

پیش‌بینی مقاومت فشاری بتن حاوی خاکستر بادی با استفاده از مدل‌های یادگیری ماشین

الهه مؤذنی، یاسر مودی*

دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران

چکیده

خاکستر بادی در نتیجه فرایند احتراق ذغال‌سنگ در نیروگاه‌های حرارتی به عنوان یکی از محصولات جانبی به‌دست می‌آید. خاکستر بادی ذرات بسیار ریز و میکروسکوپی دارد که معمولاً از ترکیب مواد معدنی مانند سیلیسیم دی‌اکسید، آلومینیوم اکسید و آهن اکسید تشکیل شده است. این ترکیبات باعث می‌شوند که از خاکستر بادی در صنایع مختلف، به ویژه در صنعت بتن، استفاده شود. از کاربرد های خاکستر بادی میتوان به افزودنی به بتن، پرکننده در آسفالت، ساخت آجر و بلوک‌های بتنی و جذب آلاینده‌ها اشاره نمود. خاکستر بادی به عنوان یک ماده پوزولانی، به کاهش تولید کربن دی‌اکسید در فرآیند تولید سیمان کمک می‌کند. در این مطالعه ابتدا یک پایگاه داده‌ای جامع از مطالعات گذشته در خصوص بتن حاوی خاکستر بادی جمع‌آوری شد. این داده‌ها شامل ۵۹۹ نمونه از مطالعات آزمایشگاهی معتبر بود. مجموعه داده‌های جمع‌آوری شده شامل متغیرهای ورودی مختلفی از جمله نسبت آب به سیمان، مقدار خاکستر بادی، میزان سیمان، مقدار درشت‌دانه‌ها، مقدار ریزدانه‌ها، میزان روان‌کننده و سن عمل‌آوری بتن می‌باشد. برای پیش‌بینی مقاومت فشاری بتن‌ها، از الگوریتم‌های مختلف یادگیری ماشین از جمله برنامه‌ریزی ژنتیک (GP)^۱، سیستم استنتاج منطق فازی-عصبی (ANFIS)^۲، پرسپترون چندلایه (MLP)^۳، شبکه عصبی شعاعی پایه (RBF)^۴، کریجینگ (Kriging) و شبکه‌های عصبی تک‌لایه (ELM)^۵ استفاده شده است. همچنین، دقت هر مدل با استفاده از شاخص‌های آماری ارزیابی شده و بهترین مدل معرفی گردید. نتایج نشان می‌دهد که مدل‌های مختلف یادگیری ماشین عملکردهای متفاوتی در پیش‌بینی مقاومت فشاری دارند. به ویژه روش کریجینگ (Kriging) با ضریب همبستگی ۰/۹۶ به عنوان بهترین مدل انتخاب گردید.

کلمات کلیدی

بتن، خاکستر بادی، مقاومت فشاری، مدل پیش‌بینی، تکنیک‌های یادگیری ماشین.

¹ Genetic Programming (GP)

² Adaptive Neuro-Fuzzy Inference System (ANFIS)

³ Multilayer Perceptron (MLP)

⁴ Radial Basis Function Networks (RBF)

⁵ Extreme Learning Machine (ELM)

* y.moodi.civil@sirjantech.ac.ir

بتن پس از آب، دومین ماده پر مصرف در جهان است؛ زیرا در صنایع ساخت و ساز و مهندسی عمران کاربرد گسترده‌ای دارد. بتن به روش‌های مختلفی تولید می‌شود. بتن معمولی از سیمان، آب، انواع سنگدانه، چسباننده‌ها و افزودنی‌ها تشکیل شده است [۱]. از ویژگی‌های بتن می‌توان به مقاومت، سختی، تخلخل، دوام، چگالی، مقاومت در برابر آتش و مقاومت حرارتی اشاره کرد. با توجه به اینکه مقاومت فشاری بیشترین تاثیر را بر ایمنی و دوام اجزای بتن دارد، به عنوان مهم‌ترین ویژگی بتن شناخته می‌شود که نشان‌دهنده ایمنی سازه است [۲ و ۳]. در فرآیند تولید سیمان، به علت سوزاندن منابع طبیعی و سوخت‌های فسیلی، مقادیر زیادی گاز CO₂ تولید می‌شود [۴]. بنابراین، تولید سیمان و کاربرد آن در پروژه‌های عمرانی، از عوامل اصلی تولید گازهای گلخانه‌ای در جهان است؛ بنابراین تأثیر منفی فراوانی بر محیط زیست می‌گذارد [۵-۷]. با توجه به اینکه هر تن سیمان، معادل یک تن CO₂ تولید می‌کند، به همین میزان گاز در جو منتشر می‌شود [۸ و ۹]. برای کاهش تأثیرات منفی سیمان بر محیط زیست، می‌توان از مواد زائد یا بازیافتی به جای سیمان استفاده کرد [۱۰]. ضایعات صنعتی مانند خاکستر بادی، پودر گرانیت و خاکستر پوسته برنج می‌توانند به عنوان جایگزین سیمان استفاده شوند [۱۱]. افزودنی‌های معدنی به بتن در زمینه محیط زیست نقش مهمی دارند و به دلیل پایداری و مزایای جهانی آن‌ها، توجه ویژه‌ای به این مواد شده است [۱۲]. پوزولان‌های طبیعی از سنگ‌های آتشفشانی و مواد معدنی به دست می‌آیند. استفاده از پوزولان‌ها در بتن باعث کاهش هزینه‌ها، بهبود مقاومت، کارایی و دوام بتن می‌شود. همچنین شامل کاهش انبساط قلبایی سنگدانه‌ها، حمله سولفات‌ها و مقاومت در برابر ترک‌های حرارتی می‌شود؛ بنابراین پوزولان‌ها باعث کاهش تخریب محیط زیست نیز می‌شوند [۱۳ و ۱۴].

