

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

### ماشین

محمد پردل<sup>1</sup> و امیر امین زاده قوی فکر<sup>2\*</sup>

<sup>1</sup> کارشناسی ارشد مهندسی عمران-گرایش مهندسی و مدیریت ساخت، دانشگاه بوعلی سینا - همدان، ایران  
<sup>2</sup> استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز - تبریز، ایران

(دریافت: 00/00/00، پذیرش: 00/00/00، نشر آنلاین: 00/00/00)

### چکیده

بتن به عنوان یکی از مصالح اصلی در صنعت ساخت، نقش حیاتی در پایداری، ایمنی و رفاه فضاهای شهری ایفا می‌کند. کیفیت بتن رابطه مستقیمی با تحمل بارهای ثقیلی و جانبی دارد و می‌تواند از تخریب زود هنگام ساختمان‌ها جلوگیری کرده و علاوه بر کاهش حجم ضایعات ساختمانی، یک محیط شهری پایدار ایجاد نماید. با این حال، عوامل متعددی بر مقاومت فشاری بتن تاثیر گذارند که عدم شناسایی این عوامل می‌تواند منجر به تخریب زودرس ساختمان‌ها و همچنین پیامدهای ناگوار در بلایای طبیعی شود. درک صحیح از این عوامل برای ارتقای کیفیت بتن و تضمین عملکرد مطلوب سازه‌ها ضروری است. هدف این مقاله، تحلیل عوامل موثر 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 الگوریتم‌های فراابتکاری برای ایجاد یک مدل پیش‌بینی دقیق استفاده شده است. نتایج این پژوهش نشان می‌دهد که عوامل متعددی از جمله نسبت آب به سیمان، نوع و کیفیت سنگدانه، افزودنی‌های بتن، شرایط عمل‌آوری و شرایط محیطی، بر مقاومت بتن تاثیر گذار هستند. همچنین، در این پژوهش مدل یادگیری ماشین قادر به شناسایی الگوهای پیچیده در بین عوامل شناسایی شده و پیش‌بینی دقیق مقاومت فشاری بتن با دقت 95/66 درصد است. نتایج این مطالعه می‌تواند به ارتقای کیفیت ساخت، افزایش طول عمر مفید سازه‌ها، کاهش هزینه‌های نگهداری و تعمیرات و ایجاد فضاهای شهری پایدار و ایمن منجر شود.

**کلیدواژه‌ها:** مدیریت شهری، الگوریتم یادگیری ماشین، الگوریتم فراابتکاری، مقاومت فشاری بتن، محیط زیست، ضایعات ساختمانی

### 1- مقدمه

برای بهبود طراحی سازه‌های بتنی الزامی به نظر می‌رسد (Moein و همکاران، 2023). در بین ویژگی‌های مختلف بتن، مقاومت فشاری به عنوان شاخص اصلی برای ارزیابی عملکرد در نظر گرفته می‌شود 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 سازه‌های بتنی، اتلاف منابع طبیعی و مصالح را به دنبال دارد و بر بار زیست‌محیطی آن‌ها می‌افزاید. مقاومت فشاری بتن با تأثیر بر دوام، ایمنی و طول عمر ساختمان‌ها و زیرساخت‌ها به طور 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 به شمار می‌رود. به عبارت بهتر یکی از مهم‌ترین پارامترهایی که کیفیت و پایداری سازه‌های

بتن به عنوان یکی از پرمصرف‌ترین مصالح ساختمانی در سراسر جهان، نقش حیاتی در ایجاد زیرساخت‌ها و ساخت و ساز شهری ایفا می‌کند و انتظار می‌رود تقاضا برای بتن تا سال 2050 به 18 میلیارد تن برسد (Feng و همکاران، 2020). با این حال، بتن در طول زمان می‌تواند تحت تاثیر عوامل مختلفی مانند خوردگی، یخ زدگی و بارگذاری فرسوده شود و منجر به خرابی زودرس سازه‌ها شود. این خرابی‌ها نه تنها هزینه‌های هنگفتی را به دنبال دارند، بلکه می‌توانند تهدیدی جدی برای ایمنی و رفاه ساکنان شهری باشند. در سال‌های اخیر، توجه زیادی به توسعه مصالح و روش‌های ساخت پایدار و بادوام معطوف شده است. در این میان، بتن به عنوان یک ماده با پتانسیل بالا برای ارتقای پایداری و کارایی در نظر گرفته می‌شود. با این حال، با رشد جمعیت و توسعه شهرها، داشتن ارزیابی دقیق خواص مکانیکی

