظور، پایگاه داده‌ای دارای ۹۲ نمونه آزمایشگاهی گردآوری شد و مقدارهای اضافه‌مقاومت فشاری پیش‌بینی‌شده به کمک چندین رابطه تجربی با نتیجه‌های به‌دست آمده از آزمایش‌ها مقایسه شدند. در ادامه، به‌منظور بهبود دقت پیش‌بینی، مدل شبکه عصبی مصنوعی توسعه داده شد و عملکرد رابطه‌ی پیشنهادی به‌دست آمده از آن در مقایسه با روش‌های تجربی ارزیابی شد. در پایان، با بهره‌گیری از

آزمایشگاهی از پژوهش‌های مختلف، امکان تحلیل دقیق‌تر و تعمیم‌پذیری بالاتر نتیجه‌ها فراهم شده است. علاوه بر این، ارایه‌ی کامل وزن‌ها و بایاس‌های شبکه‌ی عصبی در این پژوهش گامی در جهت ارتقای شفافیت علمی و تسهیل بازتولید نتیجه‌ها به کمک سایر پژوهشگران به شمار می‌رود. در پایان، انجام تحلیل حساسیت برای شناسایی عامل‌های کلیدی اثرگذار بر افزایش مقاومت فشاری ستون‌ها، جنبه‌ی متمایز دیگری است که این پژوهش را از پژوهش‌های مشابه پیشین متمایز می‌سازد.



شکل ۱- روند انجام مرحله‌های مختلف در این پژوهش


۲- پایگاه داده‌ها

محصورشده گفته می‌شود و با $\frac{f_{cc}}{f_{co}}$ نماد نشان داده می‌شود.

در این پژوهش، به‌منظور ارزیابی دقت رابطه‌های موجود و همچنین ارایه رابطه‌ی جدید برای برآورد افزایش مقاومت فشاری ستون‌های بتنی محصورشده با کامپوزیت‌های پایه‌معدنی (FRIM)، پایگاه داده‌ای شامل ۹۲ نمونه ستون بتنی با مقطع دایره‌ای بر اساس نتیجه‌های پژوهش‌های آزمایشگاهی پیشین گردآوری شده است. جزئیات ویژگی‌های این نمونه‌ها در جدول ۱ ارایه شده است. در این جدول، نمادهای D ، N ، E_f ، t_f و f_{co} به‌ترتیب بیانگر قطر نمونه ستون‌ها، تعداد لایه‌های کامپوزیت پایه‌معدنی مورد استفاده، ضریب کشسانی الیاف، ضخامت معادل الیاف، کرنش نهایی الیاف در

تحلیل حساسیت، اثرگذارترین عامل‌های ورودی بر میزان اضافه‌مقاومت فشاری ستون‌های محصورشده با کامپوزیت‌های پایه‌معدنی شناسایی و معرفی شد. روند انجام مرحله‌های مختلف این پژوهش در شکل ۱ نشان داده شده است. نوآوری پژوهش حاضر از چند جنبه قابل توجه است. نخست آن‌که تمرکز بر کامپوزیت‌های پایه‌معدنی صورت گرفته که در مقایسه با کامپوزیت‌های پلیمری مرسوم کمتر مورد بررسی قرار گرفته‌اند. دوم آن‌که با گردآوری و یک‌پارچه‌سازی پایگاه داده‌ای متشکل از ۹۲ نمونه‌ی

آن‌گونه که در شکل ۲ نشان داده شده است، مقدار مقاومت فشاری نمونه‌ستون بتنی محصورشده با کامپوزیت FRIM که با نماد f_{cc} نشان داده می‌شود به عامل‌هایی شامل قطر نمونه ستون (D)، تعداد لایه‌های کامپوزیت پایه‌معدنی که نمونه ستون را پوشش داده‌اند (N)، ضریب کشسانی الیاف (E_f)، ضخامت معادل الیاف (t_f)، کرنش نهایی الیاف در کامپوزیت استفاده‌شده (E_f) و مقاومت فشاری نمونه‌ستون در حالت محصورنشده (f_{co}) بستگی دارد. در بیشتر موردها، مقاومت فشاری نمونه‌ستون محصورشده (f_{cc}) را به‌صورت نسبت آن بر مقاومت فشاری متناظر در نمونه‌ستون محصورنشده (f_{co}) بیان می‌کنند. به این نسبت، اضافه‌مقاومت فشاری در نمونه‌ستون



شکل ۲- عامل‌های ورودی اثرگذار بر مقاومت فشاری ستون
محصورشده با کامپوزیت FRIM

کامپوزیت، و مقاومت فشاری ستون در حالت بدون محصورسازی هستند. همچنین، f_{cc} به عنوان خروجی آزمایش‌ها، مقاومت فشاری ستون در حالت محصورشده را نشان می‌دهد. ویژگی‌های آماری این پایگاه داده، شامل کمینه (Min)، بیشینه (Max)، میانگین (Ave)، انحراف استاندارد (SD) و ضریب تغییرات (CoV)، در جدول ۲ گزارش شده است. برای بررسی بهتر پراکندگی داده‌ها، نمودارهای توزیع ورودی‌ها بر حسب خروجی در شکل ۳ رسم شده است. همان‌طور که مشاهده می‌شود، داده‌های ورودی و خروجی به طور یکنواخت در دامنه مقادیرهای کمینه و بیشینه خود پخش شده‌اند و تمرکز غیرمعمول یا داده پرت چشم‌گیری وجود ندارد.

جدول ۱- پایگاه داده‌های آزمایشگاهی

f_{cc} (MPa)	f_{co} (MPa)	ε_f (%)	t_f (mm)	E_f (Gpa)	N	D (mm)	منبع			ردیف
							مرجع	سال	نام پژوهش‌گر	
۲۳/۸۸	۱۵/۲۴	۰/۰۱۳۱	۰/۰۴۷	۲۵۵	۲	۱۵۰	[۱۲]	۲۰۰۶	Triantafillou	۱
۲۷/۳۶	۲۱/۸۱	۰/۰۱۳۱	۰/۰۴۷	۲۵۵	۲	۱۵۰				۲
۲۷	۱۵/۲۴	۰/۰۱۳۱	۰/۰۴۷	۲۵۵	۳	۱۵۰				۳
۳۲/۴۴	۲۱/۸۱	۰/۰۱۳۱	۰/۰۴۷	۲۵۵	۳	۱۵۰				۴
۷۰/۱۸	۶۷/۱	۰/۰۱۴۲	۰/۰۴۷	۲۴۰	۱	۱۵۰	[۱۴]	۲۰۰۷	Ombres	۵
۳۲/۰۳	۲۷/۰۵	۰/۰۱۴۲	۰/۰۴۷	۲۴۰	۱	۱۵۰				۶
۷۱/۷۷	۶۷/۱	۰/۰۱۴۲	۰/۰۴۷	۲۴۰	۲	۱۵۰				۷
۳۴/۸۷	۲۷/۰۵	۰/۰۱۴۲	۰/۰۴۷	۲۴۰	۲	۱۵۰				۸
۲۹	۱۹/۲۴	۰/۰۱۴۲	۰/۰۴۷	۲۴۰	۲	۱۵۰				۹
۳۶/۷۹	۲۷/۰۵	۰/۰۱۴۲	۰/۰۴۷	۲۴۰	۳	۱۵۰				۱۰
۳۱/۴۳	۱۹/۲۴	۰/۰۱۴۲	۰/۰۴۷	۲۴۰	۳	۱۵۰				۱۱
۳۵/۰۹	۱۹/۲۴	۰/۰۱۴۲	۰/۰۴۷	۲۴۰	۴	۱۵۰				۱۲
۲۲/۶۶	۱۵/۵۲	۰/۰۱۹۹	۰/۰۴۶	۹۱	۱	۱۵۰	[۳۱]	۲۰۰۸	Di Ludovico	۱۳
۲۵/۳۲	۱۷/۸۳	۰/۰۱۹۹	۰/۰۴۶	۹۱	۱	۱۵۰				۱۴
۲۸/۳۵	۱۷/۸۳	۰/۰۱۹۹	۰/۰۴۶	۹۱	۲	۱۵۰				۱۵
۲۲/۵	۱۵/۵۲	۰/۰۲	۰/۰۵	۷۲	۱	۱۵۰	[۳۲]	۲۰۱۰	Di Ludovico	۱۶
۲۵/۳۲	۱۷/۸۳	۰/۰۲	۰/۰۵	۷۲	۱	۱۵۰				۱۷
۲۲/۳۵	۱۵/۵۲	۰/۰۱۹۹	۰/۰۵	۹۱	۲	۱۵۰				۱۸
۲۸/۳۵	۱۷/۸۳	۰/۰۲	۰/۰۵	۷۲	۲	۱۵۰				۱۹
۲۲/۵	۱۵/۵۲	۰/۰۲	۰/۰۵	۷۲	۲	۱۵۰				۲۰
۲۸/۶۷	۲۱/۸	۰/۰۱۷۲	۰/۰۸۷	۵۲	۱	۱۵۰	[۳۳]	۲۰۱۰	García	۲۱
۲۸/۷۸	۲۱/۸	۰/۰۱۷۲	۰/۰۸۷	۵۲	۲	۱۵۰				۲۲

