

Prediction of Compressive Strength of High-Performance Concrete Using Gradient Boosting Regression and Ada Boost Regression Models

Amin Khazaei^{1*} , Ali Khazaei²

¹ Department of Civil Engineering, Esfarayen University of Technology, Esfarayen, Iran

² Department of Electrical Engineering, University of Bojnord, Bojnord, Iran

ARTICLE INFO

Article Type

Original Research

Article History

Received: February 05, 2026

Revised: May 06, 2026

Accepted: May 09, 2026

ePublished: June 17, 2026

ABSTRACT

Compressive strength is one of the most critical performance indicators of high-performance concrete (HPC), playing a key role in the safety, durability, and load-bearing capacity of structures. Due to the time-consuming and costly nature of conventional laboratory testing methods for determining this parameter, the application of intelligent data-driven approaches has gained increasing attention as an efficient and accurate alternative. In this study, to predict the compressive strength of high-performance concrete, two models—Gradient Boosting Regression and Ada Boost Regression—were employed as advanced machine learning algorithms. The dataset used in this research consists of 1,030 experimental HPC samples collected from the University of California, Irvine database, including various mix design parameters such as cement content, water, blast furnace slag, fly ash, superplasticizer, aggregates, and specimen age. Initially, correlation analysis was conducted to examine the relationships between input variables and compressive strength, revealing that cement content, concrete age, and superplasticizer dosage have the strongest positive correlations, while water content exhibits the most significant negative correlation with compressive strength. Subsequently, the proposed model was trained and evaluated using a ten-fold cross-validation strategy. Subsequently, the two proposed models were trained and evaluated using 10-fold cross-validation. The results demonstrated that the Gradient Boosting Regression model possesses higher accuracy and reliability in predicting the compressive strength of high-performance concrete compared to the Ada Boost Regression model across all evaluation metrics. The findings of this study highlight the strong potential of boosting-based machine learning algorithms as reliable and cost-effective alternatives to traditional experimental methods for the design and performance assessment of advanced concrete materials.

Keywords: High-Performance Concrete (HPC), Compressive Strength, Machine Learning, Gradient Boosting Regression, Ada Boost Regression

How to cite this article

Khazaei A., Khazaei A., Prediction of Compressive Strength of High-Performance Concrete Using Gradient Boosting Regression Model. *Modares Mechanical Engineering*; 2026;26(08):598-607.

*Corresponding author's email: a.khazaei@esfarayen.ac.ir

*Corresponding ORCID ID: 0009-0007-8688-6306



Copyright© 2026, TMU Press. This open-access article is published under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.



پیش بینی مقاومت فشاری بتن توانمند با استفاده از مدل رگرسیون گرادیان تقویتی و رگرسیون تقویتی آدا

امین خزائی*^۱، علی خزائی^۲

^۱ گروه مهندسی عمران، مجتمع آموزش عالی فنی و مهندسی اسفراین، اسفراین، ایران
^۲ گروه مهندسی برق، دانشگاه بجنورد، بجنورد، ایران

چکیده

مقاومت فشاری یکی از مهم‌ترین شاخص‌های عملکردی بتن توانمند است که نقش تعیین‌کننده‌ای در ایمنی، دوام و ظرفیت باربری سازه‌ها ایفا می‌کند. با توجه به هزینه‌بر و زمان‌بر بودن روش‌های آزمایشگاهی متداول برای تعیین این پارامتر، استفاده از روش‌های هوشمند داده‌محور می‌تواند راهکاری کارآمد و دقیق باشد. در این پژوهش، به منظور پیش‌بینی مقاومت فشاری بتن توانمند، از دو مدل رگرسیون گرادیان تقویتی و رگرسیون تقویتی آدا به عنوان دو مورد از الگوریتم‌های پیشرفته یادگیری ماشین استفاده شده است. مجموعه داده مورد استفاده شامل ۱۰۳۰ نمونه آزمایشگاهی بتن توانمند بوده که از پایگاه داده دانشگاه کالیفرنیا، ایروین گردآوری شده و پارامترهای مختلف طرح اختلاط از جمله مقدار سیمان، آب، سرباره کوره بلند، خاکستر بادی، فوق‌روان‌کننده، سنگدانه‌ها و سن نمونه را در بر می‌گیرد. در گام نخست، تحلیل همبستگی بین متغیرهای ورودی و مقاومت فشاری انجام شد که نتایج آن نشان داد مقدار سیمان، سن بتن و فوق‌روان‌کننده بیشترین همبستگی مثبت و مقدار آب بیشترین همبستگی منفی را با مقاومت فشاری دارند. سپس دو مدل پیشنهادی با استفاده از اعتبارسنجی متقابل ده‌گانه آموزش و ارزیابی شده‌اند. نتایج حاصل نشان داد که مدل رگرسیون گرادیان تقویتی در تمامی معیارهای ارزیابی نسبت به رگرسیون تقویتی آدا، از دقت و قابلیت اطمینان بالاتری در پیش‌بینی مقاومت فشاری بتن توانمند برخوردار است. یافته‌های این تحقیق بیانگر توانمندی بالای الگوریتم‌های تقویتی یادگیری ماشین به عنوان ابزارهای کمکی مناسب و توانمند در کنار روش‌های آزمایشگاهی سنتی در طراحی و ارزیابی بتن‌های پیشرفته است.

اطلاعات مقاله

نوع مقاله
مقاله پژوهشی

تاریخچه مقاله

دریافت: ۱۴۰۴/۱۱/۱۶
بازنگری: ۱۴۰۵/۰۲/۱۶
پذیرش: ۱۴۰۵/۰۲/۱۹
ارائه آنلاین: ۱۴۰۵/۰۳/۲۷

کلید واژه‌ها: بتن توانمند، مقاومت فشاری، یادگیری ماشین، رگرسیون گرادیان تقویتی، رگرسیون تقویتی آدا

نحوه ارجاع به این مقاله

خزائی امین، خزائی علی، پیش بینی مقاومت فشاری بتن توانمند با استفاده از مدل رگرسیون گرادیان تقویتی و رگرسیون تقویتی آدا، مهندسی مکانیک مدرس، ۶۰۷-۵۹۸ (۰۸): ۲۶(۱۴۰۵)

*پست الکترونیکی نویسنده عهده‌دار مکاتبات: a.khazaei@esfarayen.ac.ir

*شناسه ارکید نویسنده عهده‌دار مکاتبات: 0009-0007-8688-6306



۱- مقدمه

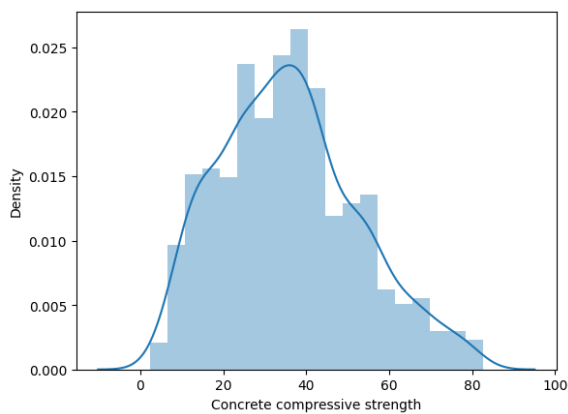
بتن توانمند یا بتن با عملکرد بالا (High Performance Concrete- HPC)، به بتنی گفته می‌شود که علاوه بر دارا بودن مقاومت فشاری بسیار بالا، از دوام و کارایی بیشتر در مقایسه با بتن معمولی (Normal Strength Concrete- NSC) برخوردار است. این نوع بتن تنها بر اساس مقاومت فشاری تعریف نمی‌شود، بلکه ترکیبی از خواص مطلوب برای شرایط محیطی و کاربردی خاص است [۱]. تمایز اصلی بتن با مقاومت معمولی و بتن توانمند در ترکیب افزودنی‌های شیمیایی و معدنی است. افزودنی‌های شیمیایی نقش مهمی در کاهش میزان آب و در نتیجه کاهش تخلخل بتن دارند. افزودنی‌های معدنی، که به عنوان مواد سیمانی مکمل نیز شناخته می‌شوند، بسته به خواص منحصر به فرد خود، عملکردهای مختلفی را انجام می‌دهند. دوده سیلیس، سرباره کوره بلند و خاکستر بادی معمولاً موادی هستند که در بتن توانمند استفاده می‌شوند. این مواد به عنوان پوزولان و پرکننده‌های ریز عمل می‌کنند و پس از سخت شدن، منجر به ماتریس سیمانی متراکم‌تر و قوی‌تر می‌شوند. خاکستر بادی، هنگامی که به عنوان جایگزین جزئی از سیمان استفاده می‌شود، با افزایش زمان گیرش و اغلب بهبود مقاومت نهایی، عملکرد را افزایش می‌دهد. دوده سیلیس به بهبود خواص مکانیکی و افزایش دوام بتن کمک می‌کند. به طور مشابه، استفاده از سرباره نه تنها مقاومت نهایی را بهبود می‌بخشد، بلکه وقتی جایگزین بخشی از سیمان می‌شود، دوام را نیز افزایش می‌دهد. از آنجایی که این افزودنی‌های معدنی معمولاً محصولات جانبی صنعتی هستند، استفاده از آنها مزایای اقتصادی قابل توجهی را ارائه می‌دهد. این مواد در صورت ترکیب با فوق روان‌کننده‌ها، امکان تولید اقتصادی بتن توانمند با مقاومت، کارایی و دوام بهبود یافته را فراهم می‌کنند. مدل‌سازی ریاضی بتن توانمند به دلیل روابط بسیار پیچیده و غیرخطی، به ویژه بین اجزا و خواص آن، چالش برانگیز است. در نتیجه، مدل‌های سنتی اغلب برای پیش‌بینی دقیق مقاومت فشاری بتن توانمند کافی نیستند [۲]. مقاومت فشاری بتن (Concrete Compressive Strength- CCS) یک پارامتر حیاتی در مهندسی عمران است که بر دوام، ایمنی و ظرفیت باربری سازه‌ها تأثیر می‌گذارد. روش‌های سنتی برای تعیین CCS به آزمایش‌های آزمایشگاهی متکی هستند که زمان‌بر و پرهزینه است. در نتیجه، محققان به طور فزاینده‌ای به تکنیک‌های یادگیری ماشین برای پیش‌بینی CCS بر اساس پارامترهای طرح اختلاط، سن و عوامل محیطی روی آورده‌اند [۳]. الگوریتم‌ها و مدل‌های یادگیری ماشین به دلیل در دسترس بودن حجم زیادی از داده‌های تاریخی آزمایشگاهی، به طور گسترده‌ای برای پیش‌بینی مقاومت بتن مورد مطالعات پیشین می‌تواند برای پیش‌بینی مؤثر مقاومت بتن به کار گرفته شود. این مدل‌های یادگیری ماشین با بهره‌گیری از

روش‌های آماری پیشرفته و الگوریتم‌های شناسایی الگو، روابط پیچیده میان اجزای مختلف طرح اختلاط بتن که بر مقاومت آن تأثیر می‌گذارند را آشکار می‌سازند. افزون بر این، این مدل‌ها قابلیت تطبیق‌پذیری برای انواع مختلف بتن توانمند را دارند. با بهبود مستمر دقت پیش‌بینی مقاومت، می‌توان در نهایت کیفیت ساخت‌وساز را ارتقا داده و زمان اجرای پروژه‌ها را تسریع کرد. از این رو، پیش‌بینی سریع و دقیق مقاومت بتن توانمند از نظر اقتصادی دارای ارزش قابل توجهی بوده و در عین حال راهنمایی عملی مهمی برای متخصصان حوزه ساخت‌وساز فراهم می‌کند [۴]. شبکه‌های عصبی مصنوعی (Artificial Neural Networks- ANN) به دلیل توانایی ذاتی در یادگیری روابط غیرخطی پیچیده، ابزار بسیار قدرتمندی برای این موارد هستند. به در سال ۱۹۹۸ و ۲۰۰۷ [۵ و ۶] از شبکه‌های عصبی مصنوعی برای پیش‌بینی مقاومت بتن استفاده کرد و نشان داد که شبکه‌های عصبی مصنوعی به طور قابل توجهی از مدل‌های رگرسیون کلاسیک بهتر عمل می‌کند. چیترا و همکاران [۷] از تحلیل رگرسیون چندگانه و شبکه عصبی مصنوعی برای پیش‌بینی مقاومت فشاری بتن توانمند استفاده کردند. نتایج به دست آمده برای پیش‌بینی توسط شبکه عصبی مصنوعی، دقت و همبستگی بالاتری را با R^2 برابر با ۰.۹۹۸۷ در مقایسه با نتایج رگرسیون نشان داد. سونبی و همکاران [۸]، امکان‌سنجی استفاده از ماشین بردار پشتیبان برای پیش‌بینی خواص تازه بتن خودتراکم را بررسی کردند. نتایج نشان داد که مدل ماشین بردار پشتیبان (Support vector machines- SVM) با کرنل تابع پایه شعاعی در مقایسه با کرنل چندجمله‌ای، دقت بالاتری در پیش‌بینی شاخص‌های مختلف کارایی تازه بتن از جمله جریان اسلامپ، زمان‌های جریان و نسبت انسداد دارد. تحلیل حساسیت نیز بیانگر تأثیر قابل توجه پارامترهای طرح اختلاط و زمان آزمایش بر خواص تازه بتن بوده است. امجد و همکاران [۹] از مدل تقویت گرادیان شدید (Extreme Gradient Boosting) برای پیش‌بینی خواص بتن خودترمیمی با R^2 برابر با ۰.۹۵ استفاده کردند. به طور مشابه، تکنیک‌های مختلف یادگیری ماشین دیگری مانند الگوریتم‌های گروهی (عمران و همکاران [۱۰])، درخت تصمیم (بهنود و همکاران [۱۱]) و شبکه‌های عصبی آشپزی رو به جلو (ایمران و همکاران [۱۲]) برای پیش‌بینی مقاومت فشاری به کار گرفته شده‌اند. مقدس و باثو [۱۳] نشان دادند که استفاده از الگوریتم‌های پیشرفته‌ای نظیر XGBoost، LightGBM و Random Forest می‌تواند دقت پیش‌بینی پارامترهایی مانند عمق سایش بتن را به‌طور قابل‌توجهی افزایش دهد. علاوه بر این، ترکیب مراحل پیش‌پردازش داده‌ها از جمله انتخاب ویژگی و تشخیص ناهنجاری با مدل‌های یادگیری ماشین، منجر به بهبود عملکرد مدل‌ها شده است. به‌کارگیری روش‌های ترکیبی و الگوریتم‌های متنوعی نظیر شبکه‌های عصبی مصنوعی، ماشین بردار پشتیبان، درخت تصمیم و جنگل تصادفی می‌تواند دقت

جدول ۱ مشخصات کلی مصالح مصرفی در بتن


Table 1 General specifications of materials used in concrete

| Component | Unit | Minimum | Maximum | Average | Standard deviation |
|-------------------------------|-------------------|---------|---------|---------|--------------------|
| Cement | Kg/m ³ | 102 | 540 | 281.2 | 104.5 |
| Blast Furnace Slag | Kg/m ³ | 11 | 359.4 | 107.3 | 61.9 |
| Fly Ash | Kg/m ³ | 24.5 | 200.1 | 83.9 | 40 |
| Water | Kg/m ³ | 121.8 | 247 | 181.6 | 24.4 |
| Superplasticizer | Kg/m ³ | 1.7 | 32.2 | 8.5 | 4 |
| Coarse Aggregate | Kg/m ³ | 801 | 1145 | 973 | 77.8 |
| Fine Aggregate | Kg/m ³ | 594 | 992.6 | 773.6 | 80.2 |
| Age of Testing | Day | 1 | 365 | 45.7 | 63.2 |
| Concrete Compressive Strength | MPa | 2.3 | 82.6 | 35.9 | 16.7 |



شکل ۱ توزیع مقادیر مقاومت فشاری

Fig.1 Distribution of compressive strength



شکل ۲ توزیع مقاومت فشاری نمونه ها براساس سن

Fig. 2 Distribution of compressive strength based on age

مختلف به دست آمده است. تمام آزمایش‌ها بر روی نمونه‌های استوانه‌ای استاندارد با قطر ۱۵ سانتی‌متر انجام شده است. جدول ۱ مجموعه داده‌های تجربی مورد استفاده در این مطالعه را نشان می‌دهد. تصویر ۱ توزیع مقادیر مقاومت فشاری را در این مجموعه داده‌ها به صورت هیستوگرام نشان می‌دهد. علاوه بر این توزیع مقادیر مقاومت فشاری براساس سن نمونه‌ها در تصویر ۲ نشان داده است.

پیش‌بینی را بهبود بخشد، زیرا هر الگوریتم دارای ساختار و قابلیت‌های متفاوتی در مدل‌سازی روابط غیرخطی است. سینخوند و همکاران [۱۴] نشان دادند که مدل‌های یادگیری ماشین قادرند مقاومت فشاری بتن حاوی موادی مانند پودر آجر رسی و لاستیک ضایعاتی را با دقت قابل قبولی پیش‌بینی کنند. همچنین، تحلیل‌های تبیین‌پذیر مانند SHAP نشان داده‌اند که میزان لاستیک ضایعاتی به‌عنوان یکی از مهم‌ترین عوامل تأثیرگذار بر مقاومت فشاری بتن شناخته می‌شود، در حالی که سیمان نقش مکمل در طراحی مخلوط ایفا می‌کند. روی و همکاران [۱۵] هفت متغیر مهم را به‌عنوان ورودی برای پیش‌بینی مقاومت فشاری و کششی بتن حاوی خاکستر پوسته برنج با استفاده از مدل‌های یادگیری ماشین، از جمله رگرسیون فرآیند گاوسی، رگرسیون جنگل تصادفی و رگرسیون درخت تصمیم‌گیری با بهینه‌سازی جستجوی شبکه‌ای انتخاب کردند. نتایج ارائه شده نشان داد که در میان این مدل‌ها، مدل رگرسیون درخت تصمیم‌گیری عملکرد برتری در پیش‌بینی مقاومت فشاری با مقادیر R^2 ، RMSE، MAE و MAPE به ترتیب ۰٫۹۶۴، ۳٫۳۱۴، ۲٫۲۲۵ و ۵٫۰۶۸ دارد.