\* نویسنده مسئول؛ شماره تماس: 09144038773

می‌شود (Quah و همکاران، 2023). در نتیجه، انقلاب صنعتی چهارم علاوه بر این که استانداردهای کیفیت ساخت و ساز را بالا می‌برد، راه را برای زیرساخت‌های هوشمند و انعطاف پذیر 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 به عنوان 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 (Barai و Dutta، 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 پیش‌بینی کردند. آنان در مطالعه خود از سه هسته مختلف (خطی، چند جمله‌ای و گاوسی)، فرآپارامترهای 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

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 ترک خوردن یا فرو ریختن، 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 موثر بر کیفیت و مقاومت بتن اهمیت بسیاری دارد.

بتن سیستم پیچیده‌ای از ترکیب اجزای مختلف (سنگدانه‌ها، آب، سیمان و مواد افزودنی) است که به طور 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. به عبارت 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.

از طرفی، 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 به ویژه در بخش بتن مشهود است (Chatterjee، 2021). زیرا روش‌هایی مانند یادگیری ماشین با استفاده از تجزیه و تحلیل عوامل تاثیرگذار و پیش‌بینی‌کننده و همچنین با استفاده از الگوریتم‌های هوشمند، نیازهای تعمیر و نگهداری و آسیب‌های احتمالی را پیش‌بینی می‌کنند. مدل‌های یادگیری ماشین با استفاده از داده‌ی حسگرهای تعبیه‌شده در سازه‌های بتنی و تجزیه و تحلیل عوامل موثر در تغییر شکل و نقاط شکست احتمالی را پیش‌بینی می‌کنند (Prasad و Dinesh، 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

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 نوآورانه‌ی 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 مساله در راستای فهم درست عوامل مؤثر بر استحکام بتن است که به افزایش کارایی در ساختمان‌های در حال ساخت، کمک شایانی می‌کند.

بخش‌های دیگر مقاله به صورت زیر مرتب شده است: تعریف مسئله در بخش 3 ذکر شده است، بخش 4 الگوریتم‌های PSO و XGBoost را معرفی می‌کند، بخش 5 شامل نتایج عددی و بحث است، و نتیجه گیری در بخش 6 به تفصیل بیان شده است.

### 3- تعریف مساله

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 تأثیر گذار است. از طرفی، نتایج مطالعات اثبات کرده است که مواردی مانند نسبت آب به سیمان، اندازه سنگدانه، شرایط عمل آوری و کیفیت مصالح به طور قابل توجهی بر مقاومت فشاری بتن تأثیر گذار است (Khademi و همکاران، 2017). درک و بهینه‌سازی این عوامل برای تولید بتن باکیفیت ضروری است. اخیراً، یادگیری ماشین به عنوان 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 (Prasad و Dinesh، 2024). 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

سنگدانه را به صورت 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 که حاوی ضایعات ساختمانی (جایگزین درشت دانه) 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 به عنوان 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  $R_2$ ، RMSE و MAPE به دست آمده برای هر دو مدل نشان‌دهنده عملکرد بهتر ANN بود.

دسته‌ی 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 به عنوان الگوریتم‌های قابل اعتماد برای پیش‌بینی مدول الاستیک گزارش کردند. آن‌ها 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  $R_2$  قابلیت مدل را تأیید می‌کند.

مجموعه ای از اصول اساسی است که عملیات آن را هدایت می کند (Jain و همکاران، 2022).

در حوزه بهینه سازی یک مسئله، بهینه سازی ازدحام ذرات با قرار دادن تصادفی جمعیتی از ذرات در فضای راه حل آغاز می شود (Du و همکاران، 2019). مکان هر ذره در این فضا نشان دهنده 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 بهره برداری است. این استراتژی مشارکتی بهینه سازی ازدحام ذرات را قادر می سازد تا به طور کارآمد فضای جستجو را به صورت غیرمتمرکز کاوش و بهره برداری 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،  $\vec{V}_{ij}(h)$  نشان دهنده سرعت ذره  $i$  در طول تکرار  $h$  است، در حالی که  $\vec{y}_{ij}(h)$  نشان دهنده مکان ذره  $i$  در همان تکرار است. عبارات  $e_1$  و  $e_2$  اعداد تصادفی در محدوده  $(0,1)$  هستند و  $\varphi_1$  و  $\varphi_2$  ثابت هستند. علاوه بر این،  $\vec{z}_{ij}(h)$  بهترین مکان یک ذره را نشان می دهد و  $\vec{z}_{gi}(h)$  نشان دهنده بهترین مکان کل ازدحام ذرات است.  $W$  نیز یک مقدار ثابت است. محاسبه مکان جدید یک ذره با رابطه (2) تعیین می شود.

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

در این مقاله، بهینه سازی ازدحام ذرات برای بهینه سازی فرآپارامترهای مدل یادگیری ماشین، با هدف افزایش دقت در

عملکرد کار استفاده می شود. نمودار جریان بهینه سازی ازدحام ذرات در شکل 1 نشان داده شده است.

را شناسایی و پیش بینی کند. ویژگی هایی که در این پژوهش مورد استفاده قرار خواهد گرفت در جدول 1 ذکر شده است (Yeh، 2006).

سنگ دانه جز مصالح اصلی تشکیل دهنده بتن است که پس از مخلوط شدن آب و سیمان با نسبت های مناسب پیوند می یابد. بنابراین کیفیت سنگدانه بر مقاومت بتن تأثیر می گذارد. به طور کلی سنگدانه ها در دو دسته درشت دانه و ریز دانه تقسیم می شوند و حدود 80 درصد حجم بتن را تشکیل می دهند. فوق روان کننده ها نیز نیاز به آب را بدون اینکه بر کارایی تأثیر بگذارند بین 15 تا 20 درصد کاهش می دهند که منجر به افزایش مقاومت فشاری بتن می شود. نسبت آب به سیمان یکی از مهم ترین عوامل موثر بر مقاومت بتن است که رابطه مستقیمی با مقاومت فشاری بتن دارد و در طرح های مختلف میزان آن متفاوت است (Prasad، 2024).

#### 4- روش پژوهش

در این بخش، الگوریتم فراابتکاری که برای تنظیم فرآپارامترهای مدل یادگیری ماشین استفاده می شود، الگوریتم یادگیری ماشین و معیارهای ارزیابی معرفی می شوند.

#### 4-1- الگوریتم فراابتکاری

بهینه سازی ازدحام ذرات (PSO) یک الگوریتم بهینه سازی است که به عنوان یک روش فراابتکاری طبقه بندی می شود که از رفتار جمعی مشاهده شده در پرندگان و ماهی ها الهام می گیرد (Amani و Sarkodie، 2022). بهینه سازی ازدحام ذرات که به دلیل اثربخشی و سازگاری در پرداختن به مسائل بهینه سازی

شهرت دارد، یک سیستم اجتماعی را شبیه سازی می کند که در آن افراد که به عنوان ذرات به تصویر کشیده می شوند، با هم کار می کنند تا بهترین راه حل را در یک فضای جستجوی معین کشف کنند. قدرت حل مسئله بهینه سازی ازدحام ذرات بر اساس

جدول 1- ویژگی های مورد استفاده در مدل یادگیری ماشین

نام ویژگی	واحد اندازه گیری	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 روان کننده	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

## 2-4- یادگیری ماشین

همکاران، 2018). تابع هدف برای الگوریتم تقویت گرادیان شدید را می‌توان به صورت زیر بیان کرد:

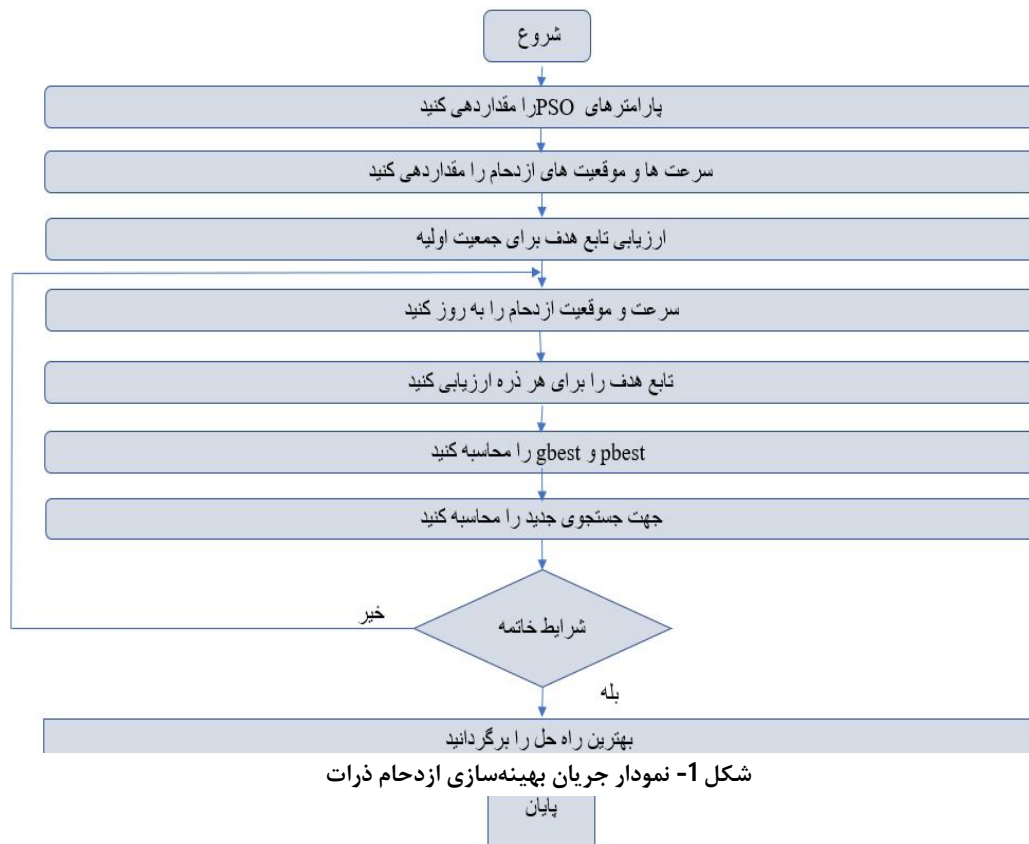
$$Objective(\theta) = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (3)$$

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،  $\Omega(f_k)$  عبارت تنظیم‌کننده برای درخت  $k$ -امین است، و  $\theta$  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.

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

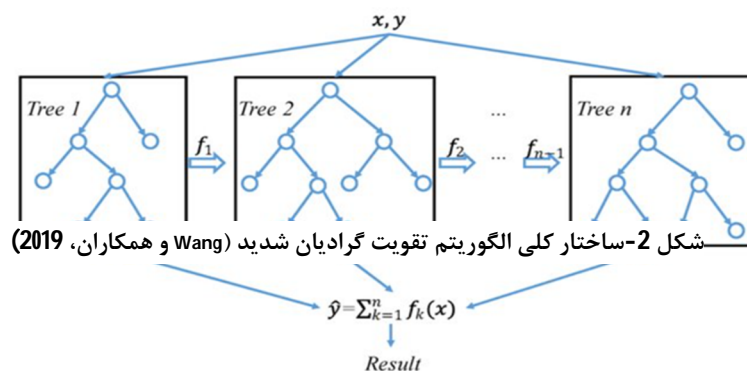
الگوریتم تقویت گرادیان شدید (XGBoost) یک الگوریتم یادگیری ماشین محبوب و قدرتمند است که در دسته یادگیری گروهی قرار می‌گیرد (Wang و Kiangala، 2021). به طور خاص، این یک الگوریتم تقویتی است که پیش‌بینی‌های چند یادگیرنده ضعیف، معمولاً درخت‌های تصمیم‌گیری را برای ایجاد یک مدل پیش‌بینی قوی ترکیب می‌کند (Asselman 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 به دست 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،



شکل 1- نمودار جریان بهینه‌سازی ازدحام ذرات

و یک عبارت منظم‌سازی، که از پیچیده شدن مدل و بیش از حد برازش داده‌های آموزشی جلوگیری می‌کند (Dhaliwal و



### 4-3- معیارهای ارزیابی

خاکستر بادی و فوق

روان کننده: این‌ها همبستگی 0/38 دارند، یک همبستگی مثبت متوسط، که به این معنی است که مقدار خاکستر بادی و فوق روان کننده 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 روان کننده‌ها استفاده می‌شود.

سنگدانه ریز و آب: این جفت دارای همبستگی 0/45- است که نشان دهنده 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 نشان دهنده 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 معنی داری وجود ندارد.

### 5-2- 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

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 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 روان کننده: همبستگی منفی قوی 0/66- وجود دارد. این نتیجه نشان می‌دهد که هر چه فوق روان کننده بیشتر استفاده شود، آب کمتری مورد نیاز است. فوق روان کننده‌ها برای افزایش کارایی بتن استفاده می‌شوند و امکان کاهش محتوای آب را بدون کاهش کارایی بتن فراهم می‌کنند.

مقاومت فشاری بتن در شکل 5 قابل مشاهده است. 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.

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




شکل 3- تجزیه و تحلیل همبستگی متغیرها

جدول 2- مقایسه‌ی مدل‌های ساخته شده با الگوریتم‌های یادگیری ماشین

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



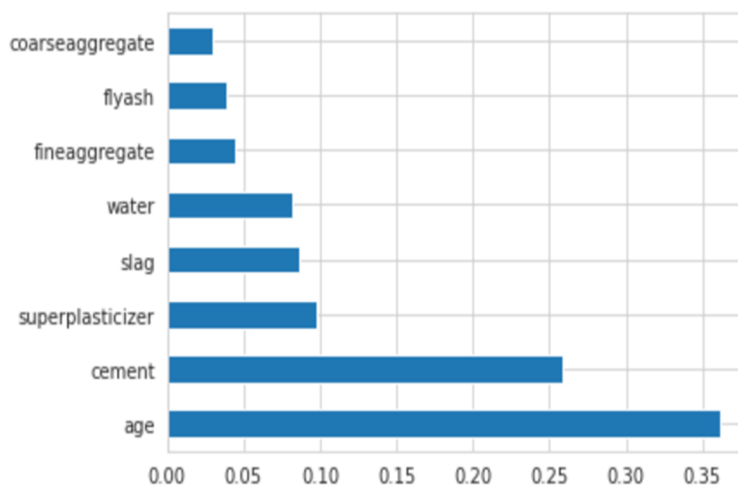




شکل 4- مقایسه دقت مدل‌های یادگیری ماشین

جدول 3- پارامترهای مهم الگوریتم‌های PSO و XGBoost

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



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

به تصمیمات آگاهانه، به موقع و استراتژیک در مدیریت ساخت و ساز می‌شود.

#### 6- نتیجه‌گیری

مقاومت فشاری بتن با تعیین دوام، ایمنی و طول عمر ساختمان‌ها و زیرساخت‌ها بر فضاهای شهری و زندگی اجتماعی