خاکستر بادی از فرآیند سوزاندن زغال‌سنگ تولید می‌شود. این ماده باعث کاهش مصرف سیمان و کاهش هزینه‌های دفع ضایعات می‌شود و به‌طور وسیع در صنعت ساخت‌وساز به‌عنوان جایگزین سیمان به‌کار می‌رود. بتن حاوی خاکستر بادی خمیر متراکم‌تری تولید می‌کند [۱۶] و [۱۵]. خاکستر بادی به‌عنوان جایگزین سیمان، ویژگی‌های مکانیکی و رئولوژی بتن را بهبود می‌بخشد [۱۷]. استاندارد ASTM C 618 خاکستر بادی را در دو گروه طبقه‌بندی می‌کند: گروه کلاس F و گروه کلاس C. گروه کلاس F دارای مقدار کمی آهک است و خواص پوزولانی دارد، در حالی که کلاس C علاوه بر خواص پوزولانی، خواص سیمانی نیز دارد [۱۸]. در تحقیقات نشان داده شده است، با افزایش مقدار خاکستر بادی در بتن، مقاومت فشاری در سنین اولیه کاهش می‌یابد؛ اما به‌دلیل فعالیت پوزولانی خاکستر بادی، در مراحل بعدی عمل‌آوری، مقاومت فشاری افزایش می‌یابد [۱۹]. بر اساس یافته‌های احسانی^۱ و همکاران [۲۰] حداکثر مقاومت فشاری بتن حاوی خاکستر بادی در نسبت‌های جایگزینی کمتر از ۳۵ درصد حاصل می‌شود و افزایش این نسبت، افت چشمگیری در مقاومت فشاری ایجاد می‌کند. راوینا و مهتا^۲ [۲۱] در تحقیقات خود به این نتیجه دست یافتند که در مخلوط‌های بتن کم‌سیمان، جایگزینی سیمان و ماسه با مقادیر قابل توجهی خاکستر بادی، از جنبه‌های مختلف عملکردی بسیار مفید و کارآمد است. بر اساس یافته‌های توماس و متیوز^۳ [۲۲]، عمل‌آوری کافی، نقشی حیاتی در دوام بتن داشته و با افزایش دوره آن از ۱ به ۷ روز، میزان کرناسیون تا ۵۰ درصد کاهش می‌یابد، به‌طوری که بتن‌های حاوی تا ۳۰ درصد خاکستر بادی، عملکردی مشابه یا اندکی ضعیف‌تر از بتن معمولی دارند، اما افزایش این مقدار به ۵۰ درصد، سرعت کرناسیون را به‌طور قابل توجهی افزایش می‌دهد. لام^۴ و همکاران [۲۳] دریافته‌اند که خاکستر بادی به‌طور قابل توجهی رفتار فشاری بتن را در ناحیه پس از اوج مقاومت بهبود می‌بخشد و شیب بخش نزولی منحنی تنش-کرنش را کاهش می‌دهد؛ مقادیر کم آن مقاومت کششی بتن را افزایش می‌دهد، در حالی که بتن با حجم بالای خاکستر بادی علی‌رغم مقاومت کششی اندکی پایین‌تر، در آزمایش‌های شکست مقادیر بالاتری خیز نهایی میان‌دهانه داشته و مقادیر انرژی شکست آن مشابه یا بالاتر از بتن معمولی است. بر اساس یافته‌های اونر^۵ و همکاران [۲۴]، مقاومت بتن با افزایش خاکستر بادی

^۱ Ehsani

^۲ Ravina & Mehta

^۳ Thomas & Matthews

^۴ Lam

^۵ Oner

تا حد بهینه حدود ۴۰ درصد وزنی سیمان افزایش یافته و پس از آن کاهش می‌یابد، که در این میان نسبت خاکستر بادی به سیمان به عنوان عامل کلیدی در تعیین کارایی آن شناسایی شده است.

در مهندسی عمران، مسائل متعددی تحت تأثیر عدم قطعیت‌ها قرار دارند که می‌توانند از طریق محاسبات و تجربه به دست آیند. اما در بسیاری از موارد، این اطلاعات و تجربه کافی نیستند. به همین دلیل، استفاده از هوش مصنوعی ضروری می‌شود [۲۵ و ۲۶]. در سال‌های اخیر، از تکنولوژی‌های پیشرفته مانند هوش مصنوعی و روش‌های یادگیری ماشینی برای پیش‌بینی خواص بتن استفاده شده است [۲۷ و ۲۸]. با استفاده از مدل‌های یادگیری ماشینی و رگرسیون‌ها، می‌توان متغیرها را پیش‌بینی کرد و این الگوریتم‌ها روابط دقیق‌تری با استفاده از متغیرهای ورودی ایجاد می‌کنند [۲۹].