در این پژوهش، با هدف ارائه یک چارچوب دقیق و قابل‌اعتماد برای پیش‌بینی مقاومت فشاری بتن توانمند، از دو الگوریتم پیشرفته یادگیری ماشین مبتنی بر تقویت شامل رگرسیون گرادیان تقویتی و رگرسیون تقویتی آدا به‌صورت موازی استفاده شده است. نوآوری اصلی این تحقیق در مقایسه نظام‌مند عملکرد این دو رویکرد تقویتی در یک بستر داده‌ای یکسان، همراه با تحلیل اولیه همبستگی جهت شناسایی متغیرهای مؤثر، و بهینه‌سازی ساختاری پارامترهای مدل‌ها از طریق جستجوی شبکه‌ای و اعتبارسنجی متقابل ده‌گانه است. برخلاف بسیاری از مطالعات پیشین که تنها بر یک مدل خاص یا یک معیار ارزیابی متمرکز بوده‌اند، در این پژوهش عملکرد مدل‌ها با استفاده از چندین شاخص آماری به‌صورت همزمان ارزیابی شده و پایداری و قابلیت تعمیم آن‌ها به‌طور دقیق مورد بررسی قرار گرفته است. علاوه بر این، تحلیل تطبیقی بین دو الگوریتم تقویتی با مکانیزم‌های یادگیری متفاوت (مبتنی بر گرادیان در مقابل وزن‌دهی تطبیقی نمونه‌ها)، امکان ارائه درک عمیق‌تری از کارایی این روش‌ها در مدل‌سازی روابط غیرخطی پیچیده در بتن توانمند را فراهم می‌سازد. این رویکرد می‌تواند به‌عنوان مبنایی کاربردی برای انتخاب مدل بهینه در طراحی و ارزیابی بتن‌های پیشرفته مورد استفاده قرار گیرد.

۲- داده‌های مورد استفاده

مجموعه داده‌های تجربی مورد استفاده در این مطالعه از داده‌های دانشگاه کالیفرنیا، ایروین [۵] به دست آمده است. مجموعه‌ای از ۱۰۳۰ نمونه بتن بتن توانمند از آزمایشگاه‌های دانشگاه‌های

۳- چارچوب رگرسیون گروهی

برای بهبود دقت پیش‌بینی و افزایش پایداری، از روش‌های رگرسیون گروهی (Ensemble Regression) استفاده کردیم که خروجی چندین یادگیرنده ضعیف را با یکدیگر ترکیب می‌کنند تا یک مدل پیش‌بینی‌کننده قوی‌تر ایجاد شود. این تکنیک‌ها در مسائل رگرسیون به‌ویژه مفید هستند، زیرا می‌توانند به طور مؤثر واریانس و بایاس را کاهش داده و همزمان روابط غیرخطی پیچیده را مدل‌سازی کنند. از میان روش‌های موجود (بسته‌بندی (Bagging)، پشته‌سازی (Stacking) و تقویت (Boosting))، رویکرد تقویت انتخاب شد زیرا بر اساس مطالعات تجربی پیشین عملکرد برتری در مسائل رگرسیون ساختاریافته نشان داده است [۸].

به‌طور کلی، هدف مدل‌های رگرسیونی مورد استفاده در این پژوهش، تقریب تابع نگاشت بین بردار ویژگی‌های ورودی و مقاومت فشاری بتن به صورت $y = f(x)$ است، که در آن x شامل پارامترهای طرح اختلاط و سن نمونه و y مقاومت فشاری متناظر می‌باشد. در رویکردهای رگرسیون گروهی، این تابع به صورت ترکیب خطی از یادگیرنده‌های ضعیف مدل‌سازی می‌شود:

$$\hat{y} = \sum_{m=1}^M \gamma_m h_m(x) \quad (1)$$

که در آن $h_m(x)$ بیانگر یادگیرنده‌های پایه (درخت‌های رگرسیون)، γ_m ضرایب وزن‌دهی هر یادگیرنده و M تعداد کل مراحل تقویت است. تفاوت اصلی میان روش‌های مورد استفاده در این تحقیق در نحوه تعیین ضرایب γ_m و به‌روزرسانی مدل در هر تکرار می‌باشد که در ادامه تشریح می‌گردد. پارامترهای کلیدی هر مدل شامل تعداد مراحل تقویت، نرخ یادگیری و عمق درخت‌های پایه می‌باشند.

۳-۱- رگرسیون گرادیان تقویتی

رگرسیون گرادیان تقویتی (Gradient Boosting Regression)، روشی تجمعی افزایشی است که با برازش متوالی درختان رگرسیون (Tree Regression) به باقیمانده‌های مدل‌های قبلی، به تدریج یک پیش‌بین قوی می‌سازد. در هر مرحله، الگوریتم یک تابع خطای مشتق‌پذیر را با استفاده از روش نزول گرادیان (Gradient Descent) به حداقل می‌رساند. این رویکرد تکراری باعث می‌شود مدل به طور پیوسته روی خطاهای مراحل قبل تمرکز کرده و عملکرد خود را بهبود دهد.

به طور رسمی، اگر مجموعه آموزشی $\{(x_i, y_i)\}_{i=1}^N$ داده شود، مدل تقویت هدف y را به صورت زیر می‌سازد:

$$F_M(x) = F_0(x) + \sum_{m=1}^M \eta \gamma_m h_m(x) \quad (2)$$

که در آن $h_m(x)$ یادگیرنده‌های ضعیف (درخت‌های رگرسیون)، $\eta \in (0, 1]$ نرخ یادگیری (پارامتر کاهش)، γ_m ضرایب بهینه در هر تکرار و M تعداد کل مراحل تقویت است.

فرآیند تقویت با یک مدل اولیه $F_0(x)$ شروع می‌شود که معمولاً به صورت میانگین مقادیر هدف تعریف می‌گردد:

$$F_0(x) = \arg \min_{\gamma} \sum_{i=1}^n L(y_i, \gamma) \quad (3)$$

در تکرار m ، الگوریتم باقیمانده‌های کاذب (Pseudo-residuals) را به صورت گرادیان منفی تابع خطا نسبت به پیش‌بینی فعلی محاسبه می‌کند:

$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{m-1}(x)} \quad \text{for } i = 1, \dots, n \quad (4)$$

سپس یک درخت رگرسیون $h_m(x)$ روی این باقیمانده‌ها برازش داده می‌شود. ضریب بهینه γ_m با حل رابطه زیر به دست می‌آید:

$$\gamma_m = \arg \min_{\gamma} \sum_{i=1}^n L(y_i, F_{m-1}(x_i) + \gamma h_m(x_i)) \quad (5)$$

در نهایت، مدل با استفاده از رابطه زیر به‌روز می‌شود:

$$F_m(x) = F_{m-1}(x) + \eta \gamma_m h_m(x) \quad (6)$$

این روند تا رسیدن به تعداد تکرار M یا همگرایی ادامه می‌یابد. پارامترهای کلیدی این روش شامل تعداد تکرارها M ، عمق حداکثر درخت‌ها، نرخ یادگیری η و نسبت نمونه‌برداری تصادفی با استفاده از جستجوی شبکه‌ای (Grid search) بهینه شدند.

۳-۲- رگرسیون تقویتی آدا

یکی دیگر از روش‌های گروهی مورد استفاده در این مطالعه، رگرسیون تقویتی آدا (Ada Boost Regression) است که در زمرة الگوریتم‌های تقویت تطبیقی (Adaptive Boosting) قرار می‌گیرد. این روش با ترکیب ترتیبی مجموعه‌ای از یادگیرنده‌های ضعیف، معمولاً درخت‌های رگرسیون کم‌عمق، یک پیش‌بین قوی می‌سازد. برخلاف رگرسیون گرادیان تقویتی که به صورت صریح گرادیان تابع خطا را بهینه‌سازی می‌کند، تقویتی آدا با به‌روزرسانی تطبیقی وزن نمونه‌های آموزشی، تمرکز فرآیند یادگیری را به سمت نمونه‌هایی هدایت می‌کند که در مراحل پیشین با خطای بیشتری پیش‌بینی شده‌اند. بدین ترتیب، مدل در هر تکرار توجه بیشتری به نواحی دشوار فضای داده معطوف می‌سازد.

به طور رسمی، با در نظر گرفتن مجموعه داده‌ی آموزشی $\{(x_i, y_i)\}_{i=1}^N$ هدف رگرسیون تقویتی آدا تقریب تابع هدف (y) از طریق یک مدل گروهی به صورت زیر است:

$$F_M(x) = \sum_{m=1}^M \gamma_m h_m(x) \quad (7)$$

که در آن $h_m(x)$ یادگیرنده‌های ضعیف (درخت‌های رگرسیون)، γ_m ضرایب وزن‌دهی هر یادگیرنده و M تعداد کل مراحل تقویت است. این فرم‌بندی کاملاً مشابه ساختار تجمعی مدل در رگرسیون گرادیان تقویتی است، با این تفاوت که ضرایب γ_m نه از طریق بهینه‌سازی گرادیانی مستقیم، بلکه بر اساس عملکرد وزن‌دار هر یادگیرنده تعیین می‌شوند.

استفاده از مدل می‌باشد. n تعداد کل مقادیر است. رابطه MAPE در زیر نشان داده شده است:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \bar{y}_i}{y_i} \right| \times 100 \quad (12)$$

MAPE نشان می‌دهد که پیش‌بینی مدل به‌طور میانگین چند درصد از مقدار واقعی انحراف دارد. مثلاً اگر $MAPE = 8\%$ باشد، یعنی مدل به‌طور میانگین ۸ درصد از مقادیر واقعی خطا دارد. جذر میانگین مربعات خطا (RMSE) معیاری است که اغلب برای اندازه‌گیری اختلاف بین مقادیر پیش‌بینی شده توسط یک مدل و مقادیر مشاهده شده واقعی استفاده می‌شود و با معادله زیر محاسبه می‌شود:

$$RMSE = \sqrt{\frac{\sum (y_i - \bar{y}_i)^2}{n}} \quad (13)$$

ضریب تعیین (R^2) عددی است که نشان دهنده نسبت واریانس متغیر وابسته است که از متغیر مستقل قابل پیش‌بینی است و به صورت زیر محاسبه می‌شود.

$$R^2 = 1 - \left[\frac{\sum_j (y_i - \bar{y}_i)^2}{\sum_i (\bar{y}_i)^2} \right] \quad (14)$$

هر چقدر R^2 به عدد یک نزدیکتر باشد، رابطه مورد نظر دارای دقت بیشتری می‌باشد.

میانگین خطای مطلق یا MAE یک معیار معروف برای مسائل رگرسیون است که در آن واحدهای خطا با واحدهای متغیر هدف مطابق هستند. رابطه MAE به صورت زیر است.

$$MAPE = \frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}_i| \quad (15)$$

۵- نتایج

با توجه به نتایج آزمایشگاهی، ابتدا به بررسی مقدار همبستگی بین پارامترهای مختلف با مقاومت فشاری بتن پرداخته شده است. در تصویر ۳ ماتریس همبستگی بین متغیرهای مختلف، با استفاده از رنگها و اعداد به صورت نقشه حرارتی (Heat map) رسم شده است. در این نمودار مقادیر نزدیک به ۱+ یا ۱- نشان دهنده همبستگی قوی مثبت یا منفی هستند. این نمودار به شناسایی متغیرهای کلیدی تأثیرگذار بر مقاومت فشاری بتن کمک می‌کند. از تصویر ۳ می‌توان دریافت که برخی از اجزا همبستگی مثبت و برخی دیگر همبستگی منفی دارند. وزن سیمان در مخلوط بتن بیشترین تأثیر را بر مقدار CCS دارد و همبستگی آن مثبت است، یعنی افزایش وزن سیمان باعث افزایش مقدار CCS و برعکس می‌شود. دو همبستگی مثبت قوی دیگر مربوط به وزن فوق روان‌کننده و سن بتن است. وزن آب همبستگی منفی قوی با مقدار CCS دارد، یعنی افزایش مقدار آب باعث کاهش مقدار CCS می‌شود. با توجه به این که مقدار سیمان بیشترین همبستگی با CCS دارد، در تصویر ۴، نمودار مقدار سیمان در برابر رسم شده است.

فرآیند تقویت با تخصیص وزن‌های اولیه یکنواخت به نمونه‌های آموزشی آغاز می‌شود:

$$\omega_i^{(1)} = \frac{1}{N} \quad i = 1, \dots, N \quad (8)$$

در تکرار m ، یک یادگیرنده ضعیف $h_m(x)$ با در نظر گرفتن وزن‌های فعلی نمونه‌ها $\omega_i^{(m)}$ آموزش داده می‌شود. سپس خطای وزن‌دار مدل نسبت به تابع خطای انتخاب شده $L(\cdot)$ محاسبه می‌گردد:

$$\varepsilon_m = \sum_{i=1}^N \omega_i^{(m)} L(y_i, h_m(x_i)) \quad (9)$$

در این مطالعه، تابع خطا از نوع رگرسیونی (مانند خطای مربعی یا قدرمطلق) در نظر گرفته شده است. بر اساس مقدار خطای ε_m ، ضریب بهینه γ_m محاسبه می‌شود، به‌گونه‌ای که یادگیرنده‌هایی با خطای کمتر، سهم بیشتری در مدل نهایی داشته باشند.

پس از تعیین γ_m ، وزن نمونه‌ها برای تکرار بعدی به صورت تطبیقی به‌روزرسانی می‌شود:

$$\omega_i^{m+1} = \omega_i^{(m)} \exp(\gamma_m L(y_i, h_m(x_i))) \quad (10)$$

سپس وزن‌ها نرمال‌سازی می‌شوند تا مجموع آن‌ها برابر با یک باقی بماند. این مکانیسم باعث می‌شود نمونه‌هایی که خطای بیشتری دارند، در تکرارهای بعدی وزن بالاتری دریافت کرده و نقش پررنگ‌تری در آموزش یادگیرنده‌های بعدی ایفا کنند. در نهایت، مدل تجمعی با افزودن یادگیرنده جدید به‌روزرسانی می‌شود:

$$F_m(x) = \gamma_m h_m(x) + F_{m-1}(x) \quad (11)$$

این روند تکراری تا رسیدن به تعداد مراحل تقویت M یا دستیابی به همگرایی ادامه می‌یابد. در نتیجه، مدل نهایی حاصل ترکیب وزن‌دار مجموعه‌ای از یادگیرنده‌های ضعیف است که به صورت تطبیقی بر خطاهای مراحل پیشین متمرکز شده‌اند.

پارامترهای کلیدی رگرسیون تقویتی آدا شامل تعداد مراحل تقویت M ، نرخ یادگیری (learning rate) و عمق حداکثر درخت‌های پایه است. این پارامترها با استفاده از جستجوی شبکه‌ای (Grid Search) و اعتبارسنجی متقاطع بهینه‌سازی شدند تا تعادل مناسبی میان دقت پیش‌بینی، پایداری مدل و قابلیت تعمیم آن برقرار گردد.

۴- معیار عملکرد مدلسازی

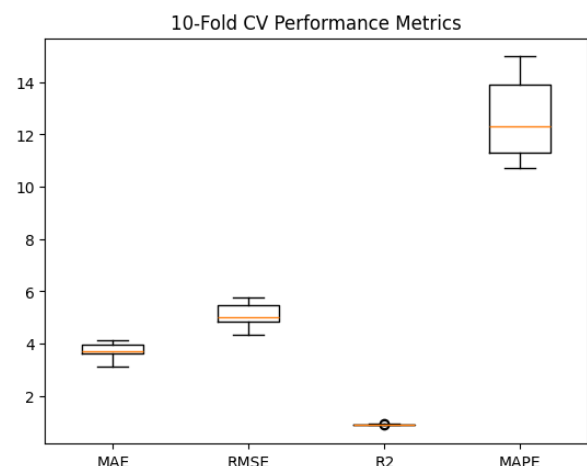
به منظور سنجش عملکرد مدلسازی از پارامترهای R^2 ، MAPE، RMSE و MAE استفاده می‌گردد.

MAPE (درصد میانگین خطای مطلق) یکی از متداول‌ترین معیارها برای سنجش میزان خطا در مدل‌های پیش‌بینی و رگرسیون است. این رابطه اندازه خطا را بر حسب درصد اندازه‌گیری می‌کند. این شاخص به صورت میانگین درصد خطای بدون علامت محاسبه می‌شود. در روابط زیر y ، مقدار مقاومت فشاری نمونه از آزمایش و \bar{y} مقدار مقاومت فشاری پیش‌بینی شده با

جدول ۲ مقدار خطای مدل ها

Table 2 Error values of the models

| | MAE | RMSE | R2 | MAPE |
|------------------------------|--------|--------|--------|---------|
| Gradient Boosting Regression | 3.7203 | 5.0705 | 0.9044 | 12.5512 |
| Ada Boost Regression | 6.2501 | 7.5735 | 0.7870 | 25.8781 |



شکل ۴ توزیع معیارهای عملکرد رگرسیون که با استفاده از اعتبارسنجی متقابل ده‌گانه

Fig. 5 Distribution of regression performance metrics obtained using 10-fold cross-validation

واریانس توضیح داده شده توسط مدل را کمی می‌کند. MAPE خطای پیش‌بینی را به صورت درصد بیان می‌کند و امکان مقایسه مستقل از مقیاس را فراهم می‌کند و MAE میانگین خطای مطلق را نشان می‌دهد.


مقدار میانگین حاصل برای هر کدام از معیارهای ارزیابی با توجه به روش اعتبارسنجی متقابل ده‌گانه در جدول ۲ نشان داده شده است. نتایج جدول نشان می‌دهد که در تمامی معیارها، خطای روش رگرسیون گرادیان تقویتی از روش رگرسیون تقویتی آدا کمتر بوده و دارای دقت بیشتری در تخمین پاسخ می‌باشد.

با توجه به دقت بیشتر روش رگرسیون گرادیان تقویتی، توزیع معیارهای عملکرد رگرسیون که با استفاده از اعتبارسنجی متقابل ده‌گانه به دست آمده‌اند در تصویر ۵ برای این روش رسم شده است. تصویر ۵ نمودارهای جعبه‌ای، MAE، RMSE، R² و MAPE را در تمام لایه‌ها خلاصه می‌کنند و هم‌گرایش مرکزی و هم‌تغییرپذیری در عملکرد مدل را نشان می‌دهند.

در نهایت مقادیر پیش‌بینی در برابر تست برای نمونه‌ها با استفاده از روش رگرسیون گرادیان تقویتی در تصویر ۶ رسم گردیده است.



شکل ۳ نقشه حرارتی نتایج همبستگی بین متغیرهای مختلف
Fig. 3 Heat map of correlation results between different variables



شکل ۴ مقاومت فشاری بتن در برابر مقدار سیمان مصرفی
Fig. 4 Plot of the Cement versus CCS. Values of Cement have the most correlation with the CCS

برای ارزیابی توانایی مدل در پیش‌بینی CCS، از استراتژی اعتبارسنجی متقابل ده‌گانه استفاده شد. اعتبارسنجی متقابل ده‌گانه روشی محبوب در مسائل تشخیص الگو برای جلوگیری از سوگیری نمونه‌گیری تصادفی در مقایسه با سایر اعتبارسنجی‌های متقابل است. در این روش داده‌ها به صورت تصادفی به ده زیرمجموعه تقسیم شدند و در هر زیرمجموعه، نه زیرمجموعه برای آموزش و زیرمجموعه دیگر به عنوان آزمایش استفاده شد. در پایان اعتبارسنجی متقابل ده‌گانه، هر زیرمجموعه فقط یک بار به عنوان زیرمجموعه آزمایش استفاده شده است. در هر زیرمجموعه، خطای MAE، RMSE، R² و MAPE پیش‌بینی محاسبه شد و در نهایت میانگین در ده زیرمجموعه به عنوان معیار نهایی عملکرد گزارش شد. از آنجا که تعداد نمونه‌های موجود در مجموعه داده‌ها ۱۰۳۰ بود، در هر زیرمجموعه، ۹۲۷ نمونه به عنوان آموزش و ۱۰۳ نمونه دیگر به عنوان آزمایش استفاده شدند. RMSE خطاهای بزرگتر را بیشتر جریمه می‌کند و بینشی در مورد واریانس ارائه می‌دهد، در حالی که R² نسبت

بیشترین تأثیر منفی را بر مقاومت فشاری بتن دارند که با مبانی فیزیکی و تجربی رفتار بتن همخوانی دارد. دو مدل پیشنهادی با استفاده از اعتبارسنجی متقابل ده‌گانه آموزش و ارزیابی شدند و عملکرد آن‌ها با شاخص‌های آماری مختلف سنجیده گردید. مقادیر به‌دست‌آمده برای معیارهای MAE، RMSE، MAPE و ضریب تعیین R^2 نشان‌دهنده دقت مناسب، پایداری و توانایی بالاتر مدل رگرسیون گرادیان تقویتی در پیش‌بینی مقاومت فشاری بتن توانمند است. به‌ویژه مقدار پایین خطای میانگین مطلق، قابلیت اعتماد این مدل را در کاربردهای عملی تأیید می‌کند.

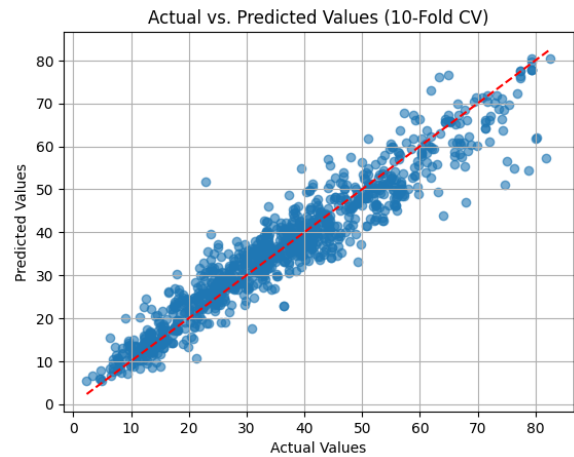
بر اساس نتایج این تحقیق، می‌توان نتیجه گرفت که دو مدل رگرسیون گرادیان تقویتی و رگرسیون تقویتی آدا ابزارهای کارآمدی برای مدلسازی روابط غیرخطی پیچیده میان اجزای طرح اختلاط بتن و مقاومت فشاری آن هستند و می‌توانند به‌عنوان جایگزینی سریع، کم‌هزینه و دقیق برای آزمایش‌های آزمایشگاهی متداول مورد استفاده قرار گیرند. استفاده از این رویکرد می‌تواند نقش مؤثری در بهینه‌سازی طرح اختلاط، کاهش هزینه‌ها و زمان طراحی و ارتقای کیفیت بتن‌های پیشرفته در پروژه‌های عمرانی ایفا کند.

تأییدیه اخلاقی: محتویات علمی این مقاله حاصل پژوهش نویسندگان است و در هیچ نشریه ایرانی و غیرایرانی منتشر نشده است.

تعارض منافع: تعارض منافی برای اظهار وجود ندارد.

منابع

- [1] P. K. Mehta and P. J. M. Monteiro, *Concrete: Microstructure, Properties, and Materials*, 3rd ed. New York, NY, USA: McGraw-Hill, 2006.
- [2] A. Khazaee and A. Khazaee, "Compressive strength prediction of high performance concrete using artificial bee colony algorithm," *Romanian Journal of Materials (Revista Română de Materiale)*, vol. 47, no. 3, pp. 331–338, 2017.
- [3] J. S. Chou and A. D. Pham, "Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength," *Construction and Building Materials*, vol. 74, pp. 87–96, 2015, doi: 10.1016/j.conbuildmat.2013.08.078.
- [4] M. Imran, A. Raza, and M. Touqeer, "Prediction of compressive strength of high-performance concrete (HPC) using machine learning algorithms," *Multiscale and Multidisciplinary Modeling, Experiments and Design*, vol. 7, no. 3, pp. 1881–1894, 2024, doi: 10.1007/s41939-023-00310-5.
- [5] I.-C. Yeh, "Modeling of strength of high-performance concrete using artificial neural networks," *Cement and Concrete Research*, vol. 28, no. 12, pp. 1797–1808, 1998, doi: 10.1016/S0008-8846(98)00165-3.



شکل ۵ مقادیر تجربی در برابر مقادیر پیش‌بینی شده
Fig. 6 Actual values versus predicted values

بررسی نتایج به‌دست‌آمده نشان می‌دهد که مدل رگرسیون گرادیان تقویتی از دقت مناسبی در پیش‌بینی مقاومت فشاری بتن توانمند برخوردار است، به‌طوری‌که مقدار ضریب تعیین بالا بیانگر توانایی مدل در توضیح بخش قابل توجهی از تغییرات داده‌ها می‌باشد. مقدار نسبتاً پایین خطاهای MAE و RMSE نیز نشان‌دهنده نزدیکی پیش‌بینی‌های مدل به مقادیر واقعی است. علاوه بر این، مقدار MAPE بیانگر آن است که خطای نسبی مدل در محدوده قابل قبول مهندسی قرار دارد.

تحلیل نمودار مقادیر واقعی در برابر مقادیر پیش‌بینی‌شده نشان می‌دهد که اکثر نقاط در نزدیکی خط ایده‌آل قرار دارند که بیانگر عملکرد پایدار مدل در کل دامنه داده‌ها است. با این حال، در برخی بازه‌ها، به‌ویژه در مقادیر بالای مقاومت فشاری، میزان پراکندگی افزایش یافته است که می‌تواند ناشی از پیچیدگی بیشتر رفتار غیرخطی بتن در این ناحیه باشد. همچنین، نتایج تحلیل اهمیت ویژگی‌ها نشان داد که پارامترهایی نظیر مقدار سیمان، سن بتن و فوق‌روان‌کننده بیشترین تأثیر را در پیش‌بینی مقاومت فشاری دارند، که این یافته با مبانی فیزیکی و مطالعات پیشین همخوانی دارد. این موضوع بیانگر توانایی مدل در استخراج روابط معنادار بین متغیرهای ورودی و خروجی است.

۵- نتیجه‌گیری

در این پژوهش، به‌منظور پیش‌بینی مقاومت فشاری بتن توانمند، از دو مدل رگرسیون گرادیان تقویتی و رگرسیون تقویتی آدا به‌عنوان روش‌های پیشرفته یادگیری ماشین استفاده شد. برای این منظور، مجموعه‌ای شامل ۱۰۳۰ نمونه آزمایشگاهی بتن توانمند با پارامترهای متنوع طرح اختلاط و سن نمونه مورد تحلیل قرار گرفت. نتایج تحلیل همبستگی نشان داد که مقدار سیمان، سن بتن و میزان فوق‌روان‌کننده بیشترین تأثیر مثبت و مقدار آب

(<https://archive.ics.uci.edu/dataset/165/concrete+compressive+strength>)

[6] I.-C. Yeh, "Modeling slump flow of concrete using second-order regressions and artificial neural networks," *Cement and Concrete Composites*, vol. 29, no. 6, pp. 474–480, 2007, doi: [10.1016/j.cemconcomp.2007.02.001](https://doi.org/10.1016/j.cemconcomp.2007.02.001).

[7] S. Chithra, S. R. R. S. Kumar, and K. Chinnaraju, "A comparative study on the compressive strength prediction models for high performance concrete containing nano silica and copper slag using regression analysis and artificial neural networks," *Construction and Building Materials*, vol. 114, pp. 528–535, 2016, doi: [10.1016/j.conbuildmat.2016.03.214](https://doi.org/10.1016/j.conbuildmat.2016.03.214).

[8] M. Sonebi, E. Lachemi, K. M. A. Hossain, and M. A. B. El-Maaddawy, "Modelling the fresh properties of self-compacting concrete using support vector machine approach," *Construction and Building Materials*, vol. 106, pp. 55–64, 2016, doi: [10.1016/j.conbuildmat.2015.12.035](https://doi.org/10.1016/j.conbuildmat.2015.12.035).

[9] H. Amjad, M. M. H. Khattak, and R. A. Khushnood, "A simplified machine learning empirical model for biomimetic crack healing of bioinspired concrete," *Materials Today Communications*, vol. 37, Art. no. 107063, 2023, doi: [10.1016/j.mtcomm.2023.107063](https://doi.org/10.1016/j.mtcomm.2023.107063).

[10] B. A. Omran, Q. Chen, and R. Jin, "Comparison of data mining techniques for predicting compressive strength of environmentally friendly concrete," *Journal of Computing in Civil Engineering*, vol. 30, no. 6, Art. no. 04016029, 2016, doi: [10.1061/\(ASCE\)CP.1943-5487.0000596](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000596).

[11] A. Behnood, V. Behnood, M. Modiri Gharehveran, and K. E. Alyamac, "Prediction of the compressive strength of normal and high-performance concretes using M5P model tree algorithm," *Construction and Building Materials*, vol. 142, pp. 199–207, 2017, doi: [10.1016/j.conbuildmat.2017.03.061](https://doi.org/10.1016/j.conbuildmat.2017.03.061).

[12] M. Imran, R. A. Khushnood, and M. Fawad, "A hybrid data-driven and metaheuristic optimization approach for the compressive strength prediction of high-performance concrete," *Case Studies in Construction Materials*, vol. 18, Art. no. e01890, 2023, doi: [10.1016/j.cscm.2023.e01890](https://doi.org/10.1016/j.cscm.2023.e01890).

[13] S. A. Moghaddas and Y. Bao, "Explainable machine learning framework for predicting concrete abrasion depth," *Case Studies in Construction Materials*, vol. 22, p. e04686, 2025. doi: [10.1016/j.cscm.2025.e04686](https://doi.org/10.1016/j.cscm.2025.e04686).

[14] D. Sinkhonde, T. Bezabih, D. Mirindi, D. Mashava, and F. Mirindi, "Ensemble machine learning algorithms for efficient prediction of compressive strength of concrete containing tyre rubber and brick powder," *Cleaner Waste Systems*, vol. 10, p. 100236, 2025, doi: [10.1016/j.clwas.2025.100236](https://doi.org/10.1016/j.clwas.2025.100236).

[15] T. Roy, P. Das, R. Jagirdar, M. Shhabat, M. S. Abdullah, A. Kashem, and R. Rahman, "Prediction of mechanical properties of eco-friendly concrete using machine learning algorithms and partial dependence plot analysis," *Smart Construction and Sustainable Cities*, vol. 3, no. 1, p. 2, 2025, doi: [10.1007/s44268-025-00048-8](https://doi.org/10.1007/s44268-025-00048-8).