

AI-Driven Prediction of Compressive Strength in Fiber-Reinforced Concrete with Nanomaterials

Hamed Shokrnia¹, Ashkan KhodaBandehLou^{2*}, Peyman Hamidi³, Fedra Ashrafzadeh⁴

1. Ph.D. Student, Department of Civil Engineering, Ur.C., Islamic Azad University, Urmia, Iran
- *2. Associate Professor, Department of Civil Engineering, Ur.C., Islamic Azad University, Urmia, Iran
3. Assistant Professor, Department of Civil Engineering, Ur.C., Islamic Azad University, Urmia, Iran
4. Assistant Professor, Department of Civil Engineering, Ur.C., Islamic Azad University, Urmia, Iran

*Email Address: a.khodabandehlou@iau.ac.ir

Article Info	ABSTRACT
Article Type: Research Paper Article History: Received Date: 2026/04/29 Revised Date: 2026/05/25 Accepted Date: 2026/09/20 Published Date: 2026/09/20 Keywords: Fiber-reinforced concrete, Nanomaterials, Compressive strength, Artificial intelligence, Metaheuristic optimization.	In the present study, the primary objective is to identify the most important variables affecting the compressive strength of fiber-reinforced concrete containing nanomaterials. The innovation of the present research lies in focusing on the modeling and prediction of the behavior of fiber-reinforced concrete enhanced with nanosilica. In this research, the Neighborhood Component Analysis (NCA) method is used to identify the most important variables influencing the compressive strength of fiber-reinforced concrete containing nanomaterials. Subsequently, intelligent models including Extreme Learning Machine (ELM) and Adaptive Neuro-Fuzzy Inference System (ANFIS), based on the metaheuristic optimization algorithms of Particle Swarm Optimization (PSO) and Water Cycle Algorithm (WCA), are employed to estimate the compressive strength of fiber-reinforced concrete containing nanomaterials. In these hybrid models, the effects of various parameters, including aggregates, cement, and additives, on the compressive strength of concrete are investigated. A detailed statistical comparison between the actual compressive strength values of concrete and the predicted results of the models showed that the hybrid ELM-WCA method has better performance compared to the other proposed methods. The correlation coefficient (R) and root mean square error (RMSE) between the actual compressive strength values of concrete and the ELM-WCA predicted values are 0.9900 and 2.85 in the training phase, and 0.9736 and 4.04 in the testing phase, respectively. In addition, the ELM-WCA method, with a smaller predicted error interval (−8.22 to 7.74) compared to other methods, exhibits lower uncertainty in predicting the compressive strength of fiber-reinforced concrete containing nanomaterials.
Cite this article:	Hamed Shokrnia, Ashkan KhodaBandehLou , Peyman Hamidi, Fedra Ashrafzadeh (2026) AI-Driven Prediction of Compressive Strength in Fiber-Reinforced Concrete with Nanomaterials, Journal of Environmental Sciences Studies, 11(2), Pages 11232-11246.

EXTENDED ABSTRACT

Introduction

The construction industry is in a constant state of evolution, driven by the demand for high-performance, durable, and sustainable materials. Concrete, as the most widely used construction material globally, is at the forefront of this transformation. A significant advancement in this field is the development of fiber-reinforced concrete (FRC) enhanced with nanomaterials. This advanced composite addresses two critical limitations of conventional concrete: its inherent brittleness and its relatively low tensile strength. The addition of fibers (such as steel, glass, or polypropylene) provides crack-bridging mechanisms, significantly improving post-cracking behavior, toughness, and flexural strength. Concurrently, the incorporation of nanomaterials, particularly nanosilica (nano-SiO₂), refines the microstructure through pore-filling and the acceleration of pozzolanic reactions, leading to a denser interfacial transition zone (ITZ) and enhanced compressive strength and durability. This combination makes it an environmentally friendly option by potentially reducing the cement content required for a given strength, thereby lowering the carbon footprint associated with concrete production. However, the macroscopic behavior of this multi-phase composite material is governed by a complex and highly nonlinear interaction of numerous parameters. These include the type, geometry, and volume fraction of fibers; the dosage and dispersion of nanosilica; the water-to-cement (w/c) ratio; the properties of aggregates; and the curing age. Traditional statistical and empirical models often fall short of accurately capturing this complexity, making the reliable prediction of key mechanical properties, such as compressive strength, a significant challenge. This research gap hinders the widespread adoption and optimal design of these advanced materials. Therefore, the primary objective of this study is to develop and validate a robust, intelligent framework for predicting the compressive strength of nanosilica-enhanced FRC. The novelty of this work lies in its systematic integration of a feature selection method with state-of-the-art hybrid artificial intelligence (AI) models, combining machine learning algorithms with metaheuristic optimization techniques to achieve superior predictive accuracy and reliability. Research on fiber-reinforced concrete (FRC) and nanomaterial-modified concrete shows that fibers enhance ductility and impact resistance, while nanosilica improves mechanical properties and durability through pozzolanic activity. However, the combined effects of both components remain underexplored and highly dependent on mix design. Meanwhile, AI techniques like ANNs and ANFIS have been increasingly used to model concrete properties, with recent advances focusing on hybrid models optimized by metaheuristic algorithms such as PSO and GA to improve prediction accuracy. Despite these developments, the use of advanced algorithms like the Water Cycle Algorithm (WCA) for predicting the behavior of FRC containing nanomaterials is still limited. Additionally, systematic feature selection before modeling is frequently neglected—a gap this study addresses using Neighborhood Component Analysis (NCA).

Materials and methods

This research was conducted in three distinct phases: data preparation and feature selection, model development, and performance evaluation. **Data Collection and Feature Selection:** A comprehensive experimental database was compiled from reputable, published literature. The initial set of input variables included mixture proportions: cement content (kg/m³), fine aggregate (kg/m³), coarse aggregate (kg/m³), water-to-cement ratio, fiber content (%), nanosilica content (%), and curing age (days). The output variable was the compressive strength (MPa). To reduce dimensionality and identify the most critical parameters, the Neighborhood Component Analysis (NCA) method was employed. NCA is a non-parametric method for feature selection that learns a feature weight vector by minimizing a loss function, typically the leave-one-out regression error. This process highlights variables with the most significant impact on the target variable, which are then used as inputs for the predictive models. This study developed four hybrid AI models by combining two base learners (ELM and ANFIS) with two optimization algorithms (PSO and WCA). The optimizers fine-tuned the internal parameters of the base models—adjusting weights and biases for ELM, and membership function parameters for ANFIS. The resulting models were ELM-PSO, ELM-WCA, ANFIS-PSO, and ANFIS-WCA. **Performance Evaluation:** The database was randomly partitioned into a training set (70%) for model building and a testing set (30%) for evaluating generalization capability. Model performance was assessed using two standard statistical metrics: the correlation coefficient (R) and the root mean square error (RMSE). A higher R (closer to 1) and a lower RMSE indicate better predictive accuracy.

Results and discussion

The results demonstrate a clear distinction in the performance of the developed models. The feature selection phase using NCA identified nanosilica content, water-to-cement ratio, fiber content, and curing age as the most influential parameters affecting compressive strength. These four variables served as the primary inputs for all subsequent models. A detailed statistical comparison between the actual and predicted compressive strength values revealed that all hybrid models offered satisfactory predictions. However, the models optimized with the Water Cycle Algorithm consistently outperformed those optimized with Particle Swarm Optimization. Specifically, the ELM-WCA hybrid model exhibited superior performance across both the training and testing phases. The ELM-WCA model achieved an exceptionally high correlation coefficient (R) of 0.9900 and a low root mean square error (RMSE) of 2.85 MPa during the training phase. For the testing phase, which is the true measure of a model's predictive power, the ELM-WCA model maintained a high R value of 0.9736 and an RMSE of 4.04 MPa. In comparison, while the ANFIS-based models and ELM-PSO provided reasonable predictions, their RMSE values were higher, and their R values were lower, particularly on the testing dataset. Furthermore, an uncertainty analysis was conducted by examining the prediction error intervals. The ELM-WCA model exhibited the narrowest prediction error range (-8.22 to 7.74) compared to the other methods. This smaller interval indicates that the model's predictions are more consistent and reliable, with less scatter around the regression line, signifying lower uncertainty.