چندین تحقیق در زمینه مدل‌سازی تأثیر خاکستر بادی بر مقاومت فشاری بتن با استفاده از تکنیک‌های یادگیری ماشینی انجام شده است. به عنوان مثال، ماهاجان و بهگت^۱ [۳۰] مدل‌سازی تأثیر خاکستر بادی بر مقاومت فشاری بتن را با استفاده از مدل‌های شبکه عصبی مصنوعی (ANN)، الگوریتم ژنتیکی پیشرفته (GEP) و درخت تصمیم (D-T) بر روی ۱۰۰ نمونه انجام دادند. احسانی^۲ و همکاران [۲۰] پیش‌بینی مقاومت فشاری بتن‌های معمولی، حاوی خاکستر بادی و سرباره را بر اساس روش‌های نوین و ارائه طرح‌مخلوط‌های بهینه آن‌ها با استفاده از مدل‌های مختلف یادگیری ماشینی نظیر رگرسیون خطی (LR)، رگرسیون تصادفی (FR)، رگرسیون چند جمله‌ای درجه دو (PFR)، الگوریتم ژنتیک (GA) و الگوریتم رقابت لیگ فوتبال (WCA) بر روی ۱۰۳۰ داده انجام دادند که از این میان، ۲۳۹ داده مربوط به بتن حاوی خاکستر بادی بوده است. سونگ^۳ و همکاران [۳۱] مدل‌سازی تأثیر خاکستر بادی بر مقاومت فشاری بتن را با استفاده از مدل‌های مختلفی همچون شبکه عصبی مصنوعی (ANN)، الگوریتم ژنتیکی پیشرفته (GEP)، درخت تصمیم (D-T) و Boosting بر روی ۹۸ نمونه انجام دادند. روشنی^۴ و همکاران [۳۲] در تحقیق خود، مدل‌سازی تأثیر خاکستر بادی بر مقاومت فشاری بتن را با استفاده از مدل‌های مختلفی همچون شبکه عصبی مصنوعی (ANN) بر روی ۲۹۶ نمونه انجام دادند. جیانگ^۵ و همکاران [۳۳] در تحقیق خود، مدل‌سازی تأثیر خاکستر بادی بر مقاومت فشاری بتن را با استفاده از مدل‌های مختلفی همچون الگوریتم یادگیری افراطی ماشین (ELM)، جنگل تصادفی (RF)، رگرسیون برداری پشتیبانی (SVR) و (Grid Search SVR) بر روی ۲۷۰ نمونه انجام دادند. احمد و خان^۶ [۳۴] در تحقیق خود، مدل‌سازی تأثیر خاکستر بادی بر مقاومت فشاری بتن را با استفاده از مدل‌های مختلفی همچون درخت تصمیم (D-T)، شبکه پرسپترون چندلایه (MLP)، جنگل تصادفی (RF) و رگرسیون برداری پشتیبانی (BR) بر روی ۵۶۹ نمونه انجام دادند. قربانی^۷ [۳۵] در تحقیق خود، مدل‌سازی تأثیر خاکستر بادی بر مقاومت فشاری بتن را با استفاده از مدل‌های مختلفی همچون ANN بر روی ۴۷۱ نمونه انجام دادند. آل‌هاشم^۸ و همکاران [۳۶] نیز در تحقیق خود، مدل‌سازی تأثیر خاکستر بادی بر مقاومت فشاری بتن را با استفاده از مدل‌های مختلفی همچون ANN و GEP بر روی ۳۱۰ نمونه انجام دادند.

مرور ادبیات تحقیق نشان می‌دهد که اگرچه مطالعات متعددی توسط پژوهشگرانی همچون ماهاجان و بهگت [۳۰]، احسانی و همکاران [۲۰]، سونگ و همکاران [۳۱]، روشنی و همکاران [۳۶]، جیانگ و همکاران [۳۳]، احمد و خان [۳۴]، قربانی [۳۵] و آل‌هاشم و همکاران [۳۲] در زمینه مدل‌سازی مقاومت فشاری بتن حاوی خاکستر بادی با استفاده از تکنیک‌های یادگیری ماشینی انجام شده است، اما محدودیت حجم بانک داده‌های آزمایشگاهی به عنوان یک خلأ تحقیقاتی اصلی در این حوزه مطرح است. اکثر مطالعات پیشین بر روی مجموعه داده‌های با حجم کم (کمتر از ۳۰۰ نمونه) استوار بوده‌اند که این امر می‌تواند دقت مدل‌ها و قابلیت تعمیم‌دهی آن‌ها را برای طیف وسیعی از طرح‌های مخلوط بتن محدود نماید.

^۱ Bhagat

^۲ Ehsani

^۳ Song

^۴ Roshani

^۵ Jiang

^۶ Ahmad, Khan

^۷ Ghorbani

^۸ Al Hashem

در راستای رفع خلأهای موجود در مطالعات پیشین، نوآوری اصلی این پژوهش در گردآوری و توسعه یک بانک داده جامع شامل ۵۹۹ داده آزمایشگاهی نهفته است که از نظر تعداد نمونه‌ها، برتری محسوسی نسبت به اغلب تحقیقات گذشته داشته و زمینه ارائه مدلی با قابلیت تعمیم‌پذیری بالاتر را فراهم می‌سازد. داده‌های جمع‌آوری شده از مطالعات آزمایشگاهی معتبر استخراج شده و شامل پارامترهای مؤثر بر مقاومت فشاری بتن‌های حاوی خاکستر بادی نظیر مقادیر سیمان، خاکستر بادی، آب، فوق‌روان‌کننده، ریزدانه، درشت‌دانه و سن نمونه‌های بتن است؛ از این رو، استفاده از این مجموعه داده گسترده امکان توسعه مدلی قابل اعتماد برای بتن‌هایی با سطوح مختلف جایگزینی خاکستر بادی را فراهم می‌کند. در ادامه، از مدل‌هایی استفاده شده است که در مقایسه با مطالعات گذشته، کمتر برای تخمین مقاومت فشاری بتن حاوی خاکستر بادی به کار گرفته شده‌اند. بدین منظور، عملکرد پنج الگوریتم پیشرفته یادگیری ماشین شامل RBF، MLP، ANFIS، ELM و Kriging به صورت هم‌زمان و در یک چارچوب مقایسه‌ای یکپارچه برای تخمین مقاومت فشاری این بتن‌ها مورد ارزیابی قرار گرفت. علاوه بر این، به منظور درک بهتر نقش هر یک از متغیرهای ورودی، تحلیل حساسیت با بهره‌گیری از یک روش کارآمد انجام شد تا میزان تأثیرگذاری پارامترهای مختلف بر مقاومت فشاری به صورت کمی بررسی گردد. در نهایت، برخلاف بسیاری از مطالعات که صرفاً به ارائه مدل‌های جعبه‌سیاه بسنده کرده‌اند، در این تحقیق یک رابطه صریح و کاربردی مبتنی بر مدل برنامه‌نویسی ژنتیکی (GP) ارائه شده است که بدون نیاز به محاسبات پیچیده یا ابزارهای پیشرفته محاسباتی، امکان تخمین مقاومت فشاری بتن حاوی خاکستر بادی را برای مهندسان و پژوهشگران فراهم می‌آورد.

