

EXTENDED ABSTRACT

Analysis of Factors Influencing Concrete Resistance in the Construction Industry: Machine Learning Approach

Mohammad Pordel^a, Amir Aminzadeh Ghavifekr^{b,*}

^a M.Sc, Civil Engineering Department, Faculty of Engineering, Bu-Ali Sina University, Hamedan, Iran

^b Assistant Professor, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

Received: 15 July 2024; **Reviewed:** 14 November 2024; **Accepted:** 28 December 2024

Keywords:

Urban management, Machine learning algorithm, Metaheuristic algorithm, Concrete compressive strength, Environment, Construction waste.

1. Introduction

Concrete, as one of the main materials in the construction industry, plays a vital role in the sustainability, safety, and welfare of urban spaces. This is because concrete has a direct impact on bearing gravitational and lateral loads, and improving the quality of concrete can prevent the premature destruction of buildings. Additionally, it can reduce the volume of construction waste and create a sustainable urban environment. However, numerous factors affect the compressive strength of concrete, and failing to identify these factors can lead to premature building destruction and adverse outcomes during natural disasters. A proper understanding of these factors is essential for enhancing concrete quality and ensuring the optimal performance of structures. Accordingly, the aim of this article is to analyze the factors influencing the quality and strength of concrete to improve the sustainability, safety, and welfare of urban spaces and to protect the urban environment. In this article, to achieve the research objectives, in addition to using a machine learning model based on the Extreme Gradient Boosting algorithm, metaheuristic algorithms have been employed to create an accurate predictive model.

2. Methodology

2.1. PSO algorithm

In this article, particle swarm optimization is used to tune the hyperparameters of the machine learning model with the aim of enhancing performance accuracy. This approach allows for the efficient exploration of the hyperparameter space, leading to improved model performance compared to traditional grid search methods. By simulating the social behavior of particles in a swarm, the algorithm effectively balances exploration and exploitation to find the optimal hyperparameters. The resulting model demonstrates superior accuracy and robustness in predicting concrete compressive strength, ultimately contributing to safer and more sustainable urban construction practices.

2.2. Machine learning

Supervised learning is one of the three branches of machine learning, comprising two main components: 1) regression and 2) classification. In regression, the prediction of a data point is performed based on independent variables.

The Extreme Gradient Boosting (XG Boost) algorithm is a popular and powerful machine learning algorithm that falls under the category of ensemble learning. Specifically, it is a boosting algorithm that combines the predictions of multiple weak learners, usually decision trees, to create a strong predictive model. One of the key strengths of the Extreme Gradient Boosting algorithm is its ability to efficiently perform both regression and classification tasks

3. Results and discussion

After analyzing the relationship between certain variables and the compressive strength of concrete, the predictive model is trained based on the independent variables. For this purpose, after applying some preprocessing methods to the dataset, it is divided into a training set and a testing set, with 75% and 25% of the data allocated to them respectively. Some classification algorithms are used to build the machine learning model, and the results are mentioned in Table 1.

Table 1. Comparison of different models

Model	Accuracy (%)
Random forest	91.9
Decision tree	82.5
XGboost	93.7
Ada Boost	85.53
Gradient Boost	93.1
Linear regression	78.4
Lasso regression	78.9
XGboost + PSO	95.66

Based on Table 1, the combination of the XG Boost algorithm and the PSO algorithm shows better performance compared to the others. Additionally, feature importance analysis is performed to identify the effect of each variable on the compressive strength of concrete after training the model. The results are shown in Fig. 1.




Fig. 1. Feature importance analysis

According to Fig. 1, it can be observed that the age variable has the greatest impact on the compressive strength of concrete, followed by the cement content. Additionally, other influential variables on the compressive strength of concrete are visible in Fig. 1.

4. Conclusions

Concrete compressive strength significantly impacts urban spaces and social life by determining the durability, safety, and longevity of buildings and infrastructure. Therefore, this study employs data analysis techniques to examine the characteristics influencing concrete compressive strength, aiming to extract valuable insights. Additionally, a predictive model was created by integrating machine learning and PSO algorithms. The resulting model has an accuracy of 95.66%, facilitating the prediction of concrete compressive strength. This not only helps decision-makers to quickly understand the compressive strength of concrete but also provides valuable information to enhance building strength. Consequently, implementing such programs to achieve adequate strength, enabling structures to withstand heavy loads and harsh environmental conditions, minimizes the need for frequent repairs and contributes to a sustainable and resilient urban environment. This stability increases residents' sense of security and well-being, enhancing social interactions and activities.

تحلیل عوامل مؤثر بر مقاومت بتن در صنعت ساخت و ساز شهری: رویکرد یادگیری

ماشین

محمد پردل¹، امیر امین زاده قوی فکر^{2*}

¹ کارشناسی ارشد عمران - مهندسی و مدیریت ساخت، دانشگاه بوعلی سینا، همدان

² استادیار گروه کنترل، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز

دریافت: 1403/4/25، بازنگری: 1403/8/24، پذیرش: 1403/10/8، نشر آنلاین: 1403/10/8

چکیده

بتن به عنوان یکی از مصالح اصلی در صنعت ساخت، نقش حیاتی در پایداری، ایمنی و رفاه فضاهای شهری ایفا می کند. کیفیت بتن رابطه مستقیمی با تحمل بارهای ثقلی و جانبی دارد و می تواند از تخریب زود هنگام ساختمان ها جلوگیری کرده و علاوه بر کاهش حجم ضایعات ساختمانی، یک محیط شهری پایدار ایجاد نماید. با این حال، عوامل متعددی بر مقاومت فشاری بتن تأثیر گذارند که عدم شناسایی این عوامل می تواند منجر به تخریب زودرس ساختمان ها و همچنین پیامدهای ناگوار در بلایای طبیعی شود. درک صحیح از این عوامل برای ارتقای کیفیت بتن و تضمین عملکرد مطلوب سازه ها ضروری است. هدف این مقاله، تحلیل عوامل مؤثر بر کیفیت مقاومت بتن در راستای ارتقا پایداری، ایمنی، رفاه فضاهای شهری و همچنین حفاظت از محیط زیست شهری است. در این مقاله، علاوه بر استفاده از مدل یادگیری ماشین مبتنی بر الگوریتم تقویت گرادیان شدید، از الگوریتم های فرا ابتکاری برای ایجاد یک مدل پیش بینی دقیق استفاده شده است. نتایج این پژوهش نشان می دهد که عوامل متعددی از جمله نسبت آب به سیمان، نوع و کیفیت سنگ دانه، افزودنی های بتن، شرایط عمل آوری و شرایط محیطی، بر مقاومت بتن تأثیر گذار هستند. همچنین، در این پژوهش مدل یادگیری ماشین، قادر به شناسایی الگوهای پیچیده در بین عوامل شناسایی شده و پیش بینی دقیق مقاومت فشاری بتن با دقت 95/66 درصد است. نتایج این مطالعه می تواند به ارتقای کیفیت ساخت، افزایش طول عمر مفید سازه ها، کاهش هزینه های نگهداری و تعمیرات و ایجاد فضاهای شهری پایدار و ایمن منجر شود.