Conclusion

This research successfully developed and validated a robust hybrid intelligence framework for predicting the compressive strength of a complex composite material: fiber-reinforced concrete containing nanosilica. The study underscores the significant potential of combining advanced AI models with metaheuristic optimization algorithms for applications in materials science and civil engineering. The key conclusions are as follows:

- Effectiveness of NCA:** Neighborhood Component Analysis proved to be a powerful and systematic tool for feature selection, successfully identifying the most critical mixture parameters (nanosilica, w/c ratio, fibers, and age) and simplifying the modeling process without compromising accuracy.
- Superiority of ELM-WCA:** The hybrid ELM-WCA model emerged as the most accurate and reliable predictor. Its exceptional performance ($R > 0.97$ and low RMSE on unseen data) demonstrates the synergistic power of combining the fast-learning ELM network with the superior global search capability of the Water Cycle Algorithm. The WCA's ability to effectively tune the ELM's parameters leads to a model that can better capture the underlying nonlinear relationships governing the material's strength.
- Importance of Optimizer Selection:** The consistent outperformance of WCA-optimized models over PSO-optimized ones highlights that the choice of the optimization algorithm is as crucial as the choice of the base model. The WCA's unique mechanisms for balancing exploration and exploitation appear particularly well-suited for this type of complex optimization problem.
- Practical Implications:** The high accuracy and low uncertainty of the ELM-WCA model make it a valuable tool for engineers and researchers. It can be used to reliably predict the compressive strength of new mixtures, significantly reducing the need for time-consuming and costly trial batches. This can accelerate the development and optimization of environmentally friendly, high-performance concrete mixes, thereby promoting sustainable construction practices.

In conclusion, this study provides a clear pathway for leveraging computational intelligence to tackle the complexity of modern construction materials, paving the way for more efficient material design and quality control.



پیش‌بینی مقاومت فشاری بتن الیافی حاوی نانو مواد با استفاده از مدل‌های هوش مصنوعی

حامد شکر نیا^۱، اشکان خدا بنده لو^{۲*}، پیمان حمیدی^۳، فدر ا اشرف زاده^۴

۱- دانشجوی دکتری، گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

۲*- دانشیار، گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

۳- استادیار، گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

۴- استادیار، گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

* ایمیل نویسنده مسئول: a.khodabandehlou@iau.ac.ir

چکیده	اطلاعات مقاله
در پژوهش حاضر هدف اولیه این است که مهمترین متغیرهای تاثیرگذار بر مقاومت فشاری بتن تقویت شده با الیاف حاوی نانو مواد شناسایی شوند. نوآوری تحقیق حاضر این است که بر مدل‌سازی و پیش‌بینی رفتار بتن الیافی تقویت‌شده با نانوسیلیس تمرکز شده است. در این تحقیق از روش آنالیز اجزای همسایه (Neighborhood Component Analysis) برای شناسایی مهمترین متغیرهای تاثیرگذار بر مقاومت فشاری بتن تقویت شده با الیاف حاوی نانو مواد استفاده می‌شود. در ادامه، از مدل‌های هوشمند ماشین‌های یادگیری بینهایت (ELM) و سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) بر پایه الگوریتم‌های بهینه‌سازی فرا ابتکاری ازدحام ذرات (PSO) و چرخه آب (WCA) برای تخمین مقاومت فشاری بتن تقویت‌شده با الیاف حاوی نانو مواد استفاده می‌شود. در این مدل‌های ترکیبی تلاش شده است که تاثیر پارامترهای مختلفی، از جمله سنگدانه ها، سیمان و مواد افزودنی بر روی مقاومت فشاری بتن مورد بررسی قرار گیرد. مقایسه دقیق آماری بین مقادیر واقعی مقاومت فشاری بتن و نتایج پیش‌بینی مدل‌ها نشان داد که روش ترکیبی ELM-WCA دارای عملکرد بهتری نسبت به سایر روشهای پیشنهادی است. ضریب همبستگی (R) و ریشه میانگین مربعات خطا (RMSE) بین مقادیر واقعی مقاومت فشاری بتن و مقادیر پیش‌بینی ELM-WCA در مرحله آموزش ۰/۹۹۰۰ و ۲/۸۵ و در مرحله تست ۰/۹۷۳۶ و ۴/۰۴ می‌باشد. علاوه بر این، روش ELM-WCA با داشتن فاصله خطای پیش‌بینی شده کمتر (۷/۷۴ تا -۸/۲۲) نسبت به روشهای دیگر عدم قطعیت کمتری در پیش‌بینی مقاومت فشاری بتن تقویت شده با الیاف نانومواد دارد.	نوع مقاله: مقاله علمی پژوهشی تاریخ دریافت: ۱۴۰۵/۰۲/۰۹ تاریخ بازنگری: ۱۴۰۵/۰۳/۰۴ تاریخ پذیرش: ۱۴۰۵/۰۶/۲۹ تاریخ انتشار: ۱۴۰۵/۰۶/۲۹ کلید واژه ها: بتن الیافی، نانو مواد، مقاومت فشاری، هوش مصنوعی، بهینه‌سازی فرا ابتکاری.

۱-مقدمه

بتن یکی از پرمصرف‌ترین مصالح جهان است و به عنوان ماده ساختمانی قرن بیست و یکم شناخته می‌شود. از آنجا که بتن معمولی در برابر تشکیل و انتشار ریزترک‌ها و ترک‌ها مقاومت مطلوبی ندارد، استفاده از رشته‌های الیاف در بتن به عنوان راهکاری مؤثر برای رفع این مشکل پیشنهاد شده است. ناحیه تماس بین خمیر سیمان و سطح سنگدانه، الیاف یا میلگرد که تحت عنوان لایه مرزی یا منطقه انتقالی شناخته می‌شود، نقش مهمی در نفوذپذیری، دوام و مقاومت بتن دارد (توکلی و عنایت پور، ۱۴۰۴). این ناحیه دارای ریزساختاری متفاوت با خمیر سیمان بوده و از تخلخل و ریزترک‌های بیشتری برخوردار است و ضخامت آن تابع نوع الیاف، نوع سیمان، نوع پوزولان، نسبت آب به سیمان و سن بتن می‌باشد. از مهم‌ترین ویژگی‌های بتن الیافی می‌توان به جذب انرژی، انعطاف‌پذیری و مقاومت در برابر ضربه اشاره کرد؛ از این رو امروزه این نوع بتن به عنوان ماده‌ای نوین و اقتصادی در ساخت سازه‌های مسکونی و تجاری مورد توجه قرار گرفته است (ایزدی و هاشمی، ۱۴۰۴). افزودن رشته‌های الیافی به بتن از اوایل دهه ۱۹۶۰ میلادی در کشورهای پیشرفته آغاز شد و با گذشت زمان جنس، شکل و روش‌های ساخت بتن الیافی بهبود یافته و کاربردهای آن گسترش پیدا کرد (Gholizadeh, 2023 & Mahboubi Niazmandi). اوکامورا و اوزاوا در دهه ۱۹۶۰ در آمریکا تحقیقات اولیه‌ای درباره استفاده از الیاف فولادی در بتن انجام دادند (Ozawa, & Okamura, 1996). پس از آن، مطالعات صنعتی گسترده‌ای در زمینه بتن تقویت‌شده با الیاف فولادی انجام شد (Shokmia et al., 2025). در سال‌های اخیر، نانو فناوری افق‌های جدیدی در توسعه بتن ایجاد کرده است. نانوذرات موادی هستند که حداقل یکی از ابعاد آن‌ها کمتر از ۱۰۰ نانومتر باشد. با توجه به ریزساختار سیمان هیدراته و وجود حفرات نانومتری در آن، استفاده از نانوذرات می‌تواند با پر کردن تخلخل‌های بسیار ریز خمیر سیمان، موجب افزایش مقاومت و به ویژه دوام بتن شود (منتصری و نجاتی، ۱۴۰۴). همچنین تخریب بتن تا حد زیادی به تشکیل و گسترش ریزترک‌ها در اثر بارگذاری یا عوامل محیطی وابسته است. استفاده از الیاف در بتن به عنوان روشی مؤثر برای جلوگیری از گسترش ریزترک‌ها و جبران ضعف مقاومت کششی بتن شناخته می‌شود (Abbasi et al., 2022). نانو سیلیس از مهم‌ترین نانو موادی است که در خمیر سیمان و بتن مورد استفاده قرار می‌گیرد. با کاهش اندازه ذرات سیلیس به مقیاس نانو، سطح ویژه و تعداد اتم‌های سطحی آن افزایش یافته و واکنش‌های شیمیایی تشدید می‌شود (Sobolev, 2016). به همین دلیل نانوذراتی مانند نانو سیلیس به دلیل انرژی سطحی بالا و فعالیت پوزولانی زیاد، به راحتی با سایر ترکیبات واکنش داده و موجب بهبود خواص بتن می‌شوند (Zabbah et al., 2022). همچنین تحقیقات نشان داده‌اند که استفاده از نانو سیلیس می‌تواند مقاومت فشاری بتن را افزایش دهد. نتایج آزمایش‌های انجام شده بر روی بتن‌های حاوی خاکستر بادی و نانو سیلیس نشان داده است که مقاومت نهایی این بتن‌ها نسبت به بتن‌های معمولی و بتن‌های حاوی خاکستر بادی بیشتر است (Li, 2004). علاوه بر این، استفاده از نانو سیلیس باعث کاهش نفوذپذیری بتن در برابر آب می‌شود و مقاومت بتن در برابر نفوذ آب را افزایش می‌دهد (Ziyaei Hajipirli et al., 2021). برای دستیابی به بتن با تراکم بالا و نفوذپذیری کم، عوامل مختلفی مانند دانه‌بندی سنگدانه‌ها، مقدار سیمان و سایر افزودنی‌ها باید بررسی و مقدار بهینه آن‌ها تعیین شود. در سال‌های اخیر استفاده از مدل‌های هوشمند و الگوریتم‌های فراابتکاری برای پیش‌بینی خواص مقاومتی بتن مورد توجه پژوهشگران قرار گرفته است. صدرالسادات و همکاران با استفاده از شبکه‌های عصبی چندلایه پرسپترون و الگوریتم پس انتشار خطا، به مدل‌سازی مقاومت ۹۱ روزه بتن غلتکی پرداختند (Sadrossadat et al., 2022). باحوریا و همکاران نیز با استفاده از روش‌های شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی تطبیقی و ماشین بردار پشتیبان به مدل‌سازی مقاومت فشاری بتن غلتکی پرداختند و نشان دادند که شبکه عصبی مصنوعی عملکرد بهتری در پیش‌بینی مقاومت فشاری دارد (Bahoria et al., 2024). همچنین پژوهشگران دیگری از روش‌هایی نظیر مدل‌های درختی، مارس، برنامه‌نویسی بیان ژن، ماشین بردار پشتیبان و الگوریتم‌های فراابتکاری برای پیش‌بینی خواص بتن استفاده کرده‌اند (Padwad et al., 2025; Khodadadi et al., 2025; Duan et al., 2013; Pham et al., 2016; Kiani et al., 2016). در مطالعات دیگر نیز روش‌های مختلف یادگیری ماشین برای مدل‌سازی مقاومت فشاری بتن مورد استفاده قرار گرفته‌اند. ده روسا و همکاران از روش‌های رگرسیونی، ماشین بردار پشتیبان و مدل‌های درختی برای مدل‌سازی مقاومت فشاری بتن درجا استفاده کردند (DeRousseau et al., 2019). سان و همکاران نیز مقاومت فشاری بتن حاوی خاکستر بادی و دوده سیلیسی را با استفاده از الگوریتم کلونی زنبور عسل مصنوعی پیش‌بینی کردند (Sun et al., 2021). سادووسکی و همکاران یک مدل هیبریدی اولتراسونیک-عصبی برای پیش‌بینی مقاومت فشاری بتن سازگار با محیط زیست ارائه دادند که دقت بالایی در مراحل آموزش و آزمایش داشت (Sadowski et al., 2019). همچنین آستریس و همکاران با استفاده از مدل جانشین به پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی متاکائولن پرداختند (Asteris et al., 2019). گل افشانی و همکاران نیز با ترکیب الگوریتم گرگ خاکستری با شبکه عصبی مصنوعی و سیستم فازی-عصبی تطبیقی، مقاومت فشاری بتن بازبافتی را پیش‌بینی کردند (Golafshani et al., 2020). در بسیاری از تحقیقات انجام شده در حوزه بتن، استفاده همزمان نانوذرات با برخی الیاف خاص مورد توجه قرار گرفته است. تعیین درصد مناسب نانوذرات و انتخاب افزودنی‌های مناسب می‌تواند به بهبود خواص و توسعه کاربرد بتن کمک کند. در این پژوهش از مدل‌های داده‌منا برای پیش‌بینی خواص بتن تقویت‌شده با الیاف حاوی نانومواد استفاده شده است. با بررسی پارامترهای طرح اختلاط و عوامل مؤثر بر مقاومت بتن، مدل‌های

هوشمند توسعه داده شده‌اند تا روابط بین متغیرها و عملکرد آن‌ها ارزیابی شود. همچنین اعتبارسنجی و تحلیل عدم قطعیت مدل‌ها انجام شده و با استفاده از تحلیل حساسیت، میزان تأثیر هر متغیر در مدل نهایی مشخص شده است.

۲- داده‌های مراجع

این پژوهش تلاش می‌کند که از ترکیب دو روش رایج داده‌کاوی (ELM و ANFIS) با الگوریتم‌های بهینه‌سازی فرا ابتکاری برای تخمین مقاومت فشاری بتن تقویت شده با الیاف حاوی نانو مواد استفاده کند. بنابراین لازم است که مجموعه‌ای جامع از داده‌های مرتبط با این مسئله از مراجع جمع‌آوری شده و برای طراحی مدل‌ها و اعتبارسنجی آنها استفاده شود. این مجموع شامل ۲۲۸ داده آزمایشگاهی است که برای مدل‌سازی مقاومت فشاری بتن تقویت شده با الیاف حاوی نانو مواد بکار خواهد رفت. کاملاً مشخص است که انتخاب متغیرهای مستقل تأثیرگذار و حذف موارد کم اهمیت باعث می‌شود که مدل مناسب‌تری برای تخمین خواص بتن تقویت‌شده با الیاف حاوی نانو مواد سازگار با محیط زیست طراحی شود. این تحقیق از روش آنالیز اجزای همسایه (Neighborhood Component Analysis) برای شناسایی بهترین متغیرهای تأثیرگذار بر مقاومت فشاری بتن تقویت شده با الیاف حاوی نانو مواد سازگار با محیط زیست استفاده می‌کند. این روش از تابع فاصله و توابع وزنی برای شناسایی متغیرهای تأثیرگذار بر متغیر وابسته (مقاومت فشاری بتن تقویت شده با الیاف حاوی نانو مواد سازگار با محیط زیست) استفاده می‌کند. به کمک این روش مشخص شد که تأثیر متغیرهای مستقل بر مقاومت فشاری بتن در محدوده وزنی ۰/۲۱۲ تا ۰/۲۵۸۲ قرار دارد. متغیرهای مستقل با وزن کمتر از ۰/۱ داشتند حذف شده و در روند مدل‌سازی استفاده نشدند. رابطه (۱) که بر اساس نتایج روش آنالیز اجزای همسایه است نشان می‌دهد که مقاومت فشاری بتن تقویت شده با الیاف حاوی نانو مواد (CS) رابطه مستحکمی با سن نمونه (AS)، پوزولان (SCM)، نسبت حجمی الیاف (Vf)، نانو سیلیس (NS)، نسبت درشت‌دانه به ریزدانه (CA/FA)، نسبت آب به سیمان (W/C)، نسبت فوق روان‌کننده به خمیر سیمان (SP/B) دارد.

$$CS = f(AS, SCM, Vf, NS, \frac{CA}{FA}, \frac{W}{C}, \frac{SP}{B}) \quad (1)$$

در (جدول ۱) مقادیر حداقل، متوسط، حداکثر، و انحراف استاندارد متغیرهای مستقل و همچنین متغیر وابسته ارائه شده است. اطلاعات ارائه شده در این جدول نشان می‌دهد که داده‌های جمع‌آوری شده از مراجع محدوده وسیع و قابل قبولی از شرایط عملیاتی را پوشش داده و بر شرایط میدانی واقعی منطبق است. شایان ذکر است که ۷۰٪ این داده‌ها بصورت تصادفی برای آموزش (training) مدل‌های هوش مصنوعی و ۳۰٪ آنها برای آزمایش (testing) عملکرد آنها در نظر گرفته می‌شود. داده‌های آموزش در فرآیند Five-fold cross-validation مورد استفاده قرار گرفته و عملاً هر داده آموزش ۵ مرتبه (training and validation) در این فرآیند مورد ارزیابی قرار می‌گیرد.