جدول ۱- ادامه


f_{cc} (MPa)	f_{co} (MPa)	ε_f (%)	t_f (mm)	E_f (Gpa)	N	D (mm)	منبع			ردیف
							مرجع	سال	نام پژوهش‌گر	
۳۵	۲۹	۰/۰۱۶۶	۰/۰۷	۷۴	۱	۱۵۰	[۳۴]	۲۰۱۱	Ortlepp	۲۳
۳۹	۲۹	۰/۰۰۴۶	۰/۰۷	۲۲۳	۱	۱۵۰				۲۴
۳۸/۵۷	۲۹	۰/۰۱۹۶	۰/۱۸	۲۰۴	۱	۱۵۰				۲۵
۱۹/۸	۱۷	۰/۰۲	۰/۰۴۷	۲۴۰	۱	۲۰۰	[۱۶]	۲۰۱۲	Colajanni	۲۶
۲۲/۵	۱۷	۰/۰۲	۰/۰۴۷	۲۴۰	۲	۲۰۰				۲۷
۲۳	۱۷	۰/۰۲	۰/۰۴۷	۲۴۰	۳	۲۰۰				۲۸
۲۶/۳	۲۱/۷	۰/۰۴۵	۰/۲۵	۷۲	۱	۱۵۲	[۳۵]	۲۰۱۲	De Caso y Basalo	۲۹
۳۰	۲۰/۴	۰/۰۴۵	۰/۲۵	۷۲	۲	۱۵۲				۳۰
۳۴/۷۳	۲۱/۷	۰/۰۴۵	۰/۲۵	۷۲	۲	۱۵۲				۳۱
۴۷/۹	۲۱/۷	۰/۰۴۵	۰/۲۵	۷۲	۴	۱۵۲				۳۲
۳۲/۵۷	۲۳/۲۳	۰/۰۱۸۱	۰/۰۴۶	۲۳۸	۱	۱۱۳	[۱۸]	۲۰۱۳	Trapko	۳۳
۴۲/۷۲	۲۳/۲۳	۰/۰۱۸۱	۰/۰۴۶	۲۳۸	۲	۱۱۳				۳۴
۵۶/۹۴	۲۳/۲۳	۰/۰۱۸۱	۰/۰۴۶	۲۳۸	۳	۱۱۳				۳۵
۲۰/۸۳	۱۶/۶۶	۰/۰۲	۰/۰۴۷	۲۴۰	۲	۲۰۰	[۳۶]	۲۰۱۴	Colajanni	۳۶
۲۲/۶۷	۱۶/۶۶	۰/۰۲	۰/۰۴۷	۲۴۰	۳	۲۰۰				۳۷
۳۱/۲۳	۲۵	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۲	۱۵۴				۳۸
۳۱/۱۷	۲۵	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۲	۲۰۰				۳۹
۳۶/۵۷	۲۵	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۳	۱۵۴				۴۰
۳۳/۵۵	۲۵	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۳	۲۰۰				۴۱
۲۹/۰۳	۱۵/۴	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۱	۱۵۲	[۳۷]	۲۰۱۴	Ombres	۴۲
۵۴/۹	۲۹/۲۶	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۱	۱۵۰				۴۳
۳۰/۹۴	۱۵/۴	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۲	۱۵۲				۴۴
۵۱/۴۵	۲۹/۲۶	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۲	۱۵۰				۴۵
۳۵/۴	۱۵/۴	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۳	۱۵۲				۴۶
۵۲/۷۴	۱۵/۴	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۴	۱۵۲				۴۷
۲۲/۲۷	۱۵/۱۲	۰/۰۲۱	۰/۵۶۲	۱۲۰	۱	۱۵۰	[۳۸]	۲۰۱۵	Thermou	۴۸
۲۵/۶۶	۱۵/۱۲	۰/۰۲۱	۰/۱۲۴	۱۲۰	۱	۱۵۰				۴۹
۲۲.۸	۱۵/۱۲	۰/۰۲۱	۰/۰۶۲	۱۲۰	۱	۱۵۰				۵۰
۲۵.۳	۱۵/۱۲	۰/۰۱۹	۰/۵۶۲	۱۱۰	۱	۱۵۰				۵۱
۲۶.۶۴	۱۵/۱۲	۰/۰۱۹	۰/۱۲۴	۱۱۰	۱	۱۵۰				۵۲
۲۲.۵۵	۱۵/۱۲	۰/۰۱۹	۰/۰۶۲	۱۱۰	۱	۱۵۰				۵۳
۳۶.۰۷	۲۶/۲	۰/۰۲۱	۰/۱۲۴	۱۲۰	۱	۱۵۰				۵۴
۳۵.۹۳	۲۶/۲	۰/۰۲۱	۰/۰۶۲	۱۲۰	۱	۱۵۰				۵۵
۴۰.۴۲	۲۶/۲	۰/۰۱۹	۰/۱۲۴	۱۱۰	۱	۱۵۰				۵۶
۳۶.۲۱	۲۶/۲	۰/۰۱۹	۰/۰۶۲	۱۱۰	۱	۱۵۰				۵۷
۲۲.۲۷	۱۹/۴۴	۰/۰۱۹۱	۰/۵۸	۱۳۰	۱	۱۵۰				۵۸
۲۵.۳	۱۹/۴۴	۰/۰۱۵۵	۰/۵۸	۱۳۰	۱	۱۵۰				۵۹
۳۶.۰۷	۱۹/۴۴	۰/۰۱۹۱	۰/۱۲	۱۳۰	۱	۱۵۰				۶۰

جدول ۱- ادامه

f_{cc} (MPa)	f_{co} (MPa)	ε_f (%)	tf (mm)	E_f (Gpa)	N	D (mm)	منبع			ردیف
							مرجع	سال	نام پژوهشگر	
۲۲/۲۷	۱۵/۱۲	۰/۰۲۱	۰/۵۶۲	۱۲۰	۱	۱۵۰	[۳۸]	۲۰۱۵	Thermou	۶۱
۲۵/۶۶	۱۵/۱۲	۰/۰۲۱	۰/۱۲۴	۱۲۰	۱	۱۵۰				۶۲
۲۲/۸	۱۵/۱۲	۰/۰۲۱	۰/۰۶۲	۱۲۰	۱	۱۵۰				۶۳
۳۵/۳۳	۳۳/۸۳	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۱	۱۵۰	[۳۹]	۲۰۱۷	Ombres	۶۴
۳۶/۲۷	۳۳/۸۳	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۱	۱۵۲				۶۵
۵۴/۹	۵۲/۳۹	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۱	۱۵۰				۶۶
۵۵/۹۴	۵۲/۳۹	۰/۰۲۱۵	۰/۰۴۶	۲۷۰	۳	۱۵۰				۶۷
۳۹/۵۶	۳۴/۶۲	۰/۰۲	۰/۰۷	۷۲	۱	۱۵۰	[۴۰]	۲۰۱۷	Zeng	۶۸
۴۳/۴۳	۳۴/۶۲	۰/۰۱۷۲	۰/۰۴۷	۲۴۴	۱	۱۵۰				۶۹
۵۰/۱۲	۳۴/۶۲	۰/۰۲	۰/۰۷	۷۲	۲	۱۵۰				۷۰
۵۷/۶	۳۴/۶۲	۰/۰۱۷۲	۰/۰۴۷	۲۴۴	۲	۱۵۰				۷۱
۱۷/۷۱	۱۱/۴	۰/۰۲۵	۰/۰۴۶	۲۷۰	۱	۱۴۰	[۴۱]	۲۰۱۸	Donnini	۷۲
۱۳/۶۶	۱۱/۴	۰/۰۱۵	۰/۰۴۸	۲۳۵	۱	۱۴۰				۷۳
۳۰/۵۴	۲۳/۱۴	۰/۰۱۹	۰/۰۶۲	۱۱۰	۱	۱۵۰	[۴۲]	۲۰۱۸	Thermou	۷۴
۳۲/۳	۲۳/۱۴	۰/۰۲۱	۰/۰۶۲	۱۲۰	۱	۱۵۰				۷۵
۲۸/۴۷	۱۶/۶۲	۰/۰۱۹	۰/۰۶۲	۱۱۰	۱	۱۵۰				۷۶
۳۱/۳۶	۲۰/۷۳	۰/۰۱۵	۰/۰۸۴	۱۹۰	۱	۱۵۰				۷۷
۲۷/۶۸	۱۸/۲۷	۰/۰۱۵	۰/۰۸۴	۱۹۰	۱	۱۵۰				۷۸
۴۰/۶۴	۱۸/۲۷	۰/۰۱۵	۰/۲۵۴	۱۹۰	۱	۱۵۰				۷۹
۴۰/۵۱	۲۹/۹۸	۰/۰۱۵	۰/۰۸۴	۱۹۰	۱	۱۵۰				۸۰
۴۵/۸۷	۲۹/۹۸	۰/۰۱۵	۰/۲۵۴	۱۹۰	۱	۱۵۰				۸۱
۳۸/۵۶	۲۳/۱۴	۰/۰۲۱	۰/۰۶۲	۱۲۰	۲	۱۵۰				۸۲
۴۴/۶۳	۲۰/۷۳	۰/۰۱۵	۰/۰۸۴	۱۹۰	۲	۱۵۰				۸۳
۳۶/۴۴	۱۸/۲۷	۰/۰۱۵	۰/۰۸۴	۱۹۰	۲	۱۵۰				۸۴
۵۳/۵۳	۱۸/۲۷	۰/۰۱۵	۰/۲۵۴	۱۹۰	۲	۱۵۰				۸۵
۴۵/۲۱	۲۹/۹۸	۰/۰۱۵	۰/۰۸۴	۱۹۰	۲	۱۵۰				۸۶
۶۴/۱۹	۲۹/۹۸	۰/۰۱۵	۰/۲۵۴	۱۹۰	۲	۱۵۰				۸۷
۱۵/۴	۹	۰/۰۲	۰/۰۵	۳۲	۱	۱۵۰	[۴۳]	۲۰۱۹	Ates	۸۸
۱۷/۱	۹	۰/۰۲	۰/۰۵	۳۲	۳	۱۵۰				۸۹
۱۹/۲	۱۷/۶	۰/۰۱۱	۰/۰۴۷	۲۴۲	۲	۱۰۰	[۴۴]	۲۰۱۹	Gonzalez-Libreros	۹۰
۲۲/۴	۱۶/۸	۰/۰۱۱	۰/۰۴۷	۲۴۲	۲	۱۵۴				۹۱
۱۹/۳	۱۶/۸	۰/۰۱۵	۰/۰۵	۵۷	۲	۱۵۴				۹۲

جدول ۲- ویژگی‌های آماری پایگاه داده آزمایشگاهی

ویژگی	D (mm)	N	E_f (Gpa)	t_f (mm)	ε_f (%)	f_{co} (Mpa)	f_{cc} (Mpa)
Min	۱۰۰	۱	۳۲	۰/۰۴۶	۰/۰۰۴۶	۹	۱۳/۶۶
Max	۲۰۰	۴	۲۷۰	۰/۵۸	۰/۰۴۵	۶۷/۱	۷۱/۷۷
Ave	۱۵۲/۲۱	۱/۶۸	۱۷۶/۲۱	۰/۱	۰/۰۱۹۱	۲۲/۹	۳۴/۰۷
SD	۱۶/۱۴	۰/۸۲	۷۷/۱۵	۰/۱۱۶	۰/۰۰۶۴	۹/۹۸	۱۱/۹۵
CoV (%)	۱۰/۶	۴۸/۶۷	۴۳/۷۹	۱۱۶/۶۱۸	۳۳/۴۷۳۶	۴۳/۵۹	۳۵/۰۸



شکل ۳- نمودار توزیع داده‌های ورودی برحسب خروجی آزمایشگاهی

۳- رابطه‌های موجود

(۵) به ارایه رابطه‌هایی برای برآورد مقاومت فشاری نمونه‌ستون در حالت محصورشده (f_{cc}) پرداخته‌اند. علاوه بر این، آیین‌نامه‌ی ACI [۴۵] (رابطه (۶)) نیز رابطه‌ای برای تخمین مقدار مقاومت فشاری f_{cc} ارایه کرده است.

تاکنون پژوهشگران فراوانی مانند Triantafillou و همکاران [۱۲] (رابطه (۱))، Ortlepp [۳۴] (رابطه (۲))، DeCaso و همکاران [۳۵] (رابطه (۳))، Ombres [۳۷] (رابطه (۴)) و Ombres و Mazzuca [۳۹] (رابطه (۵))

کامپوزیت پایه‌معدنی، E_f ضریب کشسانی الیاف، و ε_f کرنش نهایی الیاف در کامپوزیت مورد استفاده است. همچنین، D قطر نمونه ستون‌ها، ρ_f نسبت حجمی کامپوزیت پایه‌معدنی و f_{lu} تنش جانبی ناشی از محصورسازی را نشان می‌دهند.

به کمک پایگاه داده‌های آزمایشگاهی گردآوری‌شده در جدول ۱، دقت رابطه‌های موجود تجربی و آیین‌نامه و همچنین رابطه‌های پیشنهادی در این پژوهش، در بخش‌های پسین مورد ارزیابی قرار خواهد گرفت.

۴- روش پیشنهادی

۴-۱- پیش‌پردازش داده‌ها

در این پژوهش، به‌منظور دستیابی به نتیجه‌های دقیق‌تر، همه‌ی داده‌های مورد استفاده پیش از تحلیل، در بازه ۰/۱ تا ۰/۹ مقیاس‌بندی و بی‌بعد می‌شوند. این فرآیند با بهره‌گیری از رابطه خطی ارائه‌شده در رابطه (۷) انجام پذیرفته است [۴۶]:

$$X_{scaled} = \left[0.8 \times \frac{X - X_{min}}{X_{max} - X_{min}} \right] + 0.1 \quad (7)$$

در رابطه (۷)، X بیانگر متغیر ورودی یا خروجی است و X_{max} و X_{min} به‌ترتیب مقدارهای کمینه و بیشینه متغیر موردنظر را نشان می‌دهند. انتخاب بازه ۰/۱ تا ۰/۹ به جای صفر تا ۱ به دلیل جلوگیری از اشباع مقادیر در تابع فعال‌سازی در لایه پنهان انجام شده است. استفاده از این بازه باعث می‌شود که مقادیر ورودی هیچ‌گاه به کران بالایی یا پایینی تابع نزدیک نشوند و در نتیجه فرایند آموزش شبکه با ثبات بیشتری انجام شده و گرادینت‌ها دچار مشکل نشوند. الگوی شبکه‌ی عصبی مصنوعی برای پیش‌بینی مقاومت فشاری ستون در حالت محصورشده (f_{cc}) با در نظر گرفتن ورودی‌هایی شامل قطر ستون (D)، تعداد لایه‌های کامپوزیت پایه‌معدنی (N)، ضریب کشسانی الیاف (E_f)، ضخامت معادل الیاف (t_f)، کرنش نهایی الیاف

این رابطه‌های موجود به‌ترتیب در رابطه‌های (۱) تا (۶) گزارش شده است.

$$f_{cc} = f_{co} \left(1 + 1.9 \left(\frac{f_{lu}}{f_{co}} \right)^{1.27} \right) \Rightarrow \quad (1)$$

$$f_{lu} = \frac{N t_f E_f \varepsilon_f}{D}$$

$$f_{cc} = f_{co} \left(1 + 0.27 \left(\frac{f_{lu}}{f_{co}} \right) + 5.55 \left(\frac{f_{lu}}{f_{co}} \right)^2 - 3.51 \left(\frac{f_{lu}}{f_{co}} \right)^3 \right) \quad (2)$$

$$\Rightarrow f_{lu} = \frac{N t_f E_f \varepsilon_f}{D}$$

$$f_{cc} = f_{co} \left(1 + 2.87 \left(\frac{f_{lu}}{f_{co}} \right)^{0.775} \right) \quad (3)$$

$$\Rightarrow f_{lu} = \frac{2 N t_f E_f \varepsilon_f}{D}$$

$$f_{cc} = f_{co} \left(1 + 5.285 \left(\frac{f_{lu}}{f_{co}} \right) \right) \quad (4)$$

$$\Rightarrow f_{lu} = k_e \rho_f E_f \varepsilon_f$$

$$\rightarrow k_e = \frac{\varepsilon_{fl_{max}}}{\varepsilon_{fu}} = 0.492; \quad \rho_f = \frac{4 t_f}{D}$$

$$f_{cc} = f_{co} \left(1 + 0.913 \left(\frac{f_{lu}}{f_{co}} \right)^{0.5} \right) \quad (5)$$

$$\Rightarrow f_{lu} = \frac{1}{2} k_e \rho_f E_f \varepsilon_f$$

$$\rightarrow k_e = 0.25 \left[\left(\frac{\rho_f E_f}{f_{co}} \right)^{0.3} - 1 \right]; \quad \rho_f = \frac{4 t_f}{D}$$

$$f_{cc} = f_{co} \left(1 + 3.1 \left(\frac{f_{lu}}{f_{co}} \right) \right) \quad (6)$$

$$\Rightarrow f_{lu} = \frac{2 N t_f E_f \varepsilon_f}{D}$$

در رابطه‌های (۱) تا (۶)، f_{co} بیانگر مقاومت فشاری ستون در حالت بدون محصورسازی، N تعداد لایه‌های کامپوزیت پایه‌معدنی پوشاننده ستون، t_f ضخامت معادل الیاف در

در کامپوزیت (ϵ_f) و مقاومت فشاری ستون در حالت بدون محصورسازی (f_{co}) طراحی شده است. خروجی این شبکه، مقدار مقاومت فشاری ستون در حالت محصورشده (f_{cc}) می‌باشد.

در این پژوهش، از کل مجموعه داده‌های گردآوری‌شده، ۸۰٪ برای فرآیند آموزش و ۲۰٪ باقی‌مانده برای مرحله آزمون بر روی داده‌های دیده‌نشده اختصاص یافته است. در میان داده‌های مرحله آموزش نیز، ۷۰٪ به آموزش (Train)، ۱۵٪ به آزمون (Test) و ۱۵٪ دیگر به صحت‌سنجی (Validation) مدل اختصاص داده شد.

۴-۲- شبکه عصبی مصنوعی بهینه

به منظور تعیین ساختار بهینه شبکه عصبی مصنوعی (ANN)^۵، از مدل پیشرو با پس‌انتشار^۶ استفاده شد. این شبکه شامل یک لایه ورودی، یک لایه پنهان با تابع فعال‌سازی tan-sigmoid که در رابطه (۸) نشان داده شده است و یک لایه خروجی با تابع انتقال خطی^۷ می‌باشد [۴۷].

$$\tan - \text{sigmoid} = \frac{2}{1 + e^{-2x}} - 1 \quad (8)$$

آموزش وزن‌های اتصال‌دهنده نورون‌های شبکه با استفاده از مدل پیشرو با پس‌انتشار و الگوریتم Levenberg-Marquardt در نرم‌افزار MATLAB انجام شد [۴۸]. پژوهش‌های پیشین نشان داده‌اند که استفاده از یک لایه پنهان برای حل مساله‌های غیرخطی مختلف مناسب است. برای تعیین تعداد بهینه نورون‌های پنهان و یافتن معماری مناسب شبکه عصبی مصنوعی در این پژوهش، تعداد نورون‌های لایه پنهان بین ۳ تا ۲۵ در نظر گرفته شد. برای انتخاب بهترین ساختار شبکه، از معیارهای آماری معتبر شامل خطای میانگین مربعات

(MSE)^۸، ضریب هم‌بستگی خطی (R)^۹ و خطای درصد میانگین مطلق (MAPE)^{۱۰} بهره گرفته شد. براساس این معیارها، شاخص‌های ارزیابی هر الگو محاسبه و نتیجه‌ها براساس کیفیت پاسخ‌ها رتبه‌بندی شدند. در نهایت، رتبه‌های اختصاص داده‌شده به هر الگو جمع شد و براساس مجموع رتبه‌ها، معماری بهینه شبکه انتخاب گردید. نتیجه‌های رتبه‌بندی شبکه عصبی مصنوعی در پیش‌بینی مقاومت فشاری ستون‌ها در حالت محصورشده (f_{cc}) در جدول ۳ و شکل ۴ ارائه شده است.

همان‌طور که در جدول ۳ و شکل ۴ مشاهده می‌شود، شبکه عصبی با ۹ نورون پنهان بهترین عملکرد را در پیش‌بینی مقاومت فشاری نمونه‌ستون در حالت محصورشده (f_{cc}) نشان داده است. در این شبکه، مقدارهای ضریب هم‌بستگی خطی R برای مراحل آموزش و آزمون به ترتیب برابر ۰/۹۹۵۲ و ۰/۹۹۹۰ می‌باشد و مقدارهای خطای MSE به ترتیب برابر ۰/۰۰۰۱۸۷ و ۰/۰۰۰۰۶۹ و خطای MAPE به ترتیب برابر ۱/۶۸۷۱٪ و ۰/۶۷۹۵٪ به دست آمده است. شکل ۵ نمای شماتیک شبکه عصبی انتخابی را نشان می‌دهد.

۴-۳- الگوی شبکه عصبی و رابطه پیشنهادی

استفاده کارآمد از شبکه‌های عصبی مصنوعی مستلزم تعیین وزن‌ها و مقدارهای بایاس در لایه‌های مختلف شبکه می‌باشد. برخلاف بسیاری از پژوهش‌های پیشین که تنها به ارائه ساختار شبکه بسنده شده است، در این پژوهش به منظور افزایش کارایی و فراهم آوردن امکان بهره‌مندی سایر پژوهشگران از نتیجه‌ها، وزن‌ها و مقدارهای بایاس شبکه در لایه‌های مختلف الگوریتم ANN برای پیش‌بینی مقاومت فشاری نمونه‌ستون در حالت محصورشده (f_{cc}) در جدول ۴ گزارش شده است. با

⁸ Mean Squared Error

⁹ Linear Correlation Coefficient

¹⁰ Mean Absolute Percentage Error

⁵ Artificial Neural Network

⁶ Feedforward Backpropagation

⁷ Linear activation

نورون‌ها در لایه پنهان، X_i مقدارهای نرمال‌شده ورودی‌های شبکه، m برابر تعداد متغیرهای ورودی، w_{ik} بیان‌گر وزن ارتباطی بین لایه نام ورودی و k امین نورون در لایه پنهان، w_k وزن ارتباطی بین k امین نورون در لایه پنهان و نورون مستقل خروجی، b_{hk} بیان‌گر بایاس در k امین نورون لایه پنهان و b_0 برابر مقدار بایاس در لایه خروجی است.


استفاده از داده‌های این جدول و مقدارهای ورودی (D)، می‌توان مقدارهای برآورد شده f_{cc} را به طور مستقیم مطابق با رابطه (۹) محاسبه کرد [۴۹]:

$$f_{cc} = f_n \left\{ b_0 + \sum_{k=1}^h \left[w_k f_a \left(b_{hk} + \sum_{i=1}^m w_{ik} X_i \right) \right] \right\} \quad (9)$$


در این رابطه، f_{cc} نشان‌دهنده مقدار نرمال‌شده مقاومت فشاری نمونه‌ستون در حالت محصورشده، f_n تابع انتقال خطی، f_a تابع فعال‌سازی tan-sigmoid، h بیان‌گر تعداد

جدول ۳- ارزیابی تعداد نورون‌ها در لایه‌های پنهان شبکه عصبی مصنوعی

عامل‌های ارزیابی						تعداد نورون در لایه پنهان
MAPE		MSE		R		
آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	
۰.۷۱۶۴	۸.۳۰۶۱	۰.۰۰۲۳۷۹۰	۰.۰۰۲۴۱۵۵	۰.۸۷۵۵	۰.۹۳۶۱	۳
۰.۰۹۵۷	۱۰.۳۹۶۵	۰.۰۰۱۳۸۹۸	۰.۰۰۳۴۲۱۱	۰.۹۴۱۶	۰.۹۰۸۲	۴
۳.۹۷۴۷	۴.۳۰۹۶	۰.۰۰۰۷۷۵۸	۰.۰۰۰۸۹۱۱	۰.۹۶۰۵	۰.۹۷۶۹	۵
۴.۶۸۳۰	۴.۴۵۰۸	۰.۰۰۰۸۱۱۱	۰.۰۰۱۰۳۳۹	۰.۹۶۳۳	۰.۹۷۳۲	۶
۴.۰۷۹۸	۳.۱۴۸۸	۰.۰۰۱۰۳۵۸	۰.۰۰۰۸۱۳۲	۰.۹۵۹۲	۰.۹۷۹۰	۷
۱.۲۴۲۳	۲.۴۹۸۲	۰.۰۰۰۰۷۱۸	۰.۰۰۰۰۳۹۶۵	۰.۹۹۸۰	۰.۹۹۱۲	۸
۰.۶۷۹۵	۱.۶۸۷۱	۰.۰۰۰۰۰۶۹	۰.۰۰۰۰۱۸۷۰	۰.۹۹۹۰	۰.۹۹۵۲	۹
۲.۰۷۳۵	۲.۸۷۹۴	۰.۰۰۰۰۱۷۱۰	۰.۰۰۰۰۳۲۴۹	۰.۹۹۱۵	۰.۹۹۱۶	۱۰
۱.۲۹۲۱	۱.۹۴۱۱	۰.۰۰۰۰۵۴۹	۰.۰۰۰۰۲۸۶۳	۰.۹۹۷۳	۰.۹۹۳۲	۱۱
۲.۸۷۰۰	۳.۴۳۴۹	۰.۰۰۰۰۲۵۷۲	۰.۰۰۰۰۴۷۱۰	۰.۹۸۷۳	۰.۹۸۷۹	۱۲
۴.۴۸۴۵	۳.۵۱۴۱	۰.۰۰۰۰۷۶۰۹	۰.۰۰۰۰۵۲۰۵	۰.۹۶۱۳	۰.۹۸۶۶	۱۳
۱.۷۵۵۵	۲.۲۹۸۹	۰.۰۰۰۰۱۶۱۰	۰.۰۰۰۰۲۵۸۵	۰.۹۹۲۲	۰.۹۹۳۴	۱۴
۳.۸۱۶۴	۴.۰۰۰۷	۰.۰۰۰۰۵۹۳۷	۰.۰۰۰۰۷۴۱۸	۰.۹۷۰۰	۰.۹۸۰۸	۱۵
۲.۵۳۷۷	۳.۲۷۶۸	۰.۰۰۰۰۲۱۵۳	۰.۰۰۰۰۶۱۴۴	۰.۹۹۰۵	۰.۹۸۴۱	۱۶
۱.۲۵۸۷	۱.۷۶۳۱	۰.۰۰۰۰۵۵۹	۰.۰۰۰۰۲۳۲۶	۰.۹۹۷۲	۰.۹۸۶۶	۱۷
۲.۰۰۷۴	۳.۳۵۲۹	۰.۰۰۰۰۱۳۲۳	۰.۰۰۰۰۶۸۰۳	۰.۹۹۳۷	۰.۹۸۲۴	۱۸
۱.۷۲۴۶	۲.۳۱۴۰	۰.۰۰۰۰۱۳۱۰	۰.۰۰۰۰۴۹۸۲	۰.۹۹۳۸	۰.۹۸۷۲	۱۹
۲.۲۸۹۳	۳.۲۳۶۸	۰.۰۰۰۰۱۷۶۵	۰.۰۰۰۰۴۹۸۵	۰.۹۹۱۴	۰.۹۸۷۲	۲۰
۲.۷۹۴۵	۳.۶۷۲۳	۰.۰۰۰۰۴۳۷۶	۰.۰۰۰۰۵۸۷۸	۰.۹۸۰۵	۰.۹۸۴۸	۲۱
۱.۰۴۷۲	۲.۴۳۴۹	۰.۰۰۰۰۰۶۵۰	۰.۰۰۰۰۴۷۸۲	۰.۹۹۶۸	۰.۹۸۷۷	۲۲
۳.۹۰۶۰	۳.۶۵۱۶	۰.۰۰۰۰۵۳۸۱	۰.۰۰۰۰۵۷۱۸	۰.۹۷۳۰	۰.۹۸۵۲	۲۳
۱.۵۳۶۸	۱.۷۱۶۷	۰.۰۰۰۰۱۲۰۰	۰.۰۰۰۰۴۳۵۱	۰.۹۹۴۱	۰.۹۹۱۵	۲۴
۱.۵۵۶۴	۳.۱۳۹۵	۰.۰۰۰۰۰۶۲۷	۰.۰۰۰۰۶۱۷۳	۰.۹۹۶۹	۰.۹۸۴۱	۲۵



شکل ۴- مقدار ضریب همبستگی و خطای MSE در شبکه‌های عصبی مصنوعی با تعداد نورون‌های مختلف



شکل ۵- نمای شماتیک الگوی شبکه عصبی با یک لایه پنهان

جدول ۴- مقدار وزن‌ها و بایاس‌های شبکه عصبی

بایاس‌ها		وزن‌ها							نورون‌های لایه پنهان
		W_k	W_{ik}						
b_0	b_{hk}		f_{co} (Mpa)	ε_f (%)	tf (mm)	E_f (Gpa)	N	D (mm)	
۸.۵۴۸	-۱۳.۴۳	۳۰.۲۵۶	-۲۸.۰۹	۳۰.۶۴	-۱۲.۶۰۴	۳۱.۷۱۸	۲.۷۲۵	۲۱.۳۲۴	نورون پنهان ۱
	۴.۹۹۹	-۲۸.۷۵	-۱.۶۴۳	-۳.۷۶۹	۸.۶۷۶	-۳.۶۰۹	۰.۵۸۳	-۲.۵۹۱	نورون پنهان ۲
	-۷.۶۰۸	-۱.۷۳۵	۰.۰۵۱	۵.۹۲۸	۲.۵۳	۴.۱۷۸	-۱.۷۲۳	۴.۲۵۷	نورون پنهان ۳
	۰.۱۵۷	۲.۵۷۸	۰.۳۲۲	۱.۹۵۹	۱.۵۶۳	۱.۹۰۷	-۱.۰۶۶	-۴.۲۵۸	نورون پنهان ۴
	-۰.۹۱۲	-۲.۳۴۴	۲.۰۴۲	۱.۶۳۸	-۶.۹۹۳	۳.۴۳۵	-۰.۵۸	-۳.۹۴۷	نورون پنهان ۵
	۱۵.۷۴۱-	۸۱.۹۷۸	۱۲.۱۲۹	۱۱.۷۶۴	۹.۱۶۳	۷.۷۳۷	-۰.۰۰۶	-۱۱.۲۷۶	نورون پنهان ۶
	-۳.۶۲۲	-۰.۸۸۲	-۰.۶۹۹	۵.۳۳۲	۴.۱۶۳	۳.۱۸۳	-۱.۹۶۹	۱.۲۲۳	نورون پنهان ۷
	۵۰.۷۲۹	۴۳.۸۸۲	-۸۶.۷۳۱	-۲۱.۵۲۱	-۲۵.۸۲۲	-۴.۲۴۸	۰.۸۴۷	۱۱.۵۸	نورون پنهان ۸
	-۸۶.۵۰۹	۰.۰۸۹	۱۷۷.۰۶۳	۱۲.۷۸	-۱.۵۶۳	۵۵.۷۳۱	۳۸.۷۴۶	-۱۳.۳۷۹	نورون پنهان ۹

با استفاده از وزن‌ها و بایاس‌های لایه پنهان (جدول ۴) از رابطه (۱۱) محاسبه می‌شود و مقدارهای به‌دست آمده در رابطه (۱۰) قرار می‌گیرند تا خروجی مقیاس‌شده شبکه به دست آید. در پایان، با استفاده از رابطه معکوس (۷)، خروجی شبکه به مقیاس واقعی بازگردانده می‌شود تا مقدار نهایی مقاومت فشاری نمونه‌ستون محصورشده با کامپوزیت‌های پایه‌معدنی مشخص شود. این فرآیند امکان استفاده مستقیم از وزن‌ها و بایاس‌ها بدون نیاز به آموزش مجدد شبکه را فراهم می‌کند و شفافیت و قابلیت بازتولید نتیجه‌ها را افزایش می‌دهد.

$$f_{cc} = 30.256A_1 - 2.875A_2 - 1.735A_3 + 2.578A_4 - 2.344A_5 + 81.978A_6 - 0.882A_7 + 43.882A_8 + 0.089A_9 + 8.548 \quad (10)$$

$$\begin{bmatrix} A_1 \\ A_2 \\ A_3 \\ A_4 \\ A_5 \\ A_6 \\ A_7 \\ A_8 \\ A_9 \end{bmatrix} = \text{Tansig} \left(\begin{bmatrix} 21.324 & 2.725 & 31.718 & -12.604 & 30.640 & -28.090 \\ -2.591 & 0.583 & -3.609 & 8.676 & -3.769 & -1.643 \\ 4.257 & -1.723 & 4.178 & 2.530 & 5.928 & 0.051 \\ -4.258 & -1.066 & 1.907 & 1.563 & 1.959 & 0.322 \\ -3.947 & -0.580 & 3.435 & -6.993 & 1.638 & 2.042 \\ -11.276 & -0.006 & 7.737 & 9.163 & 11.764 & 12.129 \\ 1.223 & -1.969 & 3.183 & 4.163 & 5.332 & -0.699 \\ 11.580 & 0.847 & -4.248 & -25.822 & -21.521 & -86.731 \\ -13.379 & 38.746 & 55.731 & -1.563 & 12.780 & 177.063 \end{bmatrix} \begin{bmatrix} D \\ N \\ E_f \\ t_f \\ \varepsilon_f \\ f_{cc} \end{bmatrix} \right) + \begin{bmatrix} -13.430 \\ 4.999 \\ -7.608 \\ 0.157 \\ -0.912 \\ -15.741 \\ -3.622 \\ 50.729 \\ -86.509 \end{bmatrix} \quad (11)$$

ضریب همبستگی خطی (R) ^{۱۵} و ضریب اطمینان (R^2) ^{۱۶} مطابق با رابطه‌های (۱۲) تا (۱۶) مورد ارزیابی قرار گرفته‌اند. نتیجه‌های این ارزیابی در جدول ۵ گزارش شده است [۵۰].

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (12)$$

$$MAPE = \frac{1}{n} \left[\frac{\sum_{i=1}^n |O_i - P_i|}{\sum_{i=1}^n |O_i|} \right] \times 100 \quad (13)$$

۵- ارزیابی و مقایسه نتیجه‌ها

در این بخش از پژوهش، نتیجه‌های به‌دست آمده از الگوی بهینه‌ی شبکه‌ی عصبی مصنوعی (ANN) برای پیش‌بینی مقدار مقاومت فشاری نمونه‌ستون در حالت محصورشده (f_{cc}) در هریک از مرحله‌های آموزش و آزمون به کمک عامل‌های رایج در ارزیابی خطا و کارایی شامل خطای میانگین مربع‌ها (MSE)^{۱۱}، خطای ریشه‌ی میانگین مربع‌ها (RMSE)^{۱۲}، خطای مطلق میانگین (MAE)^{۱۳}، خطای درصد مطلق میانگین (MAPE)^{۱۴}،

¹⁴ Mean Absolute Percentage Error

¹⁵ Linear Correlation Coefficient

¹⁶ Coefficient of Determination

¹¹ Mean Squared Error

¹² Root Mean Squared Error

¹³ Mean Absolute Error

داده‌های در نظر گرفته شده، $\bar{O}$ میانگین مقدارهای اندازه‌گیری‌شده و $\bar{P}$ میانگین مقدارهای برآورد شده است.

مقایسه داده‌های اندازه‌گیری‌شده و مقدارهای پیش‌بینی‌شده حاصل از الگوی ANN برای مقاومت فشاری ستون در حالت محصورشده (f_{cc})، در مرحله‌های آموزش، آزمون و همچنین کل داده‌ها، در شکل ۶ ارایه شده است. در این شکل، خط قطری نشان‌دهنده حالت ایده‌آل انطباق کامل بین مقدارهای اندازه‌گیری‌شده و پیش‌بینی‌شده است که در صورت دستیابی به ضریب همبستگی خطی (R) برابر با ۱ رخ می‌دهد.

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (15)$$

$$R = \left[\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \right] \quad (16)$$

در رابطه‌های (۱۲) تا (۱۶)، O_i بیان‌گر مقدار اندازه‌گیری‌شده و P_i نماینده مقدار برآوردشده، n تعداد

جدول ۵- نتیجه الگوی پیشنهادی ANN به کمک عامل‌های رایج ارزیابی کارایی و خطا

روش	دسته‌بندی داده‌ها	معیارهای ارزیابی کارایی و خطا				
		MAPE (%)	MAE	RMSE	MSE	R ²
ANN	آموزش	۲.۳۴	۰.۶۲۴۴	۱.۰۴۲۳	۱.۰۸۶۵	۰.۹۹۳۷
	آزمون	۰.۵۹	۰.۱۵۶۸	۰.۲۲۰۱	۰.۰۴۸۴	۰.۹۹۹۴
	همه داده‌ها	۱.۹۸	۰.۵۲۷۸	۰.۹۳۳۹	۰.۸۷۲۱	۰.۹۹۴۴

است. همان‌طور که مشاهده می‌شود، مقدار میانگین MSE در ۵ بخش در نظر گرفته‌شده برابر با ۰/۸۶۸۲ است که با مقدار خطای MSE گزارش‌شده برای همه داده‌های در مدل ANN پیشنهادی در جدول ۵ (۰/۸۷۲۱) اختلاف اندکی دارد و این موضوع بیان‌گر پایداری مدل و نبود بیش‌برازش قابل توجه است.


برای بررسی پراکندگی خطاها و شناسایی داده‌های پرت (outlier)، هیستوگرام خطای درصدی مدل پیشنهادی ANN به‌همراه انحراف معیار و میانه خطاها در شکل ۱۰ رسم شده است. همان‌طور که مشاهده می‌شود، بیش از ۸۵٪ داده‌ها در بازه ± 1 انحراف معیار از میانگین خطا قرار دارند و میانگین خطا بسیار به صفر نزدیک است، که نشان‌دهنده عدم وجود سوگیری سامانه‌ای در مدل ANN پیشنهادی است. تنها تعداد محدودی از داده‌ها دارای خطای بیش از $\pm 5\%$ هستند که نمایان‌گر وجود

شکل ۷ میزان خطای داده‌ها در مرحله‌های آموزش و آزمون را به‌همراه کران‌های بالا و پایین ضریب پراکندگی (CoV) در الگوریتم ANN نمایش می‌دهد. همچنین، شکل ۸ نسبت نتیجه‌های آزمایشگاهی مقاومت فشاری ستون‌های محصورشده (f_{cc-e}) به مقدارهای متناظر پیش‌بینی‌شده به کمک شبکه عصبی مصنوعی (f_{cc-p}) را نشان می‌دهد.


برای بررسی تعمیم‌پذیری مدل و اطمینان از عدم بیش‌برازش، اعتبارسنجی متقابل k بخشی (k-fold cross-validation) با ۵ بخش ($k=5$) انجام شد [۵۱]. در این روش، داده‌ها به پنج بخش تقسیم شدند که در هر مرحله چهار بخش برای آموزش و یک بخش برای آزمون مدل استفاده شد و این فرایند پنج بار تکرار شد تا همه داده‌ها در نقش داده آزمون قرار گیرند. خطای میانگین مربعات (MSE) برای هر بخش و همچنین میانگین کلی مقدارهای MSE در شکل ۹ نشان داده شده

می‌باشد که اثری بر عملکرد کلی مدل ندارد.


تعداد اندکی داده‌های پرت در داده‌های آزمایشگاهی




شکل ۶- برآورد f_{cc} به کمک الگوریتم ANN برای داده‌های مرحله‌ای: الف) آموزش، ب) آزمون و ج) کل داده‌ها




شکل ۷- مقدار خطای نسبی خروجی‌های شبکه عصبی



شکل ۸- نسبت خروجی‌های شبکه عصبی به نتیجه‌های آزمایشگاهی



شکل ۹- اعتبارسنجی متقابل پنج تایی و میانگین خطای MSE برای مدل پیشنهادی



شکل ۱۰- هیستوگرام خطای درصدی پیش‌بینی‌های مدل پیشنهادی ANN


سایر رابطه‌های موجود در پژوهش‌های پیشین نشان می‌دهند.

تحلیل نتیجه‌های ارایه‌شده در جدول ۶، شکل ۱۱ و شکل ۱۲ نشان می‌دهد که مقدارهای مقاومت فشاری نمونه‌ستون در حالت تقویت‌شده (f_{cc}) به‌دست آمده از شبکه عصبی مصنوعی، از دقت و برازش به‌مراتب بالاتری نسبت به سایر رابطه‌های موجود و آیین‌نامه برخوردار است.


نتیجه‌های حاصل از الگوی شبکه عصبی مصنوعی (ANN) با مقدارهای پیش‌بینی‌شده به کمک رابطه‌های در پژوهش‌های پیشین و آیین‌نامه‌ها مقایسه شده است. جدول ۶ خلاصه این مقایسه‌ها را ارایه می‌دهد. افزون بر این، شکل‌های ۱۱ و ۱۲ مقدارهای مقاومت فشاری ستون در حالت محصورشده (f_{cc}) به‌دست‌آمده از الگوی پیشنهادی ANN را در مقایسه با مقدارهای حاصل از

جدول ۶- مقایسه آماری نتیجه الگوریتم‌های ANN و رابطه‌های موجود در پژوهش‌های پیشین و آیین‌نامه‌ها

روش	R	R ²	MSE	RMSE	MAE	MAPE (%)
روش پیشنهادی این پژوهش (ANN)	۰.۹۹۷۲	۰.۹۹۴۴	۰.۸۷۲۱	۰.۹۳۴	۰.۵۲۸	۱.۹۸
Triantafillou و همکاران [۱۲]	۰.۷۳۷۳	۰.۵۴۳۵	۱۲۱.۶۰۴۶	۱۱.۰۲۷	۸.۹۳	۸۹.۷۸
Ortlepp [۳۴]	۰.۷۰۱۱	۰.۴۹۱۶	۱۳۰.۵۸۳۳	۱۱.۴۲۷	۹.۴۷۵	۹۱.۱۳
DeCaso و همکاران [۳۵]	۰.۵۹۹۹	۰.۳۵۹۹	۳۶۵.۳۸۱۲	۱۹.۱۱۵	۱۲.۰۸۴	۱۵۸.۱۵
Ombres [۳۷]	۰.۳۳۶۹	۰.۱۱۳۵	۵۲۵.۹۲۶۱	۲۲.۹۳۳	۱۲.۱۳۴	۱۸۸.۲۵
Mazucca و Ombres [۳۹]	۰.۷۱۶	۰.۵۱۲۷	۱۱۸.۰۵۶۶	۱۰.۸۶۵	۸.۱۸۸	۹۶.۲۹
ACI [۴۵]	۰.۵۲۱۸	۰.۲۷۲۳	۴۰۲.۲۰۰۷	۲۰.۰۵۵	۱۱.۲۹۳	۱۴۵.۱۴



شکل ۱۱- مقایسه نتیجه‌های الگوریتم‌های پیشنهادی ANN با رابطه‌های موجود: (الف) ANN، (ب) Triantafillou و همکاران، (ج) Ortlepp، (د) DeCaso و همکاران، (ه) ACI، (و) Ombres، (ز) Ombres و Mazzuca



شکل ۱۲- مقایسه نسبت خروجی‌های شبکه عصبی پیشنهادی و رابطه‌های موجود به نتیجه‌های آزمایشگاهی: (الف) ANN، (ب)

Triantafillou و همکاران، (ج) Ortlepp، (د) DeCaso و همکاران، (ه) ACI، (و) Ombres، (ز) Mazzuca و Ombres

در میان رابطه‌های موجود در پژوهش‌های پیشین و

۶- تحلیل حساسیت


در این پژوهش، به منظور ارزیابی اثر هر یک از عامل‌های ورودی شامل قطر نمونه ستون (D)، تعداد لایه‌های کامپوزیت پایه معدنی که نمونه ستون را پوشش داده‌اند (N)، ضریب کشسانی الیاف (E_f)، ضخامت معادل الیاف (t_f)، کرنش نهایی الیاف در کامپوزیت استفاده‌شده (ϵ_f) و مقاومت فشاری نمونه ستون در حالت محصورنشده

آیین‌نامه، رابطه پیشنهادی در پژوهش Triantafillou و همکاران [۱۲]، Ombres و Mazzuca [۳۹]، Ortlepp [۳۴]، DeCaso و همکاران [۳۵]، آیین‌نامه ACI [۴۵] و در پایان Ombres [۳۷] به ترتیب با ضریب‌های همبستگی خطی (R) برابر با ۰/۷۳۷۲، ۰/۷۱۶۰، ۰/۷۰۱۱، ۰/۵۹۹۹، ۰/۵۲۱۸ و ۰/۳۳۶۹، از مناسب‌ترین روش تا کم‌دقت‌ترین روش‌های موجود برای پیش‌بینی مقدار مقاومت فشاری نمونه ستون در حالت محصورشده

$$Q_i = \sum_{j=1}^{n_{hidden}} \frac{|w_{ji}^{(1)}|}{\sum_{l=1}^{n_{inputs}} |w_{jl}|} \cdot |w_j^{(2)}| \quad (17)$$

$$\Rightarrow Q_{i,ratio} = \frac{Q_i}{\sum_{k=1}^{n_{inputs}} Q_k} \times 100$$

در رابطه (۱۷)، n_{inputs} نشان‌دهنده تعداد کل عامل‌های ورودی، n_{hidden} بیانگر تعداد نورون‌ها در لایه پنهان، $w_{ji}^{(1)}$ وزن ارتباطی بین ورودی i ام و j امین نورون در لایه پنهان است و $w_j^{(2)}$ بیانگر وزن بین j امین نورون در لایه پنهان و عامل خروجی می‌باشد. در رابطه (۱۷)، مجموع مقدارهای $Q_{i,ratio}$ برای همه عامل‌های ورودی باید برابر با ۱۰۰ درصد باشد تا توزیع کامل اهمیت نسبی بین ورودی‌ها تضمین شود. شکل ۱۳ مقدار اهمیت‌های نسبی به‌دست آمده از رابطه (۱۷) برای مقدار مقاومت فشاری نمونه‌ستون در حالت محصورشده (f_{cc}) را نشان می‌دهد.



شکل ۱۳- اهمیت نسبی عامل‌های ورودی بر مقدار مقاومت فشاری نمونه‌ستون‌ها در حالت محصورشده (f_{cc})

عامل‌های ورودی اثرگذار بعدی شناسایی شدند. در مقابل، تعداد لایه‌های کامپوزیت پایه‌معدنی که سطح ستون را پوشش داده‌اند (N)، با نسبت ۵/۸۱٪ کم‌ترین میزان اثرگذاری را در تعیین مقاومت فشاری محصورشده داشته است.

نتیجه‌های تحلیل حساسیت نشان داد که تعداد لایه‌های محصورکننده کم‌ترین سهم را در افزایش مقاومت فشاری ستون‌های محصورشده با کامپوزیت‌های

(f_{co}) بر خروجی پیش‌بینی‌شده یعنی مقاومت فشاری نمونه‌ستون محصورشده (f_{cc}) تحلیل حساسیت انجام شده است.

در این تحلیل، هر عامل ورودی به‌طور جداگانه تغییر داده می‌شود، در حالی که سایر متغیرها ثابت نگه داشته می‌شوند تا اثر خاص آن عامل بر خروجی به‌طور جداگانه بررسی شود. از میان روش‌های موجود، در این پژوهش از روش Milne [۵۲] که در رابطه (۱۷) نشان داده شده است، به دلیل کاربرد گسترده و کارایی بالای آن در ارزیابی حساسیت، استفاده شده است. در رابطه (۱۷)، شاخص Q_i بیانگر میزان اثرگذاری یا اهمیت هر عامل ورودی بر خروجی نهایی الگوی ANN است و شاخص $Q_{i,ratio}$ نسبت اهمیت نرمال‌شده هر عامل ورودی را نسبت به سایر ورودی‌ها بیان می‌کند.

براساس نتیجه‌های ارایه‌شده در شکل ۱۳، مقاومت فشاری نمونه‌ستون در حالت محصورنشده (f_{co}) با نسبت ۲۰/۹۲٪ بیشترین اثر را بر مقاومت فشاری نمونه‌ستون در حالت محصورشده (f_{cc}) دارد. دیگر عامل‌های ورودی به ترتیب شامل ضخامت معادل الیاف (t_f) با نسبت ۱۹/۶۷٪، کرنش نهایی الیاف در کامپوزیت (E_f) با نسبت ۱۹/۳۰٪، ضریب کشسانی الیاف (E_f) با نسبت ۱۷/۳۱٪ و قطر نمونه‌ستون‌ها (D) با نسبت ۱۶/۹۷٪، به عنوان

علاوه بر این، نتایج تحلیل حساسیت به مهندسان کمک می‌کند تا عامل‌های کلیدی اثرگذار بر مقاومت فشاری ستون‌ها را شناسایی و کنترل کنند.

باید اشاره کرد که اگرچه پایگاه داده این پژوهش شامل ۹۲ نمونه آزمایشگاهی است، با توجه به تعداد عامل‌های ورودی و پیچیدگی شبکه عصبی استفاده‌شده، این حجم داده می‌تواند به‌عنوان یک محدودیت در تعمیم‌پذیری مدل مطرح شود. هرچند نتایج به‌دست آمده (R نزدیک به واحد و مقادیر بسیار کم خطاهای MSE و MAPE) نشان‌دهنده عملکرد مناسب مدل است، ولی برای افزایش اطمینان از قابلیت تعمیم مدل و کاهش خطر بیش‌برازش، پیشنهاد می‌شود در پژوهش‌های آینده از مجموعه داده‌های گسترده‌تر و داده‌های آزمایشگاهی جدید بهره‌گیری شود تا اعتبار نتایج تقویت شود.

هرچند مدل ANN توسعه‌یافته در این پژوهش توانایی بسیار بالایی در پیش‌بینی مقاومت فشاری ستون‌های محصورشده نشان داد، ولی باید توجه داشت که سایر روش‌های یادگیری ماشین (مانند SVM، Random Forest و XGBoost) نیز می‌توانند در مورد داده‌های ارایه‌شده در این پژوهش نتیجه‌های چشم‌گیری ارایه دهند. مقایسه این روش‌ها با ANN در پژوهش‌های آینده می‌تواند به انتخاب مدل بهینه و ایجاد چارچوب پیش‌بینی جامع‌تر کمک کند.

شایان توجه است که مدل پیشنهادی شبکه عصبی تنها براساس پایگاه داده شامل ستون‌های بتنی با مقطع دایره‌ای اعتبارسنجی شده است. بنابراین، نتیجه‌ها و دقت پیش‌بینی ارایه‌شده در این مطالعه محدود به ستون‌های دایره‌ای است و توانایی تعمیم مستقیم آن‌ها به ستون‌های با مقاطع مربعی یا مستطیلی وجود ندارد. این محدودیت در تفسیر نتیجه‌ها و کاربرد عملی مدل باید مدنظر قرار گیرد و پیشنهاد می‌شود برای کاربرد در مقطع‌های دیگر، داده‌های تجربی مرتبط جمع‌آوری و مدل دوباره آموزش و اعتبارسنجی شود.

پایه‌معدنی داشته است. علت این موضوع را می‌توان در چند عامل دانست. نخست آن‌که تمرکز این پژوهش بر کامپوزیت‌های پایه‌معدنی است که از نظر رفتار مکانیکی، انتقال تنش و تعامل الیاف و پایه تفاوت‌های قابل‌توجهی با کامپوزیت‌های پایه‌پلمیری رایج دارند و این تفاوت‌ها ممکن است باعث شود افزایش تعداد لایه‌ها در کامپوزیت‌های پایه‌معدنی اثر کمتری نسبت به کامپوزیت‌های پایه‌پلمیری داشته باشد. از طرف دیگر، دامنه تغییر تعداد لایه‌های محصورکننده در داده‌های آزمایشگاهی تنها شامل ۱ و ۲ لایه بوده است و این محدودیت باعث کاهش حساسیت مدل نسبت به این پارامتر شده است. علاوه بر آن، سایر عامل‌های مکانیکی از جمله مقاومت فشاری ستون بدون محصورشدگی، ضخامت الیاف و کرنش نهایی الیاف نقش غالب‌تری در پیش‌بینی مقاومت ایفا کرده‌اند و در میزان اثرگذاری تغییر تعداد لایه‌ها نقش داشته‌اند. بر این اساس، یافته‌های این پژوهش نشان می‌دهد که در مورد کامپوزیت‌های پایه‌معدنی، صرف افزایش تعداد لایه‌ها بدون بهینه‌سازی سایر پارامترهای طراحی نمی‌تواند بهبود قابل‌ملاحظه‌ای در مقاومت فشاری ایجاد کند و لازم است طراحی لایه‌بندی با در نظر گرفتن به ویژگی‌های کامپوزیت‌های پایه‌معدنی و شرایط بارگذاری ستون انجام شود.

۷- تحلیل نتیجه‌ها و افق‌های آینده

نتیجه‌های به‌دست آمده از مدل ANN نشان می‌دهد که این شبکه قادر است مقاومت فشاری ستون‌های محصورشده با کامپوزیت‌های پایه‌معدنی را با دقت بسیار بالا پیش‌بینی کند. از دیدگاه کاربردی، این یافته‌ها می‌توانند در پروژه‌های عمرانی برای طراحی ستون‌ها، انتخاب تعداد لایه‌های کامپوزیت، ارزیابی اثر تغییر عامل‌های ورودی و کاهش نیاز به آزمایش‌های گسترده آزمایشگاهی استفاده شوند. به‌کارگیری این مدل در تحلیل‌های مهندسی امکان صرفه‌جویی در زمان، کاهش هزینه‌ها و افزایش ایمنی سازه‌ها را فراهم می‌کند.

۸- نتیجه گیری

در این پژوهش، به منظور شناخت بهتر رفتار محصورکنندگی کامپوزیت‌های پایه معدنی، رابطه‌های موجود برای پیش‌بینی مقاومت فشاری ستون‌های محصورشده با این نوع تقویت‌کننده‌ها مورد ارزیابی قرار گرفت. بررسی یک پایگاه داده شامل نتیجه‌های آزمایش‌های تعیین مقاومت فشاری انجام‌شده بر روی ۹۲ نمونه ستون با مقطع دایره‌ای نشان داد که رابطه‌های موجود در پژوهش‌های پیشین و برخی آیین‌نامه‌ها، از دقت کافی برای برآورد مقاومت فشاری در تمام نمونه‌های محصورشده با کامپوزیت‌های پایه معدنی برخوردار نیستند. بر این اساس، با بهره‌گیری از شبکه‌های عصبی مصنوعی، رابطه‌ای نوین برای تخمین این مقاومت توسعه داده شد. در ادامه، یافته‌های حاصل از این پژوهش ارائه می‌شود:

(الف) شبکه پیشنهادی ANN با ۸۰٪ داده‌ها برای آموزش و ۲۰٪ برای آزمون، آموزش داده شد. بررسی ۳ تا ۲۵ نوروں در لایه پنهان نشان داد شبکه‌ای با ۹ نوروں بهترین عملکرد را دارد. شاخص‌های R برابر با ۰/۹۹۵۲ و ۰/۹۹۹۰، خطای MSE برابر برابر ۰/۰۰۰۱۸۷ و ۰/۰۰۰۰۰۶۹ و خطای MAPE برابر ۱/۶۸۷۱٪ و ۰/۶۷۹۵٪ به ترتیب در مرحله‌های آموزش و آزمون دقت بالای مدل پیشنهادی را نشان می‌دهند.

(ب) پیش‌بینی‌های مدل پیشنهادی ANN نسبت به

رابطه‌های تجربی و آیین‌نامه‌ها دقت بالاتری دارند. رتبه‌بندی رابطه‌های پیشین براساس R نشان داد رابطه پیشنهادی Triantafillou و همکاران [۱۲] (با مقدار R برابر با ۰/۷۳۷۲)، دقیق‌ترین و رابطه پیشنهادی Ombres [۳۷] (با مقدار R برابر با ۰/۳۳۶۹) کم‌دقت‌ترین هستند. مدل پیشنهادی ANN در این پژوهش (با مقدار R برابر با ۰/۹۹۷۲) عملکرد برتر و کاربرد عملی برای طراحی ستون‌های محصورشده ارائه می‌دهد.

(پ) برای فراهم‌سازی بازتولید مدل پیشنهادی به کمک سایر پژوهش‌گران، وزن‌ها و بایاس‌های لایه‌های مختلف شبکه پیشنهادی ANN در این پژوهش ارائه شد، تا امکان استفاده مستقیم در پیش‌بینی مقاومت فشاری ستون‌های محصورشده با کامپوزیت‌های FRIM فراهم شود.

(ت) تحلیل حساسیت نشان داد مقاومت فشاری نمونه‌ستون در حالت محصورنشده (f_{co}) با نسبت اهمیت ۲۰/۹۲ بیش‌ترین اثر و تعداد لایه‌های کامپوزیت (N) با نسبت اهمیت ۵/۸۱ کم‌ترین اثر را بر مقاومت فشاری ستون‌های محصورشده دارد.

References

- [1] Dinh NH, Park SH, Choi KK. Effect of dispersed micro-fibers on tensile behavior of uncoated carbon textile-reinforced cementitious mortar after high-temperature exposure. *Cement and Concrete Composites*. 2021; 118: 103949. doi: 10.1016/j.cemconcomp.2021.103949
- [2] Jahangir H, Esfahani MR. Experimental analysis on tensile strengthening properties of steel and glass fiber reinforced inorganic matrix composites. *Scientia Iranica*. 2021 Jun 1; 28(3): 1152-1166. doi: 10.24200/sci.2020.54787.3921
- [3] Solouki A, Tataranni P, Sangiorgi C. Mixture Optimization of Concrete Paving Blocks Containing Waste Silt. *Sustainability*. 2022; 14(1): 451. doi: 10.3390/su14010451
- [4] Foden A, Balaguru P, Lyon R, Davidovits J. High temperature inorganic resin for use in fiber reinforced composites. In: *First International Conference on Composites in Infrastructure*. Tucson, Arizona. 1996; 166-177.
- [5] Jahangir H, Esfahani MR. Investigating loading rate and fibre densities influence on SRG - concrete bond behaviour. *Steel and Composite Structures*. 2020; 34(6): 877-889. doi: 10.12989/scs.2020.34.6.877

- [6] De Santis S, Carozzi FG, de Felice G, Poggi C. Test methods for Textile Reinforced Mortar systems. *Composites Part B: Engineering*. 2017; 127: 121-132. **doi: 10.1016/j.compositesb.2017.03.016**
- [7] Jahangir H, Soleymani A, Esfahani MR. Investigating the Confining Effect of Steel Reinforced Polymer and Grout Composites on Compressive Behavior of Square Concrete Columns. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*. 2023; 47(2): 775-791. **doi: 10.1007/s40996-022-00917-7**
- [8] Gardiner T, Currie B. Flexural behaviour of composite cement sheets using woven polypropylene mesh fabrics. *International Journal of Cement Composites and Lightweight Concrete*. 1983 Aug; 5(3): 193-197. **doi: 10.1016/0262-5075(83)90006-4**
- [9] Curbach M, Jesse F. High-Performance Textile-Reinforced Concrete. *Structural Engineering International*. 1999; 9(4): 289-291. **doi: 10.2749/101686699780481745**
- [10] Kurtz S, Balaguru P. Comparison of Inorganic and Organic Matrices for Strengthening of RC Beams with Carbon Sheets. *Journal of Structural Engineering*. 2001 Jan; 127(1): 35-42. **doi: 10.1061/(ASCE)0733-9445(2001)127:1(35)**
- [11] Wu HC, Teng J. Concrete confined with fiber reinforced cement based thin sheet composites. In: *Fibre-Reinforced Polymer Reinforcement for Concrete Structures*. World Scientific Publishing Company; 2003; 591-600. **doi: 10.1142/9789812704863_0055**
- [12] Triantafillou TC. TC, Papanicolaou CG, CG, Zissimopoulos PP., Laourdekis TT. Concrete Confinement with Textile-Reinforced Mortar Jackets. *ACI Structural Journal*. 2006; 103(1): 28-37. **doi: 10.14359/15083**
- [13] Bournas DA, Lontou PV, Papanicolaou CG, Triantafillou TC. Textile-reinforced mortar versus fiber-reinforced polymer confinement in reinforced concrete columns. *ACI Structural Journal*. 2007 Nov 1; 104(6): 740-748.
- [14] Ombres L. Confinement effectiveness in concrete strengthened with fiber reinforced cement based composite jackets. In: *Proceedings of the 8th international symposium on fiber reinforced polymer reinforcement for concrete structures*. Patras, Greece; 2007; 16-18.
- [15] y Basalo FJDC, Matta F, Nanni A. Fiber reinforced cementitious matrix composites for infrastructure rehabilitation. *Composites & Polycon*. 2009; 1: 1-12.
- [16] Colajanni P, De Domenico F, Maugeri N, Recupero A, Spinella N, Mantegazza G. Experimental results of RC columns strengthened with fibre reinforced cementitious mortars. In: *Proceedings of 3rd International Conference on Concrete Repair, Rehabilitation and Retrofitting*. Cape Town, South Africa: CRC Press - Taylor & Francis Group; 2012; 1137-1143.
- [17] Colajanni P, De Domenico F, Recupero A, Spinella N. Concrete columns confined with fibre reinforced cementitious mortars: Experimentation and modelling. *Construction and Building Materials*. 2014; 52: 375-384. **doi: 10.1016/j.conbuildmat.2013.11.048**
- [18] Trapko T. Fibre Reinforced Cementitious Matrix confined concrete elements. *Materials & Design*. 2013; 44: 382-391. **doi: 10.1016/j.matdes.2012.08.024**
- [19] Nematzadeh M, Mousavimehr M, Shayanfar J, Omidalizadeh M. Eccentric compressive behavior of steel fiber-reinforced RC columns strengthened with CFRP wraps: Experimental investigation and analytical modeling. *Engineering Structures*. 2021; 226: 111389. **doi: 10.1016/j.engstruct.2020.111389**
- [20] Al-Nimry H, Neqresh M. Confinement effects of unidirectional CFRP sheets on axial and bending capacities of square RC columns. *Engineering Structures*. 2019; 196: 109329. **doi: 10.1016/j.engstruct.2019.109329**
- [21] Ghorbel E, Limaïem M, Wardeh G. Mechanical Performance of Bio-Based FRP-Confined Recycled Aggregate Concrete under Uniaxial Compression. *Materials*. 2021; 14(7): 1778. **doi: 10.3390/ma14071778**
- [22] Zhou JK, Lin G, Teng JG. Stress-strain behavior of FRP-confined concrete containing recycled concrete lumps. *Construction and Building Materials*. 2021; 267: 120915. **doi: 10.1016/j.conbuildmat.2020.120915**
- [23] Chotickai P, Tongya P, Jantharaksa S. Performance of corroded rectangular RC columns strengthened with CFRP composite under eccentric loading. *Construction and Building Materials*. 2021; 268: 121134. **doi: 10.1016/j.conbuildmat.2020.121134**
- [24] Chen X, Li R, Xiong Z, Liu Y, Zhuhe Y. Experimental study on axial behavior of pre-damaged concrete columns confined with carbon textile-reinforced ECC. *Construction and Building Materials*. 2025; 458: 139582. **doi: 10.1016/j.conbuildmat.2024.139582**
- [25] Han Q, Yuan WY, Ozbakkaloglu T, Bai YL, Du XL. Compressive behavior for recycled aggregate concrete confined with recycled polyethylene naphthalate/terephthalate composites. *Construction and Building Materials*. 2020; 261: 120498. **doi: 10.1016/j.conbuildmat.2020.120498**
- [26] Onyelowe KC, Ebid AM, Mahdi HA, Soleymani A, Jayabalan J, Jahangir H, Samui P, Singh RP. Modeling the confined compressive strength of CFRP-jacketed noncircular concrete columns using artificial intelligence techniques. *Cogent Engineering*. 2022 Dec 31;9(1):2122156. **doi: 10.1080/23311916.2022.2122156**

- [27] Nouri Y, Ghanizadeh AR, Safi Jahanshahi F, Fakharian P. Data-driven prediction of axial compression capacity of GFRP-reinforced concrete column using soft computing methods. *Journal of Building Engineering*. 2025; 101: 111831. doi: **10.1016/j.jobe.2025.111831**
- [28] Huang J, Gao P, Chen D, Ma C, Zhang N. Effect of concrete strength on the seismic performance of circular reinforced concrete columns confined by basalt and carbon fiber-reinforced polymer. *Construction and Building Materials*. 2024; 449: 138373. doi: **10.1016/j.conbuildmat.2024.138373**
- [29] Fakharian P, Nouri Y, Ghanizadeh AR, Safi Jahanshahi F, Naderpour H, Kheyroddin A. Bond strength prediction of externally bonded reinforcement on groove method (EBROG) using MARS-POA. *Composite Structures*. 2024; 349: 118532. doi: **10.1016/j.compstruct.2024.118532**
- [30] Varma DA, Sarker PK, Madhavan MK, Jayanarayanan K. Performance comparison of fiber reinforced polymer (FRP) systems and textile reinforced mortar (TRM) for concrete confinement at elevated temperature. *Composites Part C: Open Access*. 2025; 17: 100628. doi: **10.1016/j.jcomc.2025.100628**
- [31] Di Ludovico M, Prota A, Manfredi G. Concrete confinement with BRM systems: Experimental investigation. In: *Proceedings of the 4th International Conference on FRP Composites in Civil Engineering*. Zurich, Switzerland; 2008, 22-24.
- [32] Di Ludovico M, Prota A, Manfredi G. Structural upgrade using basalt fibers for concrete confinement. *Journal of Composites for Construction*. 2010; 14(5): 541-552. doi: **10.1061/(ASCE)CC.1943-5614.0000114**
- [33] García D, Alonso P, San-José JT, Garmendia L, Perlot C. Confinement of medium strength concrete cylinders with basalt Textile Reinforced Mortar. In: *13th International Congress on Polymers in Concrete*. Braga, Portugal; 2010; 1-7.
- [34] Ortlepp R, Lorenz A, Curbach M. Geometry effects onto the load bearing capacity of column heads strengthened with TRC. In: *In Proceedings of 2011 fib Symposium: Concrete Engineering for Excellence and Efficiency*. Prague; 2011; 1193-1196.
- [35] De Caso y Basalo FJ, Matta F, Nanni A. Fiber reinforced cement-based composite system for concrete confinement. *Construction and Building Materials*. 2012; 32: 55-65. doi: **10.1016/j.conbuildmat.2010.12.063**
- [36] Colajanni P, Fossetti M, Macaluso G. Effects of confinement level, cross-section shape and corner radius on the cyclic behavior of CFRCM confined concrete columns. *Construction and Building Materials*. 2014; 55: 379-389. doi: **10.1016/j.conbuildmat.2014.01.035**
- [37] Ombres L. Concrete confinement with a cement based high strength composite material. *Composite Structures*. 2014; 109(1): 294-304. doi: **10.1016/j.compstruct.2013.10.037**
- [38] Thermou GE, Katakalos K, Manos G. Concrete confinement with steel-reinforced grout jackets. *Materials and Structures*. 2015; 48(5): 1355-1376. doi: **10.1617/s11527-013-0239-6**
- [39] Ombres L, Mazzuca S. Confined Concrete Elements with Cement-Based Composites: Confinement Effectiveness and Prediction Models. *Journal of Composites for Construction*. 2017; 21(3): 04016103. doi: **10.1061/(ASCE)CC.1943-5614.0000755**
- [40] Zeng L, Li LJ, Liu F. Experimental study on fibre-reinforced cementitious matrix confined concrete columns under axial compression. *Kemija u industriji/Journal of Chemists and Chemical Engineers*. 2017; 66(3-4): 165-172. doi: **10.15255/KUI.2016.039**
- [41] Donnini J, Corinaldesi V. Concrete columns confined with different composite materials. Alexander MG, Beushausen H, Dehn F, Moyo P, editors. *MATEC Web of Conferences*. 2018; 199: 09012. doi: **10.1051/mateconf/201819909012**
- [42] Thermou GE, Hajirasouliha I. Compressive behaviour of concrete columns confined with steel-reinforced grout jackets. *Composites Part B: Engineering*. 2018; 138: 222-231. doi: **10.1016/j.compositesb.2017.11.041**
- [43] Ates AO, Khoshkholghi S, Tore E, Marasli M, Ilki A. Sprayed Glass Fiber-Reinforced Mortar with or without Basalt Textile Reinforcement for Jacketing of Low-Strength Concrete Prisms. *Journal of Composites for Construction*. 2019; 23(2). doi: **10.1061/(ASCE)CC.1943-5614.0000922**
- [44] Gonzalez-Libreros J, Zanini MA, Faleschini F, Pellegrino C. Confinement of low-strength concrete with fiber reinforced cementitious matrix (FRCM) composites. *Composites Part B: Engineering*. 2019; 177: 107407. doi: **10.1016/j.compositesb.2019.107407**
- [45] American Concrete Institute. ACI 549.4R-13. Guide to design and construction of externally bonded Fabric-Reinforced Cementitious Matrix (FRCM) systems for repair and strengthening concrete and masonry structures. Farmington Hills, MI, USA.; 2013.
- [46] Jahangir H, Nikkhah Z, Rezazadeh Eidgahee D, Esfahani MR. Performance Based Review and Fine-Tuning of TRM-Concrete Bond Strength Existing Models. *Soft Computing in Civil Engineering*. 2023; 7(1): 43-55. doi: **10.22115/scce.2022.349483.1476**
- [47] Jahangir H, Rezazadeh Eidgahee D. A new and robust hybrid artificial bee colony algorithm -ANN model

- for FRP-concrete bond strength evaluation. *Composite Structures*. 2021; 257: 113160. **doi: 10.1016/j.compstruct.2020.113160**
- [48] The MathWorks Inc. MATLAB version: 9.13.0 (R2022b). Natick, Massachusetts, United States: The MathWorks Inc.; 2022.
- [49] Naseri Nasab M, Jahangir H, Hasani H, Majidi MH, Khorashadizadeh S. Estimating the punching shear capacities of concrete slabs reinforced by steel and FRP rebars with ANN-Based GUI toolbox. *Structures*. 2023; 50: 1204-1221. **doi: 10.1016/j.istruc.2023.02.072**
- [50] Rezazadeh Eidgahee D, Rafiean AH, Haddad A. A Novel Formulation for the Compressive Strength of IBP-Based Geopolymer Stabilized Clayey Soils Using ANN and GMDH-NN Approaches. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*. 2019; 44(1): 219-229. **doi: 10.1007/s40996-019-00263-1**
- [51] White J, Power SD. k-Fold Cross-Validation Can Significantly Over-Estimate True Classification Accuracy in Common EEG-Based Passive BCI Experimental Designs: An Empirical Investigation. *Sensors*. 2023; 23(13): 6077. **doi: 10.3390/s23136077**
- [52] Milne L. Feature selection using neural networks with contribution measures. In: Eighth Australian Joint Conference on Artificial Intelligence. Canberra, Australia: World Scientific Publishing; 1995; 571-581. **doi: 10.26190/unsworks/378**