کلیدواژه ها: مدیریت شهری، الگوریتم یادگیری ماشین، الگوریتم فرا ابتکاری، مقاومت فشاری بتن، محیط زیست، ضایعات ساختمانی.

1- مقدمه

شده است. در این میان، بتن به عنوان یک ماده با پتانسیل بالا برای ارتقای پایداری و کارایی در نظر گرفته می شود. با این حال، با رشد جمعیت و توسعه شهرها، داشتن ارزیابی دقیق خواص مکانیکی برای بهبود طراحی سازه های بتنی الزامی به نظر می رسد (Moein و همکاران، 2023).

در بین ویژگی مختلف بتن، مقاومت فشاری به عنوان شاخص اصلی برای ارزیابی عملکرد در نظر گرفته می شود و این خاصیت ارتباط مستقیمی با ایمنی و عملکرد سازه در طول چرخه عمر آن دارد (Tahmouresi و همکاران، 2021). علاوه بر این، تخریب زود هنگام سازه های بتنی، اتلاف منابع طبیعی و مصالح را به دنبال دارد و بر بار زیست محیطی آن ها می افزاید.

بتن به عنوان یکی از پرمصرف ترین مصالح ساختمانی در سراسر جهان، نقش حیاتی در ایجاد زیرساخت ها و ساخت و ساز شهری ایفا می کند و انتظار می رود تقاضا برای بتن تا سال 2050 به 18 میلیارد تن برسد (Feng و همکاران، 2020).

با این حال، بتن در طول زمان می تواند تحت تأثیر عوامل مختلفی مانند خوردگی، یخ زدگی و بارگذاری فرسوده شود و منجر به خرابی زودرس سازه ها شود. این خرابی ها نه تنها هزینه های هنگفتی را به دنبال دارند، بلکه می توانند تهدیدی جدی برای ایمنی و رفاه ساکنان شهری باشند. در سال های اخیر، توجه زیادی به توسعه مصالح و روش های ساخت پایدار و بادوام معطوف



همچنین با استفاده از الگوریتم‌های هوشمند، نیازهای تعمیر و نگهداری و آسیب‌های احتمالی را پیش‌بینی می‌کنند. مدل‌های یادگیری ماشین با استفاده از داده حسگرهای تعبیه‌شده در سازه‌های بتنی و تجزیه و تحلیل عوامل مؤثر در تغییر شکل و نقاط شکست احتمالی را پیش‌بینی می‌کنند (Dinesh و Prasad, 2024).

علاوه بر این، امروزه، سیستم‌های خودکار و رباتیک فرآیندهای ریختن و عمل‌آوری بتن را ساده می‌کنند و خطای انسانی را کاهش می‌دهند که باعث افزایش کارایی و کیفیت بتن می‌شود (Quah و همکاران, 2023). در نتیجه، انقلاب صنعتی چهارم علاوه بر این که استانداردهای کیفیت ساخت‌وساز را بالا می‌برد، راه را برای زیرساخت‌های هوشمند و انعطاف‌پذیر هموار می‌کند (Baduge و همکاران, 2022).

در سال‌های اخیر با پیشرفت‌های صورت گرفته در زمینه هوش مصنوعی، روند استفاده از روش‌های یادگیری ماشین و همچنین یادگیری عمیق (شاخه‌ای از یادگیری ماشین) برای پیش‌بینی خواص مکانیکی بتن مورد توجه قرار گرفته است. روش‌های یادگیری ماشین در مقایسه با روش‌های سنتی، الگوریتم‌های خاصی دارد که می‌تواند از داده‌ها یاد بگیرد و نتایج دقیق‌تری را به‌عنوان داده‌های خروجی نمایش دهد (Salehi و Burgueño, 2018). یادگیری ماشین در مهندسی عمران در زمینه‌های مختلف ارزیابی عملکرد لرزه‌ای (Liu و همکاران, 2020)، مدل‌سازی مقاومت کششی (Behnood و همکاران, 2015) و مقاومت فشاری (Dutta و Barai, 2019)، شناسایی سیستم ساختاری (Jiang و همکاران, 2007) و کنترل ارتعاش (Abdeljaber و همکاران, 2016) استفاده می‌شود.

2- مرور ادبیات

در این بخش به گزیده‌ای از پژوهش‌هایی که با استفاده از الگوریتم‌های یادگیری ماشین به بررسی مقاومت بتن پرداخته‌اند اشاره خواهد شد. Omran و همکاران (2016) از الگوریتم برداری پشتیبان (SVM) بر اساس حداقل بهینه‌سازی متوالی برای پیش‌بینی مقاومت فشاری بتن حاوی سنگ‌دانه سبک استفاده کردند.

Han و همکاران (2019) از الگوریتم جنگل تصادفی (RF) برای پیش‌بینی مقاومت فشاری بتن با کارایی بالا استفاده کردند. در پژوهشی دیگر توسط Mangalathu و Jeon (2018) همین مدل را برای پیش‌بینی مقاومت برشی بتن آرمه اتخاذ کردند. نتایج هر دو مطالعه مطابقت خوبی داشتند و توانایی الگوریتم جنگل تصادفی در تولید پیش‌بینی‌های قابل اعتماد را تأیید کردند.

Jalal و همکاران (2020) خواص مکانیکی بتن را بررسی کردند و مقاومت فشاری بتن را از طریق الگوریتم برداری پشتیبان

مقاومت فشاری بتن با تأثیر بر دوام، ایمنی و طول عمر ساختمان‌ها و زیرساخت‌ها به‌طور قابل توجهی بر فضای شهری و زندگی اجتماعی تأثیر می‌گذارد (Wang و همکاران, 2018). لذا، ارتقای کیفیت بتن و افزایش طول عمر سازه‌های بتنی، اقدامی ضروری در جهت دستیابی به توسعه پایدار شهری، ارتقای ایمنی و رفاه ساکنان و حفظ محیط زیست به‌شمار می‌رود. به‌عبارت بهتر یکی از مهم‌ترین پارامترهایی که کیفیت و پایداری سازه‌های بتنی را تحت‌الشعاع قرار می‌دهد، مقاومت فشاری آن است. مقاومت فشاری بالا به بتن این توان را می‌بخشد که در برابر بارهای سنگین ثقلی و جانبی، همچون وزن سازه، بار باد، بار برف و زلزله، از خود مقاومت بالایی نشان دهد و بدون ترک‌خوردن یا فروریختن، بارهای وارده را تحمل کند. زیرا این امر نیاز به تعمیرات مکرر ساختمان‌ها را کاهش می‌دهد و باعث حفاظت از محیط زیست شهری می‌شود (Zhang و همکاران, 2020).

استفاده از بتن با مقاومت بالا در فضای شهری می‌تواند فواید قابل توجهی از جمله افزایش طول عمر ساختمان‌ها، کاهش هزینه‌های نگهداری، ارتقای ایمنی و پایداری و کاهش اثرات زیست محیطی داشته باشد (Mouratidis, 2021).

بنابراین شناسایی و تحلیل عوامل مؤثر بر کیفیت و مقاومت بتن اهمیت بسیاری دارد. بتن سیستم پیچیده‌ای از ترکیب اجزای مختلف (سنگ‌دانه‌ها، آب، سیمان و مواد افزودنی) است که به‌طور تصادفی در سراسر ماتریس بتن توزیع می‌شود (Moein و همکاران, 2023).

این ویژگی ناهمگن، پیش‌بینی دقیق خواص مکانیکی خاص، به‌ویژه مقاومت فشاری را دشوار می‌کند (Chopra و همکاران, 2018). انتخاب روش مناسب برای ارزیابی مقاومت فشاری بتن به عوامل مختلفی مانند دقت مورد نیاز، زمان و هزینه بستگی دارد. با این حال، رایج‌ترین راه برای ارزیابی مقاومت فشاری بتن، انجام آزمایش‌های فیزیکی بر روی نمونه‌های عمل‌آوری شده است. این روش که به آزمایش مقاومت فشاری بتن معروف است، اطلاعات دقیقی از مقاومت فشاری بتن در شرایط واقعی سازه ارائه می‌دهد. به‌عبارت دیگر، آزمایش مقاومت فشاری بتن یکی از بهترین گزینه‌ها برای سنجش میزان مقاومت فشاری بتن است (Shi و همکاران, 2009). اما از معایب این روش می‌توان به زمان‌بر بودن آزمایش، اشتباهات آزمایشگاهی، هزینه بالا و محدودیت در اندازه نمونه اشاره نمود.

ازطرفی، ظهور انقلاب صنعتی چهارم با ادغام فناوری‌های پیشرفته مانند یادگیری ماشین و اینترنت اشیا (IoT) با شیوه‌های سنتی، صنعت ساخت را متحول کرده است (Khurshid و همکاران, 2023). این تحول به‌ویژه در بخش بتن مشهود است (Chatterjee, 2021). زیرا روش‌هایی مانند یادگیری ماشین با استفاده از تجزیه و تحلیل عوامل تأثیرگذار و پیش‌بینی‌کننده و

همچنین به این نتیجه رسیدند که جذب آب سنگدانه درشت مخلوط و نسبت سنگدانه ریز به کل سنگدانه دو پارامتر مؤثر بر مدول الاستیک بتن حاوی سنگدانه‌های بازیافتی هستند.

Abdollahzadeh و همکاران (2016) مقاومت فشاری بتن بازیافتی حاوی دوده سیلیس را با برنامه‌ریزی بیان ژن ارزیابی کردند. آن‌ها تطابق بهینه بین نتایج تجربی و نتایج مدل برنامه‌ریزی بیان ژن را گزارش کردند. Iqbal و همکاران (2020) مقاومت فشاری، مقاومت کششی و مدول الاستیک بتن سبز را از طریق برنامه‌ریزی بیان ژن مورد مطالعه قرار دادند. آن‌ها گزارش دادند که نتایج به دست آمده از MAE، RMSE و R2 قابلیت مدل را تأیید می‌کند.

در این مقاله بر خلاف تحقیقاتی قبلی به بررسی عوامل مؤثر بر مقاومت بتن با استفاده از روش ترکیبی یادگیری ماشین و الگوریتم فراابتکاری پرداخته خواهد شد. همچنین، بر اساس مطالعات پیشین، محققین از روش‌های انتخاب و یا یادگیری ماشین در پژوهش‌های خود استفاده کرده‌اند. اما در پژوهش حاضر از هردوی این تحلیل‌ها برای رسیدن به یک مدل کاربردی و ارائه راهکارهای مدیریتی مناسب‌تر استفاده خواهد شد. در این مقاله از ترکیب نوآورانه الگوریتم‌های یادگیری ماشین و فراابتکاری برای تنظیم پارامترهای مدل استفاده می‌شود که هدف اصلی آن ساخت مدلی با دقت بالا و ارائه الگوریتم کاربردی است. خروجی این مسئله در راستای فهم درست عوامل مؤثر بر استحکام بتن است که به افزایش کارایی در ساختمان‌های در حال ساخت، کمک شایانی می‌کند.

3- تعریف مسئله

مقاومت فشاری بتن یک پارامتر حیاتی در صنعت ساختمان است که ظرفیت باربری و دوام کلی سازه‌ها را تعیین می‌کند. همان‌طور که پیش‌تر نیز بیان شد، مقاومت فشاری بتن، ارتباط مستقیمی با پایداری و ایمنی ساختمان‌ها، پل‌ها و سایر زیرساخت‌ها دارد و بر عواملی همچون طول عمر و مقاومت ساختمان در برابر عوامل جوی نیز تأثیرگذار است. از طرفی، نتایج مطالعات اثبات کرده است که مواردی مانند نسبت آب به سیمان، اندازه سنگدانه، شرایط عمل‌آوری و کیفیت مصالح به‌طور قابل توجهی بر مقاومت فشاری بتن تأثیرگذار است (Khademi و همکاران، 2017).

درک و بهینه‌سازی این عوامل برای تولید بتن باکیفیت ضروری است. اخیراً، یادگیری ماشین به‌عنوان یک ابزار قدرتمند در این حوزه ظاهر شده است که امکان پیش‌بینی و افزایش مقاومت فشاری بتن را از طریق بینش‌های مبتنی بر داده‌ها فراهم می‌کند (Dinesh و Prasad، 2024).

پیش‌بینی کردند. آنان در مطالعه خود از سه هسته مختلف (خطی، چند جمله‌ای و گاوسی)، فرآیندهای بهینه‌سازی و الگوریتم‌های بهینه‌سازی استفاده کردند و به این نتیجه رسیدند که الگوریتم برداری پشتیبان با داده‌های استاندارد شده و تابع هسته گاوسی، پیش‌بینی‌های دقیق‌تری را نسبت به سایر مدل‌های الگوریتم برداری پشتیبان و رگرسیون ارائه می‌دهد.