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

- ASTERIS, P. G., SKENTOU, A. D., BARDHAN, A., SAMUI, P. & PILAKOUTAS, K. 2021. Predicting concrete compressive strength using hybrid ensembling of surrogate machine learning models. *Cement and Concrete Research*, 145, 106449.
- BADUGE, S. K., THILAKARATHNA, S., PERERA, J. S., ARASHPOUR, M., SHARAFI, P., TEODOSIO, B., SHRINGI, A. & MENDIS, P. 2022. Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications. *Automation in Construction*, 141, 104440.
- BEHNOOD, A., VERIAN, K. P. & GHAREHVERAN, M. M. 2015. Evaluation of the splitting tensile strength in plain and steel fiber-reinforced concrete based on the compressive strength. *Construction and Building Materials*, 98, 519-529.
- CHATTERJEE, A. K. 2021. *Intelligent and Sustainable Cement Production: Transforming to Industry 4.0 Standards*, CRC Press.
- CHOPRA, P., SHARMA, R. K., KUMAR, M. & CHOPRA, T. 2018. Comparison of machine learning techniques for the prediction of compressive strength of concrete. *Advances in Civil Engineering*, 2018.
- DHALIWAL, S. S., NAHID, A.-A. & ABBAS, R. 2018. Effective intrusion detection system using XGBoost. *Information*, 9, 149.
- DINESH, A. & PRASAD, B. R. 2024. Predictive models in machine learning for strength and life cycle assessment of concrete structures. *Automation in Construction*, 162, 105412.
- DU, B., WEI, Q. & LIU, R. 2019. An improved quantum-behaved particle swarm optimization for endmember extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 57, 6003-6017.
- DUTTA, D. & BARAI, S. V. 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.
- FENG, D.-C., LIU, Z.-T., WANG, X.-D., CHEN, Y., CHANG, J.-Q., WEI, D.-F. & JIANG, Z.-M. 2020. Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach. *Construction and Building Materials*, 230, 117000.
- GAD, A. G. 2022. Particle swarm optimization algorithm and its applications: a systematic review. *Archives of computational methods in engineering*, 29, 2531-2561.
- GHOLAMPOUR, A., MANSOURI, I., KISI, O. & OZBAKKALOGLU, T. 2020. Evaluation of mechanical properties of concretes containing coarse recycled concrete aggregates using multivariate adaptive regression splines (MARS), M5 model tree (M5Tree), and least squares support vector regression (LSSVR) models. *Neural Computing and Applications*, 32, 295-308.
- GOLAFSHANI, E. M. & BEHNOOD, A. 2018. Automatic regression methods for formulation of elastic modulus of recycled aggregate concrete. *Applied Soft Computing*, 64, 377-400.
- GÜÇLÜER, K., ÖZBEYAZ, A., GÖYMEN, S. & GÜNAYDIN, O. 2021. A comparative investigation using machine learning models for predicting the compressive strength of concrete. *Journal of Building Engineering*, 31, 100300.
- تأثیر زیادی می‌گذارد. بنابراین، در این مطالعه از تکنیک‌های تحلیل داده‌ها برای بررسی ویژگی‌های موثر در مقاومت فشاری 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 انعطاف پذیر 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 موثر 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, D. J. 2016. Active vibration control of flexible cantilever plates using piezoelectric materials and artificial neural networks. *Journal of sound and Vibration*, 363, 33-53.
- ABDOLLAHZADEH, G., JAHANI, E. & KASHIR, Z. 2016. Predicting of compressive strength of recycled aggregate concrete by genetic programming. *Comput. Concrete*, 18, 155-163.
- AMANI, M. A. & NASIRI, M. M. 2023. A novel cross docking system for distributing the perishable products considering preemption: a machine learning approach. *Journal of Combinatorial Optimization*, 45, ۱۳۰.
- AMANI, M. A. & SARKODIE, S. A. 2022. Mitigating spread of contamination in meat supply chain management using deep learning. *Scientific reports*, 12, 5037.
- AMANI, M. A. & SARKODIE, S. A., SHUE, J. B., NASIRI, M. M. and R TAVAKKOLI-MOGHADDAM, R., 2023. A hybrid scenario-based robust model to design a relief logistics network: a data-driven approach.
- ASSELMAN, A., KHALDI, M. & AAMMOU, S. 2023. Enhancing the prediction of student performance based on the machine learning XGBoost algorithm. *Interactive Learning Environments*, 31, 3360-3379.