جدول ۱. تحلیل آماری متغیرهای مستقل تأثیرگذار بر روی مقاومت فشاری بتن تقویت‌شده با الیاف حاوی نانو مواد سازگار با محیط زیست (Behnood & Golafshani, 2018)

متغیرهای درگیر در مدل‌سازی	میانگین	انحراف استاندارد	حداقل	حداکثر
Vf (%)	۰/۲	۰/۲۹۹	۰	۱/۲۵
CA/FA (-)	۰/۸۷۴	۰/۲۵۸	۰/۸۷۴	۱/۵۱۴۰
SCM ()	۲۸۸/۹	۱۴۴/۵۶۷	۰	۲۸۸/۹
W/C (-)	۰/۳۸	۰/۰۵۱۹	۰/۳۱	۰/۵۱
NS (Kg/m ³)	۱۳/۵	۱۶/۹۹۶	۰	۴۹/۶
SP/B (-)	۰/۰۲	۰/۰۰۶۴	۰/۰۰۲	۰/۰۲۵۳
Age (day)	۲۸	۳۶/۹۲۱	۷	۱۲۰
CS (MPa)	۶۲/۴۱	۱۹/۶۶	۳/۱۲	۹۱/۲
متغیر وابسته				

۳-روش انجام تحقیق

در این بخش تلاش می‌شود که روش‌های هوش مصنوعی و الگوریتم‌های بهینه‌سازی فراابتکاری که در تحقیق حاضر مورد استفاده قرار گرفته‌اند به صورت خلاصه تشریح شوند.

• مدل‌های هوشمند

تمرکز این قسمت بر تشریح مبانی روش‌های هوش مصنوعی سیستم استنتاج فازی-عصبی تطبیقی و ماشین‌های یادگیری بینهایت مطعوف است.

• سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)

سیستم استنتاج فازی-عصبی تطبیقی در سال ۱۹۹۳ توسط جانگ طراحی و به‌عنوان یک تقریب زننده جامع پیشنهاد شده‌است (Jang, 1993). سیستم استنتاج فازی-عصبی تطبیقی در حقیقت سیستم‌های فازی هستند که برای بهبود پارامترهای خود از روش آموزش تطبیقی شبکه‌های عصبی مصنوعی بهره می‌گیرند (Özcan et al., 2009). به صورت سنتی روش‌های انتشار بازگشتی خطا و روش ترکیبی (ترکیب انتشار بازگشتی خطا با کمترین مربعات) برای آموزش برای آموزش سیستم استنتاج فازی-عصبی تطبیقی استفاده می‌شود (Zhang et al., 2025). در ساده‌ترین بیان ممکن می‌توان سیستم استنتاج فازی-عصبی تطبیقی را به عنوان یک شبکه عصبی مصنوعی ۵ لایه در نظر گرفت. لایه اول شامل فازی‌سازی (Fuzzification)، لایه دوم مقدم قوانین فازی (Fuzzy rules)، لایه سوم نشانگر بخش نرمال‌سازی (Normalization)، لایه چهارم نشان‌دهنده مرحله فازی‌زدایی (Defuzzification)، و لایه پنجم لایه خروجی (Output) است. روابط ریاضی سیستم استنتاج فازی-عصبی تطبیقی به صورت گسترده در مراجع مختلف تشریح شده‌است (Benmouiza & Cheknane, 2019).

• ماشین‌های یادگیری بینهایت (ELM)

الگوریتم ELM بر پایه ی دو قضیه کلی تشریح می‌شود (Huang et al., 2006).

قضیه ۱: (اگر یک SLFN با تعداد N گره ی مخفی داشته باشیم به گونه‌ای که تابع فعالیت آن به صورت $G: R \rightarrow R$ باشد با شرط اینکه این تابع در هر بازه ای بی‌نهایت مشتق‌پذیر باشد، آنگاه برای N داده $(\underline{x}_i, \underline{t}_i)$ بطوریکه $\underline{x}_i = [x_{i1} \ x_{i2} \ \dots \ x_{in}]^T$ و $\underline{t}_i = [t_{i1} \ t_{i2} \ \dots \ t_{im}]^T$ ، $i=1, \dots, N$ باشد به ازای هر $\underline{w}_i$ و b_i ، که به صورت تصادفی در بازه‌های R^n و R^m انتخاب می‌شوند (مطابق با هر توزیع احتمال پیوسته)، با احتمال یک می‌توان به این نتیجه رسید که ماتریس لایه ی مخفی H وارون‌پذیر است و رابطه‌ی $H\beta - T = 0$ برقرار است (Huang et al., 2024). **قضیه ۲:** (برای هر مقدار کوچک $\varepsilon > 0$ و تابع فعالیتی که به صورت $G: R \rightarrow R$ این تابع در هر بازه‌ای بی‌نهایت مشتق‌پذیر باشد، $\tilde{N} \leq N$ وجود دارد به طوریکه برای N داده $(\underline{x}_i, \underline{t}_i)$ به ازای هر $\underline{w}_i$ و b_i که به صورت تصادفی در بازه های R^n و R^m انتخاب می‌شوند (مطابق با هر توزیع احتمال پیوسته)، با احتمال یک می‌توان به این نتیجه رسید که ماتریس لایه‌ی مخفی H وارون‌پذیر است و رابطه‌ی $\|H_{N \times \tilde{N}} - T_{N \times m}\| < \varepsilon$ برقرار می‌شود) (Huang et al., 2006). برای N داده $(\underline{x}_i, \underline{t}_i)$ بطوریکه $\underline{x}_i = [x_{i1} \ \dots \ x_{in}]^T$ و $\underline{t}_i = [t_{i1} \ \dots \ t_{im}]^T$ ، $i=1, \dots, N$ باشد و تابع فعالیت $G(x)$ با $\tilde{N}$ گره مخفی، الگوریتم ماشین یادگیری بینهایت به صورت زیر خلاصه می‌شود (Huang et al., 2006) و (Huang et al., 2024):

۱- وزن‌های ورودی و بایاس لایه خروجی به صورت تصادفی مقداردهی اولیه می‌شوند.

۲- محاسبه ماتریس وزن خروجی لایه خروجی (ماتریس H).

۳- محاسبه ماتریس وزن خروجی (ماتریس β) از طریق محاسبه رابطه (۲):

$$\beta = H^* T \quad (۲)$$

H^* وارون تعمیم یافته مور-پنروس ماتریس H است و $T = [t_1 \ \dots \ t_N]^T$ ، ماتریس خروجی‌ها مورد انتظار شبکه است.

• الگوریتم‌های بهینه‌سازی فراابتکاری

در این قسمت تلاش می‌شود که مبانی دو الگوریتم‌های بهینه‌سازی فراابتکاری که در تحقیق حاضر مورد استفاده قرار می‌گیرند (ازدحام ذرات و چرخه آب) به صورت خلاصه توضیح داده‌شود.

• الگوریتم بهینه‌سازی ازدحام ذرات (PSO)

این الگوریتم که بر اساس شبیه‌سازی تعامل اجتماعی پرندگان برای دستیابی به منابع غذایی است در سال ۱۹۹۵ توسط ابرهات و کندی معرفی شد (Wang et al., 2024). در این الگوریتم فرض شده است که پرندگان در جستجوی غذا به صورت غریزی فاصله خود تا غذا را حس می‌کنند در حالیکه از مکان آن اطلاعی ندارند. علاوه بر این، فرض شده‌است که تمام پرندگان با به اشتراک گذاشتن اطلاعات خود

موقعیت نزدیکترین پرند به غذا را می‌دانند و موقعیت خود در فضای جستجو را بر مبنای آن اصلاح می‌کنند. فرآیند حرکت پرندگان به سمت منبع غذا یک پدیدهٔ اتفاقی طبیعی است که باعث می‌شود هر پرند در گروه با سرعت و جهت خاص خود حرکت کند و موقعیت اولیهٔ خود را در گروه بهبود دهد. بردار سرعت بر اساس حافظه ذخیره‌شده به وسیلهٔ هر پرند بهبود می‌یابد و گروه در مسیر جستجوی خود به مناطق بهتری دست می‌یابد و این چرخه بهبود موقعیت هر ذره و متعاقباً بهبود موقعیت کل گروه ادامه دارد تا گروه به بهترین نقطه (منبع غذایی) برسد. این الگوریتم به آسانی می‌تواند با متغیرهای پیوسته، ناپیوسته و اعداد صحیح کار کند. الگوریتم PSO در مقایسه با روش‌های بهینه‌سازی مشابه دیگر بسیار مؤثرتر است و برای رسیدن به نتایج بهتر و یا مشابه دیگر الگوریتم‌ها، به فراخوانی تابع کمتری نیاز دارد. از جمله مزایای دیگر الگوریتم می‌توان به پیاده‌سازی کامپیوتری آسان آن اشاره کرد که به آسانی با شرایط قیود و متغیرها در یک مساله خاص منطبق می‌شود (Wang et al., 2024).

• الگوریتم چرخه آب (WCA)

در سالیان اخیر، پیشرفت‌های زیادی در ایجاد الگوریتم‌های بهینه‌سازی بر پایه رفتار پدیده‌های طبیعی صورت گرفته‌است. در الگوریتم ارائه‌شده به‌وسیله اسکندر و همکاران سعی شده است که با بهره‌گیری و الهام از چرخه آب در طبیعت یک تکنیک بهینه‌سازی تکاملی جدید معرفی شود (Nasir et al., 2020). هدف الگوبرداری از چرخه آب، طراحی یک الگوریتم جدید می‌باشد که همانند ریزش باران، جمعیت هر نسل هم دارای تنوع و پراکندگی مناسبی باشد و همچنین با شبیه‌سازی فرآیند حرکات آب‌های ریزشی به سمت رودخانه، الگوریتم سرعت همگرایی بالایی برای رسیدن به بهینه سراسری داشته باشد. علاوه بر این با الگوبرداری از اشباع‌شدن گودال‌ها در حین بارندگی فرار از بهینه محلی طراحی شده‌است که این امر موجب می‌شود که الگوریتم ارائه شده جستجوی مناسبی را در فضای مسئله داشته باشد و در بهینه محلی به دام نیفتد. در یک مسئله بهینه‌سازی چند بعدی، یک قطره باران، آرایه‌ای به شکل $1 \times N_{Var}$ است. این آرایه به صورت رابطه (۳) تعریف می‌شود:

$$\text{Raindrop} = [x_1, x_2, \dots, x_{N_{Var}}] \quad (3)$$

که در آن، x_1 تا $x_{N_{Var}}$ بیانگر متغیرهای تصمیم می‌باشند. بطوریکه برای شروع یک نمونه از ماتریس قطرات باران به اندازه‌ی $N_{pop} \times N_{Var}$ که N_{pop} و N_{Var} به ترتیب تعداد قطرات باران (جمعیت اولیه) و تعداد متغیرهای طراحی می‌باشند. در ادامه این فرآیند تابع هدف نیز برای مسئله بهینه‌سازی تعریف می‌گردد. در مسائل کمینه‌سازی، قطره ی باران با کمترین مقدار به عنوان دریا در نظر گرفته می‌شود. N_{SR} ، مجموع تعداد رودها (که یک فراسنج کاربردی است) و یک دریا (رابطه ۴) می‌باشند. بقیه‌ی جمعیت (نهرهایی که ممکن است به رودخانه‌ها و یا به طور مستقیم به دریا جریان پیدا کنند) با استفاده از رابطه‌ی (۵) محاسبه می‌شود.

$$N_{SR} = \text{Number of Rivers} + \overset{sea}{1} \quad (4)$$

$$N_{Raindrops} = N_{pop} - N_{SR} \quad (5)$$

به منظور تعیین یا اختصاص قطرات باران به رودها و دریا، بسته به شدت جریان از رابطه‌ی (۶) استفاده می‌شود:

$$NS_n = \text{round} \left\{ \left| \frac{Cost_n}{\sum_{i=1}^{N_{SR}} Cost_i} \right| \times N_{Raindrops} \right\}, n = 1, 2, \dots, N_{SR} \quad (6)$$

که در آن، NS_n تعدادی از نهرها است که به رودهای خاص و یا دریا جریان می‌یابد. یک نهر جریان تا رسیدن به رودخانه در امتداد خط اتصال بین آن‌ها با استفاده از یک فاصله، که به طور تصادفی انتخاب شده، مشخص می‌شود. اگر راه حل ارائه شده به وسیله‌ی یک نهر، بهتر از رودخانه متصل به آن باشد، موقعیت رودخانه و نهر عوض می‌شود (یعنی نهر، رودخانه می‌شود رودخانه نهر). این تبادل نیز می‌تواند به همین شکل برای رودخانه‌ها و دریا اتفاق بیفتد. یکی از مهم‌ترین عواملی که از همگرایی سریع الگوریتم (الگوریتم تا بالغ)، و به دام افتادن در بهینه‌های محلی جلوگیری می‌کند، تبخیر است. فرآیند تبخیر باعث می‌شود که آب دریا با تبخیر به صورت جریان رودها و یا نهرها دوباره به دریا بریزد. بطوریکه اگر فاصله ی بین رود و دریا عدد کوچکی نزدیک به صفر باشد، نشانگر آن است که رود به دریا رسیده است. در این وضعیت، فرآیند تبخیر اثر می‌کند، و همان‌طور که در طبیعت دیده می‌شود، بعد از تبخیر کافی، باران شروع خواهد شد. بطوریکه پس از برآورده شدن فرآیند تبخیر، فرآیند بارندگی اعمال می‌شود. در فرآیند بارندگی، قطرات باران جدید نهرها را در مکان‌های مختلف تشکیل می‌دهند. لذا برای تعیین مکان جدید نهرهای تازه شکل گرفته، از رابطه‌ی (۷) استفاده می‌شود.

$$X_{stream}^{new} = LB + rand \times (UB - LB) \quad (7)$$

که در آن، LB و UB به ترتیب، کران پایین و بالای تعریف شده به‌وسیله‌ی مسئله می‌باشند. بهترین قطرات باران جدید تشکیل شده به عنوان رود، و بقیه‌ی قطرات باران جدید به عنوان نهرهای جدید، که به سمت رودخانه‌ها در جریانند، و یا ممکن است به طور مستقیم به دریا برسند، در نظر گرفته می‌شوند. به منظور افزایش سرعت همگرایی و عملکرد محاسباتی الگوریتم برای مسائل مقید از رابطه ی زیر استفاده می‌شود:

$$X_{stream}^{new} = X_{sea} + \sqrt{\mu} \times randn(1, N_{Var}) \quad (8)$$

که در آن، μ ضریبی است که محدوده ی جستجو در نزدیکی دریا را نشان می دهد. randn عدد تصادفی توزیع نرمال است. مقادیر بزرگ μ امکان خروج از منطقه ی امکان پذیر را افزایش می دهد، و مقادیر کوچک μ منجر به جستجوی الگوریتم در منطقه ی کوچک تر در نزدیکی دریا می شوند. مقدار مناسب μ ، ۰/۱ تعیین شده است.

• مقایسه و ارزیابی عملکرد مدل های پیشنهادی

در این تحقیق عملکرد مدل های پیشنهادی در پیش بینی مقادیر آزمایشگاهی مقاومت فشاری بتن تقویت شده با الیاف حاوی نانومواد از شاخص های آماری شامل ضریب همبستگی (R)، ریشه میانگین مربعات خطا^۱ (RMSE)، درصد انحراف نسبی^۲ (RPD)، شاخص پراکندگی^۳ (SI) و درصد میانگین خطای نسبی مطلق^۴ (PMARE) مورد ارزیابی قرار می گیرد. فرمول ریاضی این شاخص های آماری با روابط (۹) تا (۱۳) بیان شده است.

$$R^2 = 1 - \frac{\sum_{i=1}^M (O_i - P_i)^2}{\sum_{i=1}^M (O_i - \bar{O})^2} \quad (9)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^M (O_i - P_i)^2}{M}} \quad (10)$$

$$SI = \frac{RMSE}{\bar{O}} \quad (11)$$

$$RPD = \frac{100}{M} \sum_{i=1}^M \frac{O_i - P_i}{O_i} \quad (12)$$

$$PMARE = \frac{100}{M} \sum_{i=1}^N \frac{|O_i - P_i|}{O_i} \quad (13)$$

O_i نشان دهنده مقادیر واقعی مقاومت فشاری بتن، P_i مقادیر پیش بینی مدل ها، و $\bar{O}$ میانگین مقادیر واقعی، و M تعداد داده ها می باشد.

۴- نتایج

در این بخش، مراحل طراحی مدل های هوش مصنوعی مختلف تشریح می شود. در ادامه میزان دقت این مدل ها در مراحل آموزش و آزمایش ارزیابی شده و مقایسه می گردد. از این طریق می توان بهترین مدل را شناسایی کرد و عملکرد آن در پیش بینی مقاومت فشاری بتن تقویت شده با الیاف حاوی نانو مواد سازگار با محیط زیست بررسی می شود.

• طراحی سیستم استنتاج فازی-عصبی تطبیقی

معماری در سیستم استنتاج فازی-عصبی تطبیقی شامل تعیین تعداد تابع عضویت ورودی، نوع تابع عضویت ورودی، نوع تابع عضویت خروجی، نوع الگوریتم آموزشی و تعداد تکرار است که در یادگیری شبکه تاثیر بسزایی دارند. هر کدام از اجزاء فوق بر اساس ارزیابی دقت مدل های متعدد ساخته شده و بر اساس سعی و خطا تعیین شدند. تعداد تابع عضویت برای هر لایه ورودی برابر با ۳ انتخاب شد. تابع های عضویت ورودی انتخاب شده در این پژوهش بر اساس انتخاب روش های فازی FCM clustering و subtractive clustering کوسی در نظر گرفته شد. تابع عضویت خروجی در این پژوهش از نوع خطی انتخاب شد. الگوریتم آموزشی در این پژوهش از نوع ترکیبی انتخاب شد. تعداد تکرار نیز به روش آزمون و خطا و با توجه به میزان کاهش خطای آموزشی شبکه انتخاب شد و در نهایت تعداد ۲۰ تکرار به عنوان تکرار مناسب انتخاب شد. با افزایش تعداد تکرارها مقدار خطای شبکه روش داده های آموزشی کم می شود.

• طراحی ماشین های یادگیری بینهایت

مدل ELM سه لایه برای پیش بینی مقاومت فشاری بتن تقویت شده با الیاف حاوی نانو مواد سازگار با محیط زیست استفاده شده است. اولین لایه تعداد نرون های ورودی با توجه به ورودی های در نظر گرفته شده از ۱ تا ۷ بود، لایه خروجی دارای یک نرون است که نشان دهنده مقاومت فشاری پیش بینی شده می باشد. لایه پنهان با حد پایین ۱۰ نرون و حد بالایی از ۱۰۰ نرون مورد آزمایش قرار گرفت. توابع مختلف فعال سازی از جمله سیگموئید (Sigmoid)، سینوسی (Sin)، هاردلیمیت (Hardlim)، مثلثی (Tribas) و تابع پایه شعاعی

¹ Root Mean Square Error

² Relative percent deviation

³ Scatter Index

⁴ Percent mean absolute relative error

(Radbas) یک به یک آزمایش شدند. برای هر آزمایش، تعداد نرون ها در لایه پنهان ۱۰ واحد افزایش داده شد. زمانی که تابع سیگموئید عنوان تابع فعال استفاده شد مدل های نزدیک به بهینه ماشین یادگیری سریع به دست آمد.

• طراحی مدل های ترکیبی مبنی بر الگوریتم های WCA و PSO

در این تحقیق از مدل های ANFIS و ELM برای پیش بینی مقاومت فشاری بتن تقویت شده با الیاف حاوی نانو مواد سازگار با محیط زیست و از الگوریتم های PSO و WCA برای کالیبراسیون پارامترهای کیفی مدل های مذکور استفاده شده است. مقادیر پارامترهای الگوریتم WCA در پیش بینی مقاومت فشاری بتن تقویت شده با الیاف حاوی نانومواد برای روش های ANFIS و ELM در (جدول ۲) آمده است.

جدول ۲. پارامترهای الگوریتم WCA به منظور بهینه سازی پارامترهای روش ANFIS و ELM

ELM	ANFIS	پارامترها
۱۰۰	۱۰۰	تعداد تکرار
۸۵	۹۰	تعداد قطرات باران
۸۵	۵۰	تعداد رودخانه ها و دریا
۱۴	۱۴	تعداد متغیرهای تصمیم
۲	۲	C1
۱	۱	dmax


در (جدول ۳) مقادیر تنظیم شده الگوریتم PSO برای روش ANFIS و ELM نشان داده شده است.

جدول ۳. پارامترهای الگوریتم PSO به منظور بهینه سازی پارامترهای روش های ANFIS و ELM

ELM	ANFIS	پارامترها
۱۰۰۰	۱۰۰۰	تعداد ذرات
۸۵	۱۰۰	تعداد تکرار
۸۵	۵۰	شتاب شناسایی (C_1)
۱۴	۱۴	شتاب جمعی (C_2)
۲	۲	وزن اینرسی اولیه (W)
۱	۱	نسبت میرایی وزن اینرسی (W_{damp})

• مقایسه دقت روش های پیشنهادی در پیش بینی مقاومت فشاری بتن

در (جدول ۴) میزان دقت روش های پیشنهادی در مرحله آموزش و آزمایش با استفاده از اندیس های آماری مختلف مورد ارزیابی قرار گرفته است. با بررسی و مقایسه این معیارهای آماری مشخص شد که مدل ترکیبی ELM-WCA عملکرد بهتری نسبت به سایر روش ها در مرحله آزمایش و تست دارد. ضریب همبستگی و ریشه میانگین مربعات خطا بین مقادیر واقعی مقاومت فشاری بتن و مقادیر پیش بینی ELM-WCA در مرحله آموزش ۰/۹۹۰۰ و ۲/۸۵ و در مرحله تست ۰/۹۷۳۶ و ۴/۰۴ می باشد. ضریب همبستگی بین مقادیر واقعی مقاومت فشاری بتن و نتایج روش های ELM-PSO و ANFIS-PSO در مرحله تست برابر ۰/۹۶۲۱ و ۰/۹۵۸۲ است. اختلاف آنها بر حسب ریشه میانگین مربعات خطا به ترتیب ۵/۰۹ و ۸/۷۱ است. به این ترتیب، روش ELM-PSO دارای عملکرد بهتری نسبت به روش ANFIS-PSO در مرحله تست است. از طرف دیگر، در مرحله آزمایش، بیشترین اختلاف بین مقادیر واقعی مقاومت فشاری بتن حاوی الیاف نانو مواد سازگار با محیط زیست و پیش بینی توسط ماشین های یادگیری بینهایت مشاهده شد. این روش دارای ضریب همبستگی ۰/۹۳۵۴ و ریشه میانگین مربعات خطای ۷/۳۲ است. و در نهایت، روش هوشمند سیستم استنتاج فازی-عصبی تطبیقی دارای بیشترین خطا در پیش بینی مقاومت فشاری بتن حاوی الیاف نانو مواد سازگار با محیط زیست در مرحله تست است. این روش ضریب همبستگی ۰/۹۰۶۵ و ریشه میانگین مربعات خطای ۸/۰۰ را ارائه می دهد.



شکل ۲. نمودار پراکندگی مقادیر مقاومت فشاری آزمایشگاهی در مقابل مقادیر پیش‌بینی شده در مرحله آزمایش

• آنالیز عدم قطعیت برای مدل‌های پیشنهادی

مشکل اصلی در شناخت فرآیندهای طبیعی، وجود عامل احتمال و برخی عوامل غیرقابل کنترل است که در این راستا تحلیل عدم قطعیت برای هر پدیده درکی واقعی از پارامترهای آن را مشخص کرده و شناختی درست از نقش عوامل تاثیرگذار بر پدیده را میسر می‌سازد (Albajjan et al., 2023); (Topcu & Canbaz, 2007); (Zhang et al., 2018) و (Ji, 2005). در این بخش، یک ارزیابی کمی از عدم قطعیت با استفاده از مدل‌های هوشمند برای تخمین مقاومت فشاری بتن بازیافتی ارائه شده است. تحلیل عدم قطعیت برای ۲۲۸ داده آزمایشگاهی در دسترس انجام گرفته است. تحلیل عدم قطعیت خطای پیش‌بینی هر یک از داده‌ها را به صورت $e_j = P_j - T_j$ تعریف می‌کند. با استفاده از خطاهای پیش‌بینی محاسباتی می‌توان میانگین و انحراف معیار خطای پیش‌بینی شده را به ترتیب با فرمول-

های $\bar{e} = \sum_{j=1}^M e_j$ و $S_e = \sqrt{\sum_{j=1}^M (e_j - \bar{e})^2 / (M - 1)}$ محاسبه نمود. با استفاده از مقادیر $\bar{e}$ و S_e ، یک محدوده اطمینان حول خطای مقادیر پیش‌بینی شده تعریف می‌گردد. همچنین، با استفاده از رابطه $\pm 0.96 S_e$ یک محدوده اطمینان ۹۵ درصد فراهم می‌آید. (جدول ۵) نتایج تحلیل عدم قطعیت را برای میانگین خطای پیش‌بینی^۵ روش‌های پیشنهادی، میزان محدوده عدم قطعیت مدل‌ها و ۹۵٪ فاصله خطای پیش‌بینی شده را نشان می‌دهد. نتایج ارائه شده در این جدول نشان می‌دهد که ELM-WCA با داشتن فاصله خطای پیش‌بینی شده کمتر (۷/۷۴ تا -۸/۲۲) دارای عدم قطعیت کمتری در پیش‌بینی مقاومت فشاری بتن تقویت شده با الیاف نانو مواد سازگار با محیط زیست نسبت به روش‌های دیگر است.

جدول ۵. نتایج تحلیل عدم قطعیت برای مدل‌های پیشنهادی

مدلها	میانگین خطای پیش‌بینی شده	محدوده باند عدم قطعیت	۹۵٪ فاصله خطای پیش‌بینی شده
ELM	+۲/۲۰۶	$\pm ۱۳/۹۱$	-۱۲/۷۱ تا ۱۳/۱۲
ANFIS	+۲/۹۳۸	$\pm ۱۶/۷۲$	-۱۲/۷۸ تا ۱۶/۶۹
ELM-PSO	-۰/۷۱۶	$\pm ۱۱/۷۷۶$	-۱۳/۹۴ تا ۵/۶۱
ANFIS-PSO	-۰/۵۱۴	$\pm ۱۰/۰۰۸$	-۱۰/۵۲ تا ۹/۴۹
ELM-WCA	-۰/۲۳۷	$\pm ۷/۹۸۳$	-۸/۲۲ تا ۷/۷۴
ANFIS-WCA	-۰/۳۹۱	$\pm ۸/۶۷۴$	-۸/۵۸ تا ۸/۷۶

⁵ Mean prediction error

۵- نتیجه گیری

در این پژوهش در ابتدا از روش آنالیز اجزای همسایه برای شناسایی تاثیرگذارترین متغیرهای مستقل بر مقاومت فشاری بتن تقویت شده با الیاف حاوی نانومواد استفاده شده است. در ادامه، مقاومت فشاری بتن تقویت شده با الیاف حاوی نانومواد با بکارگیری دو روش هوش مصنوعی ELM و ANFIS مدل سازی شده است. سپس برای بهبود دقت این روش های هوشمند و حذف رویکرد سعی و خطا برای تعیین مقادیر بهینه پارامترهای هر مدل، از الگوریتم های بهینه سازی ازدحام ذرات و چرخه آب استفاده شده است. کلیدی ترین نتایج تحقیق حاضر عبارتند از: ۱- سن نمونه، پوزولان، نسبت حجمی الیاف، نانو سیلیس، نسبت درشت دانه به ریزدانه، نسبت آب به سیمان، نسبت فوق روان کننده به خمیر سیمان به عنوان هفت متغیر مستقل با بیشترین اثرگذاری بر مقاومت فشاری بتن تقویت شده با الیاف حاوی نانومواد شناسایی شدند. ۲- با بررسی معیارهای آماری مختلف مشخص شد که مدل ترکیبی ELM-WCA عملکرد بهتری نسبت به سایر روش ها در مرحله آزمایش و تست دارد. ضریب همبستگی و ریشه میانگین مربعات خطا بین مقادیر واقعی مقاومت فشاری بتن و مقادیر پیش بینی ELM-WCA در مرحله آموزش ۰/۹۹۰۰ و ۲/۸۵ و در مرحله تست ۰/۹۷۳۶ و ۴/۰۴ می باشد. ۳- علاوه بر این، روش ترکیبی ELM-WCA عدم قطعیت کمتری در پیش بینی مقاومت فشاری بتن تقویت شده با الیاف نانو مواد سازگار با محیط زیست ارائه می دهد. این روش فاصله خطای پیش بینی شده کمتر (۷/۷۴ تا ۸/۲۲-) نسبت به سایر روش ها دارد. ۴- ضریب همبستگی بین مقادیر واقعی مقاومت فشاری بتن و نتایج روش های ELM-PSO و ANFIS-PSO در مرحله تست برابر ۰/۹۶۲۱ و ۰/۹۵۸۲ است. اختلاف آنها بر حسب ریشه میانگین مربعات خطا به ترتیب ۵/۰۹ و ۸/۷۱ است. به این ترتیب، روش ELM-PSO دارای عملکرد بهتری نسبت به روش ANFIS-PSO در مرحله تست است. ۵- در مرحله آزمایش، بیشترین اختلاف بین مقادیر واقعی مقاومت فشاری بتن حاوی الیاف نانو مواد سازگار با محیط زیست و پیش بینی توسط ماشین های یادگیری بینهایت مشاهده شد. این روش دارای ضریب همبستگی ۰/۹۳۵۴ و ریشه میانگین مربعات خطای ۷/۳۲ است. ۶- روش هوشمند سیستم استنتاج فازی-عصبی تطبیقی دارای بیشترین خطا در پیش بینی مقاومت فشاری بتن حاوی الیاف نانو مواد سازگار با محیط زیست در مرحله تست است. این روش ضریب همبستگی ۰/۹۰۶۵ و ریشه میانگین مربعات خطای ۸/۰۰ را ارائه می دهد.

منابع

- Abbasi, P., Radfar, R., Eshlaghi, A. T., & Salmasi, N. P. 2022. A mixed approach of open R&D ecosystem case study: Irans nanotechnology. Journal of Decisions and Operations Research, 6(Special Issue), 1-19.
- Albaijan, I., Mahmoodzadeh, A., Mohammed, A. H., Fakhri, D., Ibrahim, H. H., & Elhadi, K. M. 2023. Optimal machine learning-based method for gauging compressive strength of nanosilica-reinforced concrete. Engineering Fracture Mechanics, 291(1), 109560-74.
- Asteris, P. G., Ashrafian, A., & Rezaie-Balf, M. 2019. Prediction of the compressive strength of self-compacting concrete using surrogate models. Comput. Concr, 24(2), 137-150.
- Bajoria, B. V., Pande, P. B., Dhengare, S. W., Raut, J. M., Bhagat, R. M., Shelke, N. M., & Vairagade, V. S. 2024. Predictive models for properties of hybrid blended modified sustainable concrete incorporating nano-silica, basalt fibers, and recycled aggregates: Application of advanced artificial intelligence techniques. Nano-Structures & Nano-Objects, 40(1), 101373-86.
- Behnood, A., & Golafshani, E. M. 2018. Predicting the compressive strength of silica fume concrete using hybrid artificial neural network with multi-objective grey wolves. Journal of Cleaner Production, 202(1), 54-64.
- Benmouiza, K., & Cheknane, A. 2019. Clustered ANFIS network using fuzzy c-means, subtractive clustering, and grid partitioning for hourly solar radiation forecasting. Theoretical and Applied Climatology, 137(1), 31-43.
- DeRousseau, M. A., Laftchiev, E., Kasprzyk, J. R., Rajagopalan, B., & Srubar III, W. V. 2019. A comparison of machine learning methods for predicting the compressive strength of field-placed concrete. Construction and Building Materials, 228(1), 116661-75.
- Duan, Z. H., Kou, S. C., & Poon, C. S. 2013. Prediction of compressive strength of recycled aggregate concrete using artificial neural networks. Construction and Building Materials, 40(1), 1200-1206.

- Golafshani, E. M., Behnood, A., & Arashpour, M. 2020. Predicting the compressive strength of normal and High-Performance Concretes using ANN and ANFIS hybridized with Grey Wolf Optimizer. *Construction and Building Materials*, 232(1), 117266-78.
- Huang, G. B., Chen, L., & Siew, C. K. 2024. Universal approximation using incremental constructive feedforward networks with random hidden nodes. *IEEE transactions on neural networks*, 17(4), 879-892.
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. 2006. Extreme learning machine: theory and applications. *Neurocomputing*, 70(3), 489-501.
- Jang, J. S. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.
- Ji, T. 2005. Preliminary study on the water permeability and microstructure of concrete incorporating nano-SiO₂. *Cement and concrete Research*, 35(10), 1943-1947.
- Khodadadi, N., Roghani, H., De Caso, F., El-kenawy, E. S. M., Yesha, Y., & Nanni, A. 2025. Machine learning approach for the flexural strength of 3D-printed fiber-reinforced concrete based on the meta-heuristic algorithm. *Structural Concrete*, 16(2), 18-31.
- Kiani, B., Gandomi, A. H., Sajedi, S., & Liang, R. Y. 2016. New formulation of compressive strength of preformed-foam cellular concrete: an evolutionary approach. *Journal of Materials in Civil Engineering*, 28(10), 04016092-99.
- Li, G. 2004. Properties of high-volume fly ash concrete incorporating nano-SiO₂. *Cement and Concrete research*, 34(6), 1043-1049.
- Mahboubi Niazmandi, M., & Gholizadeh, M. 2023. Experimental study of the effect of different types of industrial steel fibers on the mechanical properties of reactive powder concrete. *Journal of Structural and Construction Engineering*, 10(11), 5-28.
- Nasir, M., Sadollah, A., Choi, Y. H., & Kim, J. H. 2020. A comprehensive review on water cycle algorithm and its applications. *Neural Computing and Applications*, 32(23), 17433-17488.
- Okamura, H., & Ozawa, K. 1996. Self-compactable high-performance concrete in Japan. *Special publication*, 159(1), 31-44.
- Özcan, F., Atiş, C. D., Karahan, O., Uncuoğlu, E., & Tanyildizi, H. 2009. Comparison of artificial neural network and fuzzy logic models for prediction of long-term compressive strength of silica fume concrete. *Advances in Engineering Software*, 40(9), 856-863.
- Padwad, H., Puri, N., Sahare, S. A., Gote, A. C., Patil, T. R., & Kakade, N. T. 2025. Hybrid metaheuristic optimization algorithm for prediction of fatigue life performance of fiber-reinforced concrete. *Asian Journal of Civil Engineering*, 9(4), 1-12.
- Pham, A. D., Hoang, N. D., & Nguyen, Q. T. 2016. Predicting compressive strength of high-performance concrete using metaheuristic-optimized least squares support vector regression. *Journal of Computing in Civil Engineering*, 30(3), 06015002-18.
- Qing, Y., Zenan, Z., Deyu, K., & Rongshen, C. 2007. Influence of nano-SiO₂ addition on properties of hardened cement paste as compared with silica fume. *Construction and building materials*, 21(3), 539-545.
- Sadowski, Ł., Piechówka-Mielnik, M., Widziszowski, T., Gardynik, A., & Mackiewicz, S. 2019. Hybrid ultrasonic-neural prediction of the compressive strength of environmentally friendly concrete screeds with high volume of waste quartz mineral dust. *Journal of cleaner production*, 212(1), 727-740.
- Sadrossadat, E., Basarir, H., Karrech, A., & Elchalakani, M. 2022. Multi-objective mixture design and optimisation of steel fiber reinforced UHPC using machine learning algorithms and metaheuristics. *Engineering with Computers*, 38(3), 2569-2582.
- Shokrnia, H., KhodabandehLou, A., Hamidi, P., & Ashrafzadeh, F. 2025. Prediction of compressive strength of fiber-reinforced concrete containing silica (SiO₂) based on metaheuristic optimization algorithms and machine learning techniques. *Scientific Reports*, 15(1), 19671.
- Sobolev, K. 2016. Modern developments related to nanotechnology and nanoengineering of concrete. *Frontiers of structural and civil engineering*, 10(2), 131-141.

- Sun, L., Koopialipoor, M., Jahed Armaghani, D., Tarinejad, R., & Tahir, M. M. 2021. Applying a meta-heuristic algorithm to predict and optimize compressive strength of concrete samples. *Engineering with Computers*, 37(2), 1133-1145.
- Topcu, I. B., & Canbaz, M. 2007. Effect of different fibers on the mechanical properties of concrete containing fly ash. *Construction and Building Materials*, 21(7), 1486-1491.
- Wang, R., Zhang, J., Lu, Y., & Huang, J. 2024. Towards designing durable sculptural elements: Ensemble learning in predicting compressive strength of fiber-reinforced nano-silica modified concrete. *Buildings*, 14(2), 396-414.
- Zabbah, I., Maroosi, A., Noghandi, A., & Abbasi, Z. 2022. Prediction of lime quality in lime baking furnaces using neural fuzzy methods. *Journal of decisions and operations research*, 7(Special Issue), 1-10.
- Zhang, B., Tan, H., Shen, W., Xu, G., Ma, B., & Ji, X. 2018. Nano-silica and silica fume modified cement mortar used as Surface Protection Material to enhance the impermeability. *Cement and Concrete Composites*, 92(1), 7-17.
- Zhang, G., Zhang, P., Wang, J., & Hu, S. 2025. Prediction of Rheological Properties of PVA Fiber and Nano-SiO₂-Reinforced Geopolymer Mortar Based on Back Propagation Neural Network Model Optimized by Genetic Algorithm. *Polymers*, 17(8), 1046-59.
- Ziyaei Hajipirlu, M., Taghizadeh, H., & Honarmand Azimi, M. 2021. An integrated approach based on scientometrics and artificial intelligence for extracting the supply chain resilience assessment model. *Journal of decisions and operations research*, 5(4), 522-546.
- ایزدی، حمیدرضا و هاشمی، مهدی. ۱۴۰۴. ارزیابی کیفیت محیط زیست در مدل رمزی با در نظر گرفتن اثرات جانبی زیست‌محیطی: مطالعه موردی ایران تحت سیاست‌های کلی محیط زیست. *مطالعات علوم محیط زیست*، ۱۰(۴)، ۱۰۸۶۹-۱۰۸۸۷.
- توکلی، آزاده و عنایت پور، متین. ۱۴۰۴. ارزیابی تاثیر فعالیت کارخانه آسفالت عمران و تولیدی خاصه بر کیفیت هوای منطقه- مطالعه موردی استان زنجان. *مطالعات علوم محیط زیست*، ۱۰(۴)، ۱۰۸۲۴-۱۰۸۳۵.
- منتصری، حسین و نجاتی، حمید. ۱۴۰۴. پیش بینی نرخ انتقال بار بستر ورودی به آبگیرهای جانبی واقع در کانال های قوسی با استفاده از ترکیب مدل های یادگیری ماشین و مدل عددی فاز گسسته. *مطالعات علوم محیط زیست*، ۱۰(۳)، ۱۰۵۳۴-۱۰۵۴۸.