Gholampour و همکاران (2020) مقاومت فشاری، مقاومت کششی و مدول الاستیک بتن حاوی بتن بازیافتی سنگدانه را توسط مدل درخت تصمیم ارزیابی و با روش‌های دیگر مقایسه کردند. نتایج نشان می‌دهد که درخت تصمیم می‌تواند خواص مکانیکی بتن بازیافتی سنگدانه را به‌صورت دقیق برای شناسایی تأثیرات پارامترهای حیاتی پیش‌بینی کند. برخی از محققین نیز با استفاده از الگوریتم‌های یادگیری عمیق به تحلیل مقاومت بتن پرداختند.

Khademi و همکاران (2017) از شبکه عصبی مصنوعی و سیستم استنتاج فازی مبتنی بر شبکه تطبیقی برای پیش‌بینی مقاومت فشاری بتن معمولی 28 روزه استفاده کردند. هر دو مدل توانایی خودشان در ارزیابی مقاومت فشاری مخلوط‌های مختلف بتن را نشان دادند.

Güçlüer و همکاران، (2021) مقاومت فشاری بتن حاوی ضایعات ساختمانی و تخریب را با روش شبکه عصبی مصنوعی بررسی کردند. آن‌ها گزارش کردند که شبکه عصبی مصنوعی پتانسیل پیش‌بینی مقاومت فشاری بتن 28 روزه را دارد.

Naderpour و همکاران (2018) مقاومت فشاری بتن حاوی ضایعات ساختمانی (جایگزین درشت‌دانه) بود را با روش شبکه عصبی انتشار برگشتی (شامل 6 ورودی و 18 گره پنهان) ارزیابی کردند و تأثیر هر پارامتر ورودی را بر مقاومت فشاری ارزیابی کردند. نتایج آن‌ها نشان می‌دهد که جذب آب به‌عنوان یکی از ورودی‌های مدل شبکه عصبی انتشار برگشتی بیشترین تأثیر را بر مقاومت فشاری نسبت به سایر ورودی‌ها دارد.

Asteris و همکاران (2021) از روش‌های یادگیری ماشین و شبکه عصبی مصنوعی برای پیش‌بینی مقاومت کششی و فشاری بتن استفاده کردند. بعد از آموزش مدل‌ها، مقایسه RMSE و MAPE به‌دست آمده برای هر دو مدل نشان‌دهنده عملکرد بهتر ANN بود. دسته دیگری از پژوهش‌ها نیز با استفاده از الگوریتم‌های تکاملی که زیرشاخه‌ای از هوش مصنوعی هستند به تحلیل این موضوع پرداختند.

Golafshani و Behnood (2018) مقاومت کششی بتن حاوی سنگدانه‌های بازیافتی را با استفاده از سه مدل ژنتیک، کلونی زنبور و بهینه‌سازی مبتنی بر جغرافیای زیستی بررسی کردند. آن‌ها مدل‌های مورد استفاده را به‌عنوان الگوریتم‌های قابل اعتماد برای پیش‌بینی مدول الاستیک گزارش کردند. آن‌ها

4-1- الگوریتم فراابتکاری

بهینه‌سازی ازدحام ذرات (PSO) یک الگوریتم بهینه‌سازی است که به‌عنوان یک روش فراابتکاری طبقه‌بندی می‌شود که از رفتار جمعی مشاهده شده در پرندگان و ماهی‌ها الهام می‌گیرد (Amani و Sarkodie, 2022).

بهینه‌سازی ازدحام ذرات که به دلیل اثربخشی و سازگاری در پرداختن به مسائل بهینه‌سازی شهرت دارد، یک سیستم اجتماعی را شبیه‌سازی می‌کند که در آن افراد که به‌عنوان ذرات به تصویر کشیده می‌شوند، با هم کار می‌کنند تا بهترین راه حل را در یک فضای جستجوی معین کشف کنند. قدرت حل مسئله بهینه‌سازی ازدحام ذرات بر اساس مجموعه‌ای از اصول اساسی است که عملیات آن را هدایت می‌کند (Jain و همکاران, 2022).

در حوزه بهینه‌سازی یک مسئله، بهینه‌سازی ازدحام ذرات با قرار دادن تصادفی جمعیتی از ذرات در فضای راه حل آغاز می‌شود (Du و همکاران, 2019). مکان هر ذره در این فضا نشان‌دهنده یک راه حل ممکن است و مسیر حرکت آن تحت تأثیر دو عامل مهم است: تاریخچه فردی آن و عملکرد ذره با عملکرد برتر در مجاورت آن (Gad, 2022).

هدف ذرات از طریق تنظیمات مکرر موقعیت خود، نزدیک شدن به بهینه جهانی، حفظ تعادل ظریف بین اکتشاف و بهره‌برداری است. این استراتژی مشارکتی بهینه‌سازی ازدحام ذرات را قادر می‌سازد تا به‌طور کارآمد فضای جستجو را به‌صورت غیرمتمرکز کاوش و بهره‌برداری کند. تعیین حرکت ذرات شامل محاسبه تغییر سرعت با استفاده از رابطه (1) است.

$$\vec{v}_{ij}(h+1) = \varphi_1 e_1 (\vec{z}_{ij}(h) - \vec{x}_{ij}(h)) + \varphi_2 e_2 (\vec{z}_{gi}(h) - \vec{y}_{ij}(h)) + W \vec{v}_{ij}(h) \quad (1)$$

که در آن، $\vec{v}_{ij}(h)$ نشان‌دهنده سرعت ذره i در طول تکرار h است، در حالی که $\vec{y}_{ij}(h)$ نشان‌دهنده مکان ذره i در همان تکرار است. عبارات e_1 و e_2 اعداد تصادفی در محدوده (0,1) هستند و φ_1 و φ_2 ثابت هستند. علاوه بر این، $\vec{z}_{ij}(h)$ بهترین مکان یک ذره را نشان می‌دهد و $\vec{z}_{gi}(h)$ نشان‌دهنده بهترین مکان کل ازدحام ذرات است. W نیز یک مقدار ثابت است. محاسبه مکان جدید یک ذره با رابطه (2) تعیین می‌شود.

$$\vec{y}_{ij}(h+1) = \vec{y}_{ij}(h) + \vec{v}_{ij}(h+1) \quad (2)$$

در این مقاله، بهینه‌سازی ازدحام ذرات برای بهینه‌سازی فرایارامترهای مدل یادگیری ماشین، با هدف افزایش دقت در عملکرد کار استفاده می‌شود. نمودار جریان بهینه‌سازی ازدحام ذرات در شکل (1) نشان داده شده است.

با تجزیه و تحلیل مجموعه داده‌های گسترده در مورد خواص مصالح و شرایط محیطی، مدل‌های یادگیری ماشین می‌توانند الگوها و روابط پیچیده را شناسایی کنند، پیش‌بینی‌های دقیق و قابل اعتمادی را ارائه می‌کنند که منجر به تولید مخلوط‌های بتن با مقاومت فشاری بالا کمک می‌کند (Gholampour و همکاران, 2020).

در این مقاله از توانایی روش‌های یادگیری ماشین و الگوریتم‌های فراابتکاری برای ساخت یک مدل پیش‌بینی‌کننده استفاده شده است که می‌تواند با دقت بالایی مقاومت بتن و عوامل مؤثر بر آن را شناسایی و پیش‌بینی کند. ویژگی‌هایی که در این پژوهش مورد استفاده قرار خواهد گرفت در جدول (1) ذکر شده است (Yeh, 2006).

جدول 1- ویژگی‌های مورد استفاده در مدل یادگیری ماشین

نام ویژگی	واحد اندازه‌گیری	نوع	نقش
سیمان	کیلوگرم در مترمکعب	کمی	وابسته
سرباره کوره بلند	کیلوگرم در مترمکعب	کمی	وابسته
خاکستر بادی	کیلوگرم در مترمکعب	کمی	وابسته
آب	کیلوگرم در مترمکعب	کمی	وابسته
فوق روان‌کننده	کیلوگرم در مترمکعب	کمی	وابسته
سنگ‌دانه درشت	کیلوگرم در مترمکعب	کمی	وابسته
سنگ‌دانه ریز	کیلوگرم در مترمکعب	کمی	وابسته
سن	روز (1-365)	کمی	وابسته
مقاومت فشاری بتن	مگاپاسکال	کمی	مستقل


سنگ‌دانه جز مصالح اصلی تشکیل‌دهنده بتن است که پس از مخلوط شدن آب و سیمان با نسبت‌های مناسب پیوند می‌یابد. بنابراین کیفیت سنگ‌دانه بر مقاومت بتن تأثیر می‌گذارد. به‌طور کلی سنگ‌دانه‌ها در دو دسته درشت‌دانه و ریزدانه تقسیم می‌شوند و حدود 80 درصد حجم بتن را تشکیل می‌دهند. فوق روان‌کننده‌ها نیز نیاز به آب را بدون این که بر کارایی تأثیر بگذارند بین 15 تا 20 درصد کاهش می‌دهند که منجر به افزایش مقاومت فشاری بتن می‌شود. نسبت آب به سیمان یکی از مهم‌ترین عوامل مؤثر بر مقاومت بتن است که رابطه مستقیمی با مقاومت فشاری بتن دارد و در طرح‌های مختلف میزان آن متفاوت است (Prasad, 2024).

4- روش پژوهش

در این بخش، الگوریتم فراابتکاری که برای تنظیم فرایارامترهای مدل یادگیری ماشین استفاده می‌شود، الگوریتم یادگیری ماشین و معیارهای ارزیابی معرفی می‌شوند.

که در آن L تابع از دست دادن است، y_i برچسب واقعی برای مشاهده i -ام، $\hat{y}_i$ مقدار پیش‌بینی شده، K تعداد درختان، $\Omega(f_s)$ عبارت تنظیم کننده برای درخت k -امین است و θ نشان‌دهنده مجموعه پارامترهایی است که باید بهینه شوند.

نوآوری اصلی الگوریتم تقویت گرادیان شدید در استفاده از تقویت گرادیان نهفته است که در آن هر درخت جدید با توجه به پیش‌بینی مدل فعلی با گرادیان منفی تابع ضرر مطابقت دارد (Asselman و همکاران، 2023). این فرآیند به الگوریتم تقویت گرادیان شدید اجازه می‌دهد تا بر تصحیح خطاهای ایجاد شده توسط مدل موجود تأکید کند و به یک مدل نهایی بسیار دقیق و تعمیم‌یافته منجر شود. ساختار کلی الگوریتم تقویت گرادیان شدید در شکل (2) نشان داده شده است.



شکل 2- ساختار کلی الگوریتم تقویت گرادیان شدید (Wang و همکاران، 2019)

3-4- معیارهای ارزیابی

معیارهای مختلفی برای ارزیابی یک مدل یادگیری ماشین قابل استفاده است و تعدادی از آن‌ها در زیر ارائه شده است:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (5)$$


$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (6)$$

5- نتایج عددی و بحث

در این بخش، تجزیه و تحلیل داده‌های اکتشافی برای دریافت بینشی از متغیرها و رابطه آن‌ها ارائه شده و پس از آن، یک مدل پیش‌بینی کننده، آموزش داده می‌شود.

5-1- تجزیه و تحلیل داده‌های اکتشافی

تجزیه و تحلیل همبستگی متغیرهای مستقل و وابسته در شکل (3) نشان داده شده است که با بررسی آن می‌توان نتایجی را از روابط این متغیرها دریافت کرد. مقاومت فشاری سیمان و



شکل 1- نمودار جریان بهینه‌سازی ازدحام ذرات

4-2- یادگیری ماشین

یادگیری نظارت شده یکی از سه شاخه یادگیری ماشین را تشکیل می‌دهد که شامل دو جزء اصلی است: 1) رگرسیون، 2) طبقه‌بندی. در رگرسیون، پیش‌بینی یک داده بر اساس متغیرهای مستقل انجام می‌شود (Nasiri و Amani، 2023).

الگوریتم تقویت گرادیان شدید (XGBoost) یک الگوریتم یادگیری ماشین محبوب و قدرتمند است که در دسته یادگیری گروهی قرار می‌گیرد (Kiangala و Wang، 2021). به‌طور خاص، این یک الگوریتم تقویتی است که پیش‌بینی‌های چند یادگیرنده ضعیف، معمولاً درخت‌های تصمیم‌گیری را برای ایجاد یک مدل پیش‌بینی قوی ترکیب می‌کند (Asselman و همکاران، 2023). یکی از نقاط قوت کلیدی الگوریتم تقویت گرادیان شدید، توانایی آن در انجام کارآمد وظایف رگرسیون و طبقه‌بندی است (Dhaliwal و همکاران، 2018).

الگوریتم تقویت گرادیان شدید به دلیل دقت پیش‌بینی بالا کاربرد گسترده‌ای به‌دست آورده است. این الگوریتم در هسته خود، مجموعه‌ای از درخت‌های تصمیم را به‌طور متوالی می‌سازد، با هدف هر درخت تصحیح خطاهای قبلی الگوریتم یک تابع هدف منظم شده را به حداقل می‌رساند، که از دو جزء اصلی تشکیل شده است: تابع ضرر، اندازه‌گیری تفاوت بین مقادیر پیش‌بینی شده و واقعی، و یک عبارت منظم‌سازی، که از پیچیده شدن مدل و بیش از حد برازش داده‌های آموزشی جلوگیری می‌کند (Dhaliwal و همکاران، 2018). تابع هدف برای الگوریتم تقویت گرادیان شدید را می‌توان به‌صورت زیر بیان کرد:

$$Objective(\theta) = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (3)$$


جدول 2- مقایسه مدل‌های ساخته شده با الگوریتم‌های یادگیری ماشین

الگوریتم	دقت مدل (درصد)
جنگل تصادفی	91.9
درخت تصمیم	82.5
XGboost	93.7
Ada Boost	85.53
Gradient Boost	93.1
رگرسیون خطی	78.4
رگرسیون لاسو	78.9
XGboost + PSO	95.66

2-5- مدل یادگیری ماشین


پس از تجزیه و تحلیل رابطه بین برخی از متغیرها و مقاومت فشاری بتن، مدل پیش‌بینی بر اساس متغیرهای مستقل آموزش داده می‌شود. برای این منظور، پس از اعمال برخی روش‌های پیش پردازش بر روی مجموعه داده، به مجموعه آموزشی و مجموعه آزمایشی تقسیم شد که به ترتیب 75٪ و 25٪ داده‌ها به آن اختصاص داده می‌شوند.

برخی از الگوریتم‌های طبقه‌بندی برای ساخت مدل یادگیری ماشین استفاده می‌شوند و نتایج در جدول (2) ذکر شده است. بر اساس جدول (2) و شکل (4)، ترکیب طبقه‌بندی کننده الگوریتم XGBoost و الگوریتم PSO عملکرد بهتری را نسبت به سایرین نشان می‌دهد. در جدول (3) پارامترهای مهم الگوریتم‌های PSO و یادگیری ماشین قید شده‌اند. علاوه بر این، تجزیه و تحلیل اهمیت ویژگی برای شناسایی تأثیر هر متغیر بر متغیر مقاومت فشاری بتن پس از آموزش مدل انجام می‌شود. نتایج در شکل (5) نشان داده شده است. بر اساس شکل (5)، می‌توان مشاهده کرد که متغیر سن بیشترین تأثیر را بر مقاومت فشاری بتن دارد و بعد از آن میزان سیمان بیشترین تأثیر را دارد. همچنین، سایر متغیرهای تأثیرگذار بر مقاومت فشاری بتن در شکل (5) قابل مشاهده است.



شکل 4- مقایسه دقت مدل‌های یادگیری ماشین

بتن: همبستگی 0/5 است که همبستگی مثبت متوسطی است. این نشان می‌دهد که با افزایش مقدار سیمان، مقاومت فشاری بتن نیز افزایش می‌یابد. آب و فوق روان‌کننده: همبستگی منفی قوی 0/66- وجود دارد. این نتیجه نشان می‌دهد که هر چه فوق روان‌کننده بیشتر استفاده شود، آب کمتری مورد نیاز است. فوق روان‌کننده‌ها برای افزایش کارایی بتن استفاده می‌شوند و امکان کاهش محتوای آب را بدون کاهش کارایی بتن فراهم می‌کنند.



شکل 3- تجزیه و تحلیل همبستگی متغیرها

خاکستر بادی و فوق روان‌کننده: این‌ها همبستگی 0/38 دارند، یک همبستگی مثبت متوسط، که به این معنی است که مقدار خاکستر بادی و فوق روان‌کننده با هم افزایش می‌یابد. خاکستر بادی می‌تواند کارایی را بهبود بخشد و محتوای آب را کاهش دهد، به همین دلیل است که از آن در ترکیب با فوق روان‌کننده‌ها استفاده می‌شود. سنگ‌دانه ریز و آب: این جفت دارای همبستگی 0/45- است که نشان‌دهنده همبستگی منفی متوسط است. به این معنی است که افزایش مقدار سنگ‌دانه ریز ممکن است با کاهش محتوای آب همراه باشد.

سن و مقاومت فشاری بتن: با همبستگی 0/33 نشان‌دهنده یک رابطه مثبت است، البته نه خیلی قوی، که نشان می‌دهد با افزایش سن بتن، مقاومت فشاری آن افزایش می‌یابد، که انتظار می‌رود با افزایش مقاومت بتن در طول زمان.

سرباره کوره بلند و خاکستر بادی: یک همبستگی منفی 0/32- وجود دارد که می‌تواند نشان دهد که در مخلوط‌هایی که از سرباره کوره بلند استفاده می‌شود، خاکستر بادی کمتری وجود دارد و بالعکس.

آب و سیمان: همبستگی 0/08- است که همبستگی منفی بسیار ضعیفی است که نشان می‌دهد بین میزان آب و سیمان مصرفی در مخلوط بتن رابطه معنی‌داری وجود ندارد.


بتن، با هدف استخراج داده‌های کاربردی استفاده شده است. علاوه بر این، یک مدل پیش‌بینی از طریق ادغام یادگیری ماشین و الگوریتم PSO ایجاد گردیده است. مدل حاصل از دقت 95/66 درصدی برخوردار است که پیش‌بینی مقاومت فشاری بتن را تسهیل می‌کند. این موضوع نه تنها به تصمیم‌گیرندگان در رسیدگی سریع به داشتن دیدی از میزان مقاومت فشاری بتن کمک می‌کند، بلکه اطلاعات ارزشمندی را برای افزایش مقاومت ساختمان‌ها فراهم می‌نماید. در نتیجه، اجرای چنین برنامه‌هایی برای رسیدن به استحکام مناسب، که سازه‌ها را قادر می‌سازد تا بارهای سنگین و شرایط محیطی سخت را تحمل کنند مفید است و نیاز به تعمیرات مکرر را به حداقل می‌رساند و برای رسیدن به یک محیط شهری پایدار و انعطاف‌پذیر کمک می‌کند. این امر ثبات، احساس امنیت و رفاه ساکنین را افزایش داده و تعاملات و فعالیت‌های اجتماعی را ارتقا می‌دهد. برای تحقیقات آینده، می‌توان از سایر الگوریتم‌های یادگیری ماشین و یادگیری عمیق برای افزایش دقت مدل استفاده کرد و ویژگی‌های جدید مربوط به دیگر عوامل مؤثر در استحکام ساختمان‌ها را بررسی نمود و سایر مشکلات شهری را برای افزایش رفاه محل زندگی مورد تجزیه و تحلیل قرار داد.

7- مراجع

- Abdeljaber O, Avci O, Inman DJ, "Active vibration control of flexible cantilever plates using piezoelectric materials and artificial neural networks", *Journal of sound and Vibration*, 2016, 363, 33-53. <https://doi.org/10.1016/j.jsv.2015.10.029>
- Abdollahzadeh G, Jahani E, Kashir Z, "Predicting of compressive strength of recycled aggregate concrete by genetic programming", *Computers and Concrete*, 2016, 18, 155-163. <https://doi.org/10.12989/cac.2016.18.2.155>
- Amani MA, Nasiri MM, "A novel cross docking system for distributing the perishable products considering preemption: a machine learning approach", *Journal of Combinatorial Optimization*, 2023, 45, 130. <https://doi.org/10.1007/s10878-023-01057-y>
- Amani MA, Sarkodie SA, "Mitigating spread of contamination in meat supply chain management using deep learning", *Scientific Reports*, 2022, 12, 5037. <https://doi.org/10.1038/s41598-022-08993-5>
- Amani MA, Sarkodie SA, Shue JB, Nasiri MM, Tavakkoli-Moghaddam R, "A hybrid scenario-based robust model to design a relief logistics network: a data-driven approach", 2023, 33, 1-41. <http://dx.doi.org/10.2139/ssrn.4377160>
- Asselman A, Khaldi M, Aammou S, "Enhancing the prediction of student performance based on the machine learning XGBoost algorithm", *Interactive Learning Environments*, 2023, 31, 3360-3379. <https://doi.org/10.1080/10494820.2021.1928235>
- Asteris PG, Skentou AD, Bardhan A, Samui P, Pilakoutas K, "Predicting concrete compressive strength using

جدول 3- پارامترهای مهم الگوریتم‌های PSO و XGBoost

PSO	
اسم پارامتر	مقدار
تعداد ذرات	50
C_1	1
C_2	1/5
تعداد تکرار	100
XGBoost	
اسم پارامتر	مقدار
نرخ یادگیری	0/1
max_depth	4
min_child_weight	6
gamma	0



شکل 5- میزان تأثیر هر متغیر بر روی مقاومت فشاری بتن

مدل‌های پیش‌بینی‌کننده و یادگیری ماشین، نتایج ضروری را در مورد مقاومت فشاری بتن به مهندسان عمران و مدیران شهری ارائه می‌دهند، زیرا آن‌ها را قادر می‌سازد تا نتایج عملکرد را با دقت و کارایی بالا پیش‌بینی کنند. این مدل‌ها می‌توانند مقادیر زیادی از داده‌های پیشین را برای شناسایی متغیرهای کلیدی که بر مقاومت فشاری بتن تأثیر می‌گذارند، تحلیل نمایند. با درک این عوامل، تصمیم‌گیرندگان می‌توانند طرح‌های ترکیبی و فرآیندهای تولید را برای دستیابی به ویژگی‌های مقاومت فشاری بتن مورد نظر و در عین حال به حداقل رساندن هزینه‌ها و استفاده از منابع، بهینه کنند. این رویکرد مبتنی بر داده، در نهایت منجر به تصمیمات آگاهانه، به موقع و استراتژیک در مدیریت ساخت‌وساز می‌شود.

6- نتیجه‌گیری

مقاومت فشاری بتن با تعیین دوام، ایمنی و طول عمر ساختمان‌ها و زیرساخت‌ها بر فضاهای شهری و زندگی اجتماعی تأثیر زیادی می‌گذارد. بنابراین، در این مطالعه از تکنیک‌های تحلیل داده‌ها برای بررسی ویژگی‌های مؤثر در مقاومت فشاری

- support vector regression (LSSVR) models", *Neural Computing and Applications*, 2020, 32, 295-308.
<https://doi.org/10.1007/s00521-018-3630-y>
- Golafshani EM, Behnood A, "Automatic regression methods for formulation of elastic modulus of recycled aggregate concrete", *Applied Soft Computing*, 2018, 64, 377-400.
<https://doi.org/10.1016/j.asoc.2017.12.030>
- Güçlüer K, Özbeyaz A, Göymen S, Günaydın O, "A comparative investigation using machine learning methods for concrete compressive strength estimation", *Materials Today Communications*, 2021, 27, 102278.
<https://doi.org/10.1016/j.mtcomm.2021.102278>
- Han Q, Gui C, Xu J, Lacidogna G, "A generalized method to predict the compressive strength of high-performance concrete by improved random forest algorithm", *Construction and Building Materials*, 2019, 226, 734-742.
<https://doi.org/10.1016/j.conbuildmat.2019.07.315>
- Iqbal MF, Liu Q-F, Azim I, Zhu X, Yang J, Javed MF, Rauf M, "Prediction of mechanical properties of green concrete incorporating waste foundry sand based on gene expression programming", *Journal of Hazardous Materials*, 2020, 384, 121322.
<https://doi.org/10.1016/j.jhazmat.2019.121322>
- Jain M, Saihpal V, Singh N, Singh SB, "An overview of variants and advancements of PSO algorithm", *Applied Sciences*, 2022, 12, 8392.
<https://doi.org/10.3390/app12178392>
- Jalal M, Jalal H, "Retracted: Behavior assessment, regression analysis and support vector machine (SVM) modeling of waste tire rubberized concrete", *Elsevier*, 2020.
<https://doi.org/10.1016/j.jclepro.2020.122960>
- Jiang X, Mahadevan S, Adeli H, "Bayesian wavelet packet denoising for structural system identification", *Structural Control and Health Monitoring: The Official Journal of the International Association for Structural Control and Monitoring and of the European Association for the Control of Structures*, 2007, 14, 333-356.
<https://doi.org/10.1002/stc.161>
- Khademi F, Akbari M, Jamal SM, Nikoo M, "Multiple linear regression, artificial neural network, and fuzzy logic prediction of 28 days compressive strength of concrete", *Frontiers of Structural and Civil Engineering*, 2017, 11, 90-99.
<https://doi.org/10.1007/s11709-016-0363-9>
- Khurshid K, Danish A, Salim MU, Bayram M, Ozbakkaloglu T, Mosaberpanah MA, "An in-depth survey demystifying the Internet of Things (IoT) in the construction industry: Unfolding new dimensions", *Sustainability*, 2023, 15, 1275.
<https://doi.org/10.3390/su15021275>
- Kiangala SK, Wang Z, "An effective adaptive customization framework for small manufacturing plants using extreme gradient boosting-XGBoost and random forest ensemble learning algorithms in an Industry 4.0 environment", *Machine Learning with Applications*, 2021, 4, 100024.
<https://doi.org/10.1016/j.mlwa.2021.100024>
- hybrid ensembling of surrogate machine learning models", *Cement and Concrete Research*, 2021, 145, 106449.
<https://doi.org/10.1016/j.cemconres.2021.106449>
- Baduge SK, Thilakarathna S, Perera JS, Arashpour M, Sharafi P, Teodosio B, Shringi A, Mendis P, "Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications", *Automation in Construction*, 2022, 141, 104440.
<https://doi.org/10.1016/j.autcon.2022.104440>
- Behnood A, Verian KP, Gharehveran MM, "Evaluation of the splitting tensile strength in plain and steel fiber-reinforced concrete based on the compressive strength", *Construction and Building Materials*, 2015, 98, 519-529.
<https://doi.org/10.1016/j.conbuildmat.2015.08.124>
- Chatterjee AK, *Intelligent and Sustainable Cement Production: Transforming to Industry 4.0 Standards*, CRC Press, 2015.
<https://doi.org/10.1201/9781003106791>
- Chopra P, Sharma RK, Kumar M, Chopra T, "Comparison of machine learning techniques for the prediction of compressive strength of concrete", *Advances in Civil Engineering*, 2018.
<https://doi.org/10.1155/2018/5481705>
- Dhaliwal SS, Nahid A-A, Abbas R, "Effective intrusion detection system using XGBoost", *Information*, 2018, 9, 149.
<https://doi.org/10.3390/info9070149>
- Dinesh A, Prasad BR, "Predictive models in machine learning for strength and life cycle assessment of concrete structures", *Automation in Construction*, 2024, 162, 105412.
<https://doi.org/10.1016/j.autcon.2024.105412>
- Du B, Wei Q, Liu R, "An improved quantum-behaved particle swarm optimization for endmember extraction", *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57, 6003-6017.
<https://doi.org/10.1109/TGRS.2019.2903875>
- Dutta D, Barai SV, "Prediction of compressive strength of concrete: machine learning approaches", *Recent Advances in Structural Engineering, Volume 1: Select Proceedings of SEC 2016, 2019*, Springer, 503-513.
https://doi.org/10.1007/978-981-13-0362-3_40
- Feng D-C, Liu Z-T, Wang X-D, Chen Y, Chang J-Q, Wei D-F, Jiang Z-M, "Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach", *Construction and Building Materials*, 2020, 230, 117000.
<https://doi.org/10.1016/j.conbuildmat.2019.117000>
- Gad AG, "Particle swarm optimization algorithm and its applications: a systematic review", *Archives of Computational Methods in Engineering*, 2022, 29, 2531-2561.
<https://doi.org/10.1007/s11831-021-09694-4>
- Gholampour A, Mansouri I, Kisi O, Ozbakkaloglu T, "Evaluation of mechanical properties of concretes containing coarse recycled concrete aggregates using multivariate adaptive regression splines (MARS), M5 model tree (M5Tree), and least squares

- green objectives", *Engineering Structures*, 2018, 157, 119-131.
<https://doi.org/10.1016/j.engstruct.2017.11.022>
- Yeh I-C, "Analysis of strength of concrete using design of experiments and neural networks", *Journal of Materials in Civil Engineering*, 2006, 18, 597-604.
[https://doi.org/10.1061/\(ASCE\)0899-1561\(2006\)18:4\(597\)](https://doi.org/10.1061/(ASCE)0899-1561(2006)18:4(597))
- Zhang W, Zheng Q, Ashour A, Han B, "Self-healing cement concrete composites for resilient infrastructures: A review", *Composites Part B: Engineering*, 2020, 189, 107892.
<https://doi.org/10.1016/j.compositesb.2020.107892>
- Liu Q, Sun P, Fu X, Zhang J, Yang H, Gao H, Li Y, "Comparative analysis of BP neural network and RBF neural network in seismic performance evaluation of pier columns", *Mechanical Systems and Signal Processing*, 2020, 141, 106707.
<https://doi.org/10.1016/j.ymssp.2020.106707>
- Mangalathu S, Jeon J-S, "Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using machine learning techniques", *Engineering Structures*, 2018, 160, 85-94.
<https://doi.org/10.1016/j.engstruct.2018.01.008>
- Moein MM, Saradar A, Rahmati K, Mousavinejad SHG, Bristow J, Aramali V, Karakouzian M, "Predictive models for concrete properties using machine learning and deep learning approaches: A review", *Journal of Building Engineering*, 2023, 63, 105444.
<https://doi.org/10.1016/j.job.2022.105444>
- Mouratidis K, "Urban planning and quality of life: A review of pathways linking the built environment to subjective well-being", *Cities*, 2021, 115, 103229.
<https://doi.org/10.1016/j.cities.2021.103229>
- Naderpour H, Poursaeidi O, Ahmadi M, "Shear resistance prediction of concrete beams reinforced by FRP bars using artificial neural networks", *Measurement*, 2018, 126, 299-308.
<https://doi.org/10.1016/j.measurement.2018.05.051>
- Omran BA, Chen Q, Jin R, "Comparison of data mining techniques for predicting compressive strength of environmentally friendly concrete", *Journal of Computing in Civil Engineering*, 2016, 30, 04016029.
[https://doi.org/10.1061/\(ASCE\)CP.1943-5487.000059](https://doi.org/10.1061/(ASCE)CP.1943-5487.000059)
- Quah TKN, Tay YWD, Lim JH, Tan MJ, Wong TN, LI KHH, "Concrete 3D printing: process parameters for process control, monitoring and diagnosis in automation and construction", *Mathematics*, 2023, 11, 1499.
<https://doi.org/10.3390/math11061499>
- Salehi H, Burgueño R, "Emerging artificial intelligence methods in structural engineering", *Engineering Structures*, 2018, 171, 170-189.
<https://doi.org/10.1016/j.engstruct.2018.05.084>
- Shi H-S, Xu B-W, Zhou X-C, "Influence of mineral admixtures on compressive strength, gas permeability and carbonation of high performance concrete", *Construction and Building Materials*, 2009, 23, 1980-1985.
<https://doi.org/10.1016/j.conbuildmat.2008.08.021>
- Tahmouresi B, Nemati P, Asadi MA, Saradar A, Moein MM, "Mechanical strength and microstructure of engineered cementitious composites: A new configuration for direct tensile strength, experimental and numerical analysis", *Construction and Building Materials*, 2021, 269, 121361.
<https://doi.org/10.1016/j.conbuildmat.2020.121361>
- Wang Z, Jin W, Dong Y, Frangopol DM, "Hierarchical life-cycle design of reinforced concrete structures incorporating durability, economic efficiency and