- MOURATIDIS, K. 2021. Urban planning and quality of life: A review of pathways linking the built environment to subjective well-being. *Cities*, 115, 103229.
- NADERPOUR, H., POURSAEIDI, O. & AHMADI, M. 2018. Shear resistance prediction of concrete beams reinforced by FRP bars using artificial neural networks. *Measurement*, 126, 299-308.
- OMRAN, B. A., CHEN, Q. & JIN, R. 2016. Comparison of data mining techniques for predicting compressive strength of environmentally friendly concrete. *Journal of Computing in Civil Engineering*, 30, 04016029.
- PRASAD 2024. Key Factors Affecting Strength of Concrete. *Structural Guide*.
- QUAH, T. K. N., TAY, Y. W. D., LIM, J. H., TAN, M. J., WONG, T. N. & LI, K. H. H. 2023. Concrete 3D printing: process parameters for process control, monitoring and diagnosis in automation and construction. *Mathematics*, 11, 1499.
- SALEHI, H. & BURGUEÑO, R. 2018. Emerging artificial intelligence methods in structural engineering. *Engineering structures*, 171, 170-189.
- SHI, H.-S., XU, B.-W. & ZHOU, X.-C. 2009. Influence of mineral admixtures on compressive strength, gas permeability and carbonation of high performance concrete. *Construction and Building Materials*, 23, 1980-1985.
- TAHMOURESI, B., NEMATI, P., ASADI, M. A., SARADAR, A. & MOEIN, M. M. 2021. Mechanical strength and microstructure of engineered cementitious composites: A new configuration for direct tensile strength, experimental and numerical analysis. *Construction and Building Materials*, 269, 121361.
- WANG, Z., JIN, W., DONG, Y. & FRANGOPOL, D. M. 2018. Hierarchical life-cycle design of reinforced concrete structures incorporating durability, economic efficiency and green objectives. *Engineering Structures*, 157, 119-131.
- YEH, I.-C. 2006. Analysis of strength of concrete using design of experiments and neural networks. *Journal of Materials in Civil Engineering*, 18, 597-604.
- ZHANG, W., ZHENG, Q., ASHOUR, A. & HAN, B. 2020. Self-healing cement concrete composites for resilient infrastructures: A review. *Composites Part B: Engineering*, 189, 107892.
- learning methods for concrete compressive strength estimation. *Materials Today Communications*, 27, 102278.
- HAN, Q., GUI, C., XU, J. & LACIDOGNA, G. 2019. A generalized method to predict the compressive strength of high-performance concrete by improved random forest algorithm. *Construction and Building Materials*, 226, 734-742.
- IQBAL, M. F., LIU, Q.-F., AZIM, I., ZHU, X., YANG, J., JAVED, M. F. & RAUF, M. 2020. Prediction of mechanical properties of green concrete incorporating waste foundry sand based on gene expression programming. *Journal of hazardous materials*, 384, 121322.
- JAIN, M., SAIHJPAL, V., SINGH, N. & SINGH, S. B. 2022. An overview of variants and advancements of PSO algorithm. *Applied Sciences*, 12, ۸۳۹۲.
- JALAL, M. & JALAL, H. 2020. RETRACTED: Behavior assessment, regression analysis and support vector machine (SVM) modeling of waste tire rubberized concrete. *Elsevier*.
- JIANG, X., MAHADEVAN, S. & ADELI, H. 2007. 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*, 14, 333-356.
- KHADEMI, F., AKBARI, M., JAMAL, S. M. & NIKOO, M. 2017. Multiple linear regression, artificial neural network, and fuzzy logic prediction of 28 days compressive strength of concrete. *Frontiers of Structural and Civil Engineering*, 11, 90-99.
- KHURSHID, K., DANISH, A., SALIM, M. U., BAYRAM, M., OZBAKKALOGLU, T. & MOSABERPANAH, M. A. 2023. An in-depth survey demystifying the Internet of Things (IoT) in the construction industry: Unfolding new dimensions. *Sustainability*, 15, 1275.
- KIANGALA, S. K. & WANG, Z. 2021. 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*, 4, 100024.
- LIU, Q., SUN, P., FU, X., ZHANG, J., YANG, H., GAO, H. & LI, Y. 2020. Comparative analysis of BP neural network and RBF neural network in seismic performance evaluation of pier columns. *Mechanical Systems and Signal Processing*, 141, 106707.
- MANGALATHU, S. & JEON, J.-S. 2018. Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using machine learning techniques. *Engineering Structures*, 160, 85-94.
- MOEIN, M. M., SARADAR, A., RAHMATI, K., MOUSAVINEJAD, S. H. G., BRISTOW, J., ARAMALI, V. & KARAKOUZIAN, M. 2023. Predictive models for concrete properties using machine learning and deep learning approaches: A review. *Journal of Building Engineering*, 63, 105444.