۲- مجموعه داده‌ها

در این بخش، به توضیح پایگاه داده‌ای که برای تحلیل و پیش‌بینی مورد استفاده قرار گرفته است، پرداخته می‌شود. برای این منظور، از نتایج مقالات تحقیقاتی پیشین که در مجلات معتبر منتشر شده‌اند، بهره گرفته شده است (پیوست ۱). پایگاه داده شامل ۵۹۹ نمونه بتن حاوی خاکستر بادی است. از ۷ پارامتر ورودی و یک پارامتر خروجی تشکیل شده است. متغیرهای ورودی شامل مقادیر سیمان، خاکستر بادی، آب، روان‌کننده، مقدار سنگدانه‌های درشت، مقدار سنگدانه‌های ریز و سن نمونه می‌باشد، مقاومت فشاری به عنوان متغیر هدف یا متغیر خروجی در نظر گرفته شده است. شکل ۱ نمودار هیستوگرام فراوانی پارامترهای ورودی و خروجی آزمایش را نشان می‌دهد. در این تحقیق، به صورت تصادفی، ۷۰ درصد از مجموع داده‌ها به عنوان داده‌های آموزش و ۳۰ درصد از داده‌ها به عنوان داده‌های تست انتخاب شدند. برای افزایش کارایی مدل، نرمال‌سازی داده‌ها ضروری است. برای همین منظور، تمامی داده‌ها در تمام مدل‌ها بین ۰/۱ و ۰/۹ نرمال‌سازی شدند.




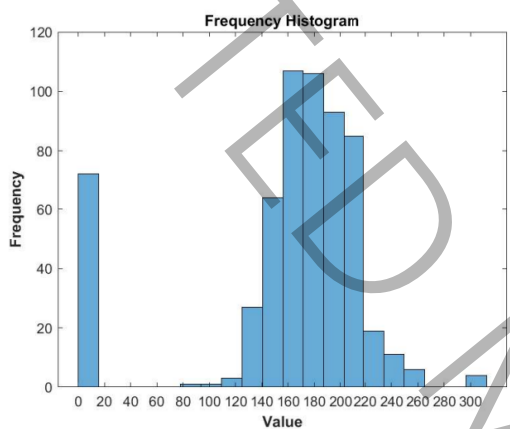


$$s_i = 0.1 + (0.9 - 0.1) \frac{i - i_{\min}}{i_{\max} - i_{\min}} \quad (1)$$

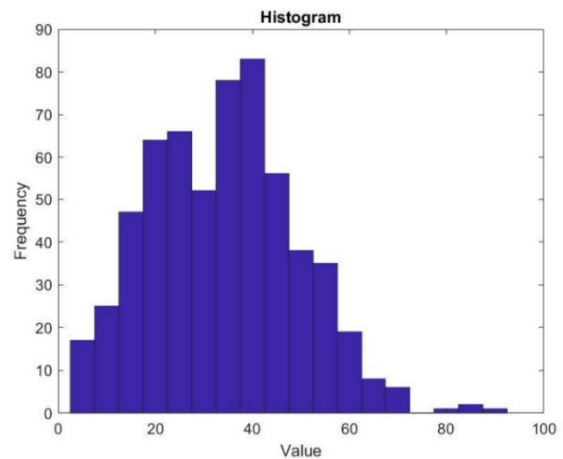
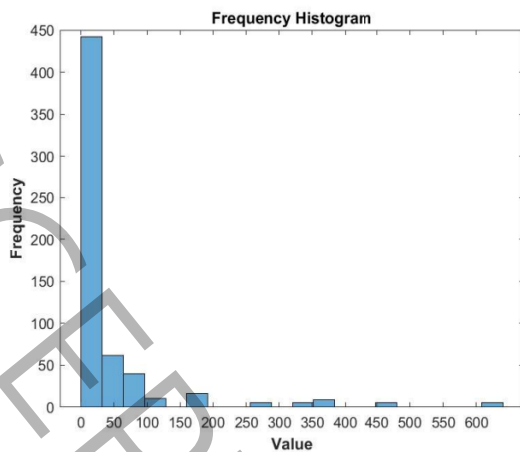
در معادله ۱، i_{\min} و i_{\max} به ترتیب نمایانگر حداقل و حداکثر مقدار متغیر ورودی i هستند و S_i نیز متغیر نرمالیزه شده را نشان می‌دهد.

جدول ۱. مشخصات آماری مجموعه داده‌ها

Table 1. Statistical characteristics of the dataset

نماد	پارامتر	واحد	حداقل	حداکثر	میانگین	انحراف معیار
C	سیمان	kg/m ³	۱۲/۴۶	۵۰۵	۲۴۸/۵۳	۱۱۶/۳۵
FA	خاکستر بادی	kg/m ³	۰/۷۸	۲۸۰	۹۴/۱۴	۴۷/۴۹
W	آب	kg/m ³	۷/۸۳	۳۱۱	۱۶۱/۳۹	۶۲/۹۹
Si	روان‌کننده	kg/m ³	۰	۲۰	۳/۹۳	۴/۸
Ca	درشت‌دانه	kg/m ³	۳۷/۳۸	۱۴۱۹/۳	۸۷۳/۴۶	۳۵۳/۰۲
Fa	ریزدانه	kg/m ³	۲۴/۲	۱۲۹۳	۶۸۲/۶۲	۲۷۶/۷۴
d	سن عمل‌آوری	days	۳	۶۲۵	۵۲/۷۸	۸۹/۹۲
f _c	مقاومت فشاری	MPa	۴/۱	۹۰	۳۶/۳۲	۱۵/۱





شکل ۱. نمودار هیستوگرام داده‌های آزمایشگاهی. الف: میزان خاکستر بادی، ب: میزان سیمان، پ: میزان روان‌کننده، ت: میزان آب، ج: میزان ریزدانه، ح: میزان درشت‌دانه، چ: مقاومت فشاری، ح: سن عمل‌آوری

Figure 1. Histogram chart of experimental data. a: Fly ash content, b: Cement content, c: Superplasticizer content, d: Water content, e: Fine aggregate content, f: Coarse aggregate content, g: Compressive strength, h: Curing age.

۳- مدلسازی

۳-۱- برنامه نویسی ژنتیک (GP)

برنامه‌نویسی ژنتیک یک شاخه از الگوریتم‌های ژنتیک است. تفاوت این دو در نحوه پردازش و نمایش جواب‌ها است. در برنامه‌نویسی ژنتیک (GP)، برنامه‌های کامپیوتری ایجاد می‌شود، در حالی که الگوریتم ژنتیک یک رشته عددی را به عنوان جواب نمایش می‌دهد. در برنامه‌نویسی ژنتیک، جمعیتی از برنامه‌های کامپیوتری ایجاد می‌شود که نسل به نسل به صورت تصادفی به جمعیتی از برنامه‌های جدید تبدیل می‌شود. ابتدا این الگوریتم به صورت تصادفی جمعیتی اولیه از برنامه‌ها را تولید می‌کند، سپس هر کدام از برنامه‌های جمعیت اجرا شده و برآوردگی آن‌ها ارزیابی می‌شود. در مرحله بعد، یک یا دو برنامه از جمعیت بر اساس قابلیت آن‌ها برای شرکت در عملیات ژنتیکی انتخاب شده و با استفاده از عملیات ژنتیک برنامه‌های جدید برای نسل بعدی تولید می‌شوند. این روند تا زمانی که یک راه‌حل قابل قبول پیدا شود، ادامه می‌یابد و این راه‌حل به عنوان نتیجه اجرای GP نمایش داده می‌شود.

در برنامه‌نویسی ژنتیک، برنامه‌ها به صورت ساختار درختی نمایش داده می‌شوند، به طوری که درخت‌ها طول ثابتی ندارند. برگ‌های درخت متغیرها و ثابت‌ها هستند که در GP به آن‌ها پایانه گفته می‌شود. گره‌های داخلی، گره‌های محاسباتی هستند که به آن‌ها توابع گفته می‌شود. این توابع و پایانه‌ها مجموعه اولیه GP را تشکیل می‌دهند. در برنامه‌نویسی ژنتیک، ابتدا متغیرهای ورودی، هدف و تابع ارتباط‌دهنده تعریف می‌شوند، سپس ساختار مناسب و ضرایب آن‌ها به الگوها اختصاص داده می‌شود. از آنجا که در این روش یک معادله ارتباط‌دهنده بین متغیرهای ورودی و خروجی وجود دارد، این روش می‌تواند متغیرهای مناسب الگو را انتخاب کرده و متغیرهای غیرمرتبط را حذف نماید. این ویژگی باعث کاهش ابعاد متغیرهای ورودی می‌شود. برای الگوسازی مسائل مربوط به ساختار پدیده‌ها در زمینه مهندسی، به‌طور گسترده‌ای از این روش استفاده می‌شود [۵۰ و ۵۱]. هرچه پارامترها در مدل GP بهینه‌تر باشند، دقت مدل افزایش می‌یابد. GP شامل پارامترهای اندازه جمعیت، عملگرها، توابع ریاضی بین ژن‌ها، بازه زمانی ضرایب ثابت تصادفی، تعداد نسل‌ها، سرعت جهش و وارونگی است. در این تحقیق، مقادیر بهینه برای این پارامترها با استفاده از روش آزمون و خطا و مطابق جدول ۲ در نظر گرفته شده است.

جدول ۲. پارامترهای در نظر گرفته شده برای مدل برنامه ریزی ژنتیک

Table 2. Parameters considered for the genetic programming model.

۱۰۰۰۰	تعداد جمعیت
۵ و ۵۰۰	تعداد نسل و تعداد ژن
TIMES·MINUS·PLUS·RDIVIDE·SQUARE EXP·LOG·SQRT·CUBE	عملگرها و توابع ریاضی بین ژن ها
۰/۹	سرعت جهش
۱۰-الی ۱۰	بازه ضرایب ثابت تصادفی

۳-۲- سیستم استنتاج تطبیقی فازی عصبی (ANFIS)

ساختار سیستم استنتاج عصبی-فازی بر پایه یک سیستم استنباط فازی است که پارامترهای بخش‌های فرض و نتیجه قوانین اگر-آنگاه فازی توسط یک مدل شبکه عصبی تنظیم می‌شود [۵۲]. در این سیستم، داده‌ها به مجموعه‌هایی با درجات عضویت بین صفر و یک تقسیم می‌شوند. ANFIS شامل بخش‌هایی از سیستم فازی سنتی است که با استفاده از لایه‌های پنهان، هر مرحله را محاسبه می‌کند و از شبکه‌های عصبی برای یادگیری و بهبود عملکرد سیستم استفاده می‌کند. شکل ۲ ساختار روش ANFIS را نشان می‌دهد. در مدل فازی سوگنو، که شامل دو متغیر ورودی و یک متغیر خروجی است، دو قانون بیان شده است [۵۳]:

$$\text{قانون ۱: اگر } (x \in A_1) \text{ و } (y \in B_1) \text{ آنگاه } (f_1 = p_1x + q_1y + r_1)$$

$$\text{قانون ۲: اگر } (x \in A_2) \text{ و } (y \in B_2) \text{ آنگاه } (f_2 = p_2x + q_2y + r_2)$$

لایه اول لایه ورودی است، هر گره در این لایه به عنوان یک گره تطبیقی انتخاب می‌شود که دارای یک تابع است:

$$O_{1,i} = \mu_{A_i}(x) \quad \text{برای } i=1,2 \quad (2)$$

$$O_{1,i} = \mu_{B_{i-2}}(Y) \quad \text{برای } i=3,4 \quad (3)$$

در این فرمول x متغیر ورودی به گره i ، $O_{1,i}$ درجه عضویت فازی و A_i و B_i یک برچسب زبانی می‌باشند. برچسب‌های زبانی به مجموعه‌های فازی اشاره دارند که می‌توانند مفاهیم مختلفی را به صورت زبانی توصیف کنند.

برای تعریف تابع عضویت $\mu_{A_i}(x)$ از فرمول (۴) استفاده می‌شود:

$$\mu_{A_i}(x) = \frac{1}{1 + \left(\frac{x - c_i}{a_i}\right)^{2b_i}} \quad (4)$$

a_i ، b_i و c_i پارامترهای پیش فرض تابع عضویت هستند که در طول فرآیند آموزش به روز می‌شوند.

هر گره در لایه دوم یک گره ثابت است که به صورت زیر محاسبه می‌شود:

$$O_{2,i} = w_i = \mu_{A_i}(x) \mu_{B_i}(Y) \quad \text{برای } i=1,2 \quad (5)$$

خروجی لایه سوم نرمالیزه شده لایه دوم است و به صورت رابطه زیر ارائه می‌گردد:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad \text{برای } i=1,2 \quad (6)$$


لایه فازی سازی مربوط به لایه چهارم است. در این لایه، هر گره یک گره تطبیقی است و مطابق تابع زیر تعریف می‌شود:

$$O_{4,i} = \bar{w}_i (p_i x + q_i y + r_i) \quad \text{برای } i=1,2 \quad (7)$$

لایه پنجم لایه خروجی است که از طریق مجموع تمام سیگنال‌های دریافتی، خروجی نهایی را محاسبه می‌کند:

$$O_{s,i} = \sum \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad \text{برای } i=1,2 \quad (8)$$

از عواملی که باعث ضعف الگوریتم‌های بهینه‌ساز محلی مبتنی بر گرادیان در تنظیم پارامترهای مدل یادگیری ماشین می‌شود، می‌توان به عدم همگرایی، نوسانات گرادیان، حساسیت به نرخ یادگیری، گرفتادن در نقاط بهینه محلی، پیچیدگی محاسبه گرادیان و حساسیت به مقیاس ویژگی‌ها اشاره کرد. برای رفع این مشکلات، می‌توان از یک الگوریتم قدرتمند جستجوی سراسری استفاده نمود [۵۴ و ۵۵]. نوع توابع عضویت متغیرهای ورودی و خروجی مدل، تعداد تکرارها و تعداد خوشه‌ها بر دقت مدل ANFIS تأثیر می‌گذارند. با تنظیم دقیق مقادیر پارامترهای بایاس شبکه، توابع عضویت متغیرها و وزن‌ها می‌توان عملکرد مدل را بهبود بخشید.



شکل ۲. ساختار روش ANFIS [۵۳].

Figure 2. Structure of the ANFIS method [53].

۳-۳- پرسپترون چند لایه (MLP)

به‌طور گسترده‌ای در مسائل مختلف یادگیری ماشین، مانند شناسایی الگو، پیش‌بینی و دسته‌بندی داده‌ها استفاده می‌شود. این شبکه شامل یک لایه ورودی، یک لایه مخفی و یک لایه خروجی است، هر نورون در این شبکه دارای یک تابع فعال‌سازی است که معمولاً غیرخطی می‌باشد [۵۶]. داده‌های پیش‌بینی شده ابتدا توسط لایه ورودی گرفته شده و سپس به نورون‌های موجود در لایه مخفی منتقل می‌شوند. در لایه ورودی، مقدار خالص به صورت معادله (۹) محاسبه می‌شود [۵۷ و ۵۸]:

$$Net = \sum_{i=1}^n w_{ij} x_i + b_j \quad (9)$$

x_i متغیرهای گره‌ای در لایه قبلی، n تعداد کل متغیرهای گره‌ای که از لایه قبلی دریافت می‌شوند و w_{ij} و b_j وزن‌ها و بایاس‌های شبکه در لایه فعلی هستند. یک تابع فعال‌سازی، برای کاهش تنوع مقادیر خالص به آن اضافه می‌شود، سپس سیگنال خروجی ارائه می‌شود [۵۹]. تابع فعال‌سازی هایپربولیک تانژانت به صورت معادله (۱۰) است:


$$y = \frac{2}{1 + e^{-2 \cdot Net}} - 1 \quad (10)$$

این فرایند بر روی هر لایه انجام می‌شود تا زمانی که سیگنال‌های خروجی از لایه آخر گزارش شوند. در نهایت، برای کاهش خطا، با اصلاح بایاس‌ها و وزن‌های اختصاص داده شده، یک الگوریتم بهینه‌سازی از طریق MLP ارائه می‌شود. الگوریتم‌های زیرمجموعه ANN دارای سرعت بالای همگرایی و دقت بالا هستند [۶۰]. شکل ۳ طرح کلی یک شبکه عصبی مصنوعی ANN را نشان می‌دهد.

۳-۴- شبکه عصبی شعاعی پایه (RBF)


شبکه‌های عصبی RBF به عنوان یک رویکرد جذاب برای تقریب توابع به دلیل معماری ساده، کارایی محاسباتی و توانایی بالای تعمیم شناخته می‌شوند. این شبکه‌ها نشان داده‌اند که به‌عنوان تقریب‌زننده‌های جهانی عمل می‌کنند؛ به این معنا که از نظر نظری، هر تابع پیوسته‌ای که در یک مجموعه محدود تعریف شده باشد، می‌تواند با افزایش تعداد گره‌های مخفی به دقت از پیش تعیین‌شده‌ای تقریب زده شود [۶۵-۶۶].

[۶۲]. طبق مقاله مدی و دارکن^۱ [۶۶]، هنگامی که بعد ورودی به اندازه کافی کوچک باشد، شبکه‌های عصبی RBF بهترین انتخاب برای یادگیری و تقریب توابع پیوسته هستند. از ویژگی‌های برجسته شبکه‌های عصبی RBF می‌توان به موارد زیر اشاره کرد: این شبکه‌ها تقریب‌زننده‌های جهانی هستند [۶۴]، بهترین ویژگی‌های تقریب را دارند [۶۷]، سرعت یادگیری آن‌ها به دلیل استفاده از نورون‌های محلی تنظیم شده سریع است [۶۶]، و از نظر توپولوژی فشرده‌تر از سایر شبکه‌های عصبی هستند [۶۸]. یک شبکه عصبی RBF، که در شکل ۴ نشان داده شده است، قادر است مجموعه‌ای از ورودی‌ها را به مجموعه‌ای از خروجی‌ها ارتباط دهد [۶۹]. لایه ورودی شبکه RBF، داده‌های ورودی را که می‌توانند بردار یا ماتریسی باشند دریافت می‌کند. لایه مخفی شامل مجموعه‌ای از نورون‌ها است. لایه خروجی این شبکه، خروجی‌های لایه مخفی را ترکیب کرده و خروجی نهایی را تولید می‌کند. این لایه وزن‌ها را به خروجی لایه دوم اعمال می‌کند و برای ایجاد خروجی نهایی از ترکیب خطی استفاده می‌کند.



شکل ۳. ساختار روش ANN [۶۱].

Figure 3. Structure of the ANN method [61].



شکل ۴. ساختار روش RBF [۶۹].

Figure 4. Structure of the RBF method [70].

^۱ Moody, Darken

۵-۳- کریجینگ (Kriging)

روش کریجینگ برای درونیایی آماری در علوم و مهندسی استفاده می‌شود و یک الگوریتم تخمین کمترین مربعات است. پیش‌بینی‌های آن قطعی بوده و واریانس صفر دارند. روش کریجینگ پیش‌بینی دقیقی برای فرآیندهای تصادفی ارائه می‌دهد و قادر به محاسبه خطای مربع میانگین است؛ بنابراین مورد توجه محققان قرار گرفته است. الگوریتم‌های بهینه‌سازی فراابتکاری همراه با مدل‌های تخمین مانند کریجینگ، برای دستیابی به طرح‌های بهینه در مسائل مهندسی کمک می‌کنند؛ همچنین استفاده از آنها آسان و کم‌هزینه است. بهینه‌سازی چندهدفه برای مسائل با معیارهای مختلف تصمیم‌گیری مناسب بوده و امکان کاهش مصرف سیمان و افزایش استفاده از سنگدانه‌های بازیافتی در بتن دوستدار محیط‌زیست را فراهم می‌آورد [۷۰]. روش کریجینگ به دلیل دقت بالا در پیش‌بینی و توانایی ارائه واریانس، در ارزیابی قابلیت اعتماد و احتمال خرابی استفاده می‌شود. علاوه بر این، با افزودن نقاط طراحی جدید، دقت پیش‌بینی مدل کریجینگ قابل افزایش است [۷۲]. مدل کریجینگ پایه با در نظر گرفتن تابع پاسخ به‌دست می‌آید [۷۳ و ۷۴]:

$$G(x) = F(x, \beta) + Z(x) = f(x)^T \beta + Z(x) \quad (11)$$

در این فرمول $G(x)$ ، $F(x, \beta)$ ، $Z(x)$ ، β^T و $f(x)^T$ به ترتیب تابع پاسخ، مدل رگرسیون، روند تصادفی، ضرایب رگرسیون و تابع پایه نامیده می‌شوند.

$$\text{Cov}(P, r) = \sigma^2 (\theta, P, r) \quad (12)$$

طبق فرمول ۱۲، σ^2 ، $R(\theta, p, r)$ به ترتیب واریانس فرایند و تابع همبستگی گوسین بین دو نقطه p و r انتخاب شده با پارامتر θ می‌باشد. توابع همبستگی مختلفی در مدل کریجینگ پایه به کار گرفته می‌شود. مقدار پاسخ مطلوب پیش‌بینی شده نیز از معادله زیر بدست می‌آید.

$$G(x)_{pre} = \beta + r(x) R^{-1} (y - 1\beta) \quad (13)$$

$r(x)$ در این معادله همبستگی بین نقاط طراحی و x را نشان می‌دهد.

۶-۳- شبکه‌های عصبی تک لایه (ELM)

مدل ELM یک مدل نوین برای آموزش شبکه‌های عصبی مصنوعی است که عملکرد عمومی مناسبی دارد. این مدل می‌تواند در زمینه‌های مختلفی از جمله پیش‌بینی و رگرسیون، طبقه‌بندی، شبیه‌سازی سیستم‌ها، مدل‌سازی و پردازش سیگنال مورد استفاده قرار گیرد. شامیری^۱ و همکاران [۷۵] از ELM برای پیش‌بینی مقاومت فشاری بتن با مقاومت بالا استفاده کرده‌اند. این شبکه عصبی به فرآیند تنظیم تکراری برای پارامترها یا اتصالات بین لایه‌های مخفی و خروجی نیاز ندارد. ELM یک روش یادگیری نسبتاً جدید است که برخلاف شبکه‌های عصبی سنتی، بایاس‌های مخفی و وزن‌های ورودی را به صورت تصادفی مقداردهی اولیه کرده و این مقادیر در طول فرآیند یادگیری ثابت می‌مانند. همچنین محاسبه مستقیم و بدون نیاز به فرآیندهای آموزشی پیچیده برای تعیین وزن‌های لایه خروجی باعث می‌شود که ELM عملکرد عمومی بسیار خوبی از خود نشان دهد [۷۵].

۴- ارزیابی دقت مدل‌ها

در این تحقیق، برای شناسایی روشی با بیشترین دقت از شاخص‌های آماری استفاده شد. این شاخص‌ها شامل ریشه دوم میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، ضریب همبستگی (R^2) و انحراف معیار (SD) می‌باشند. هرچه مقدار R^2 به یک و سایر پارامترها به صفر نزدیک‌تر باشند، مدل بهینه‌تر خواهد بود.

¹ Shamiri

میانگین قدر مطلق خطا (MAE):

$$MAE = \frac{\sum_1^N |R_{pre} - R_{Exp}|}{N} \quad (14)$$

ریشه دوم میانگین مربعات خطا (RMSE):

$$RMSE = \sqrt{\frac{\sum_1^N (R_{pre} - R_{Exp})^2}{N}} \quad (15)$$

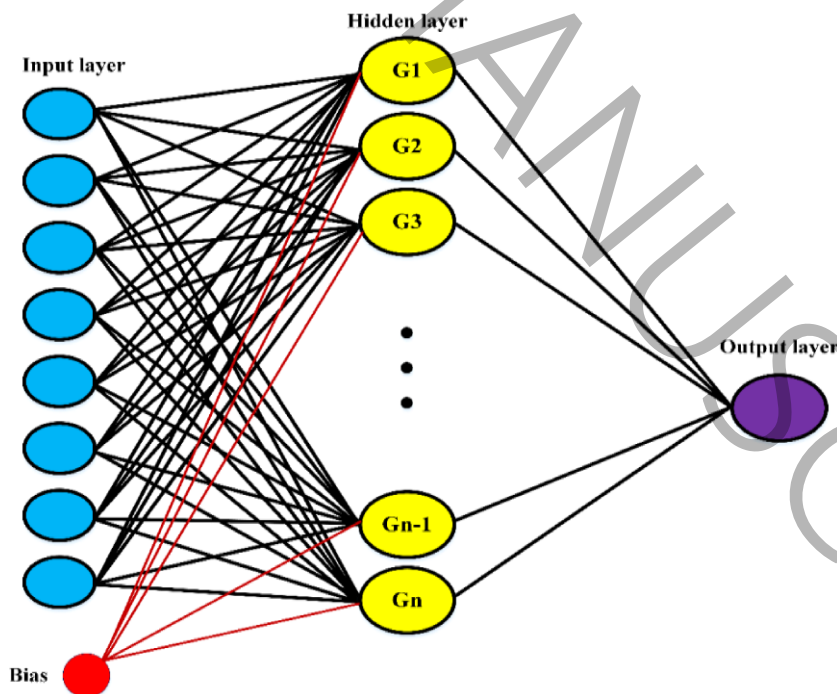
ضریب همبستگی (R^2):

$$R^2 = \frac{\left[\sum_1^N (R_{pre} - \bar{R}_{pre})(R_{Exp} - \bar{R}_{Exp}) \right]^2}{\sum_1^N (R_{pre} - \bar{R}_{pre})^2 \sum_1^N (R_{Exp} - \bar{R}_{Exp})^2} \quad (16)$$

انحراف معیار (SD):

$$SD = \sqrt{\frac{\sum_1^N \left(\frac{R_{pre}}{R_{Exp}} - \frac{\bar{R}_{pre}}{\bar{R}_{Exp}} \right)^2}{N - 1}} \quad (17)$$

در معادلات بالا N ، R_{pre} ، R_{Exp} ، \bar{R}_{pre} و \bar{R}_{Exp} به ترتیب تعداد نمونه‌ها، پارامتر خروجی پیش‌بینی شده، پارامتر خروجی تجربی، میانگین پارامتر خروجی پیش‌بینی شده و میانگین پارامتر خروجی تجربی است.



شکل ۵. ساختار روش ELM [۷۶].

Figure 5. Structure of the ELM method [77].

۵- نتایج و بحث

در این بخش، ابتدا رابطه پیشنهادی مبتنی بر GP برای تخمین مقاومت فشاری بتن حاوی خاکستر بادی ارائه می‌گردد. سپس نتایج شش مدل مختلف شامل GP، ANFIS، MLP، RBF، Kriging و ELM برای پیش‌بینی مقاومت فشاری بتن حاوی خاکستر بادی به تفصیل بیان می‌شود. در نهایت، با استفاده از شاخص‌های آماری توضیح داده‌شده در بخش‌های قبلی، مدلی که دارای دقت پیش‌بینی بالاتری است، انتخاب می‌شود. علاوه بر این، با انجام تحلیل حساسیت و بررسی پارامترها، میزان اهمیت متغیرهای ورودی به‌منظور شناسایی عواملی که بیشترین تأثیر را بر دقت پیش‌بینی مدل‌ها دارند، مورد ارزیابی قرار می‌گیرد.

۵-۱- رابطه‌ی پیشنهادی برای تخمین مقاومت فشاری

در این بخش، رابطه پیشنهادی GP برای تخمین مقاومت فشاری بتن حاوی خاکستر بادی ارائه شده است. رابطه (۱۸)، فرمول پیشنهادی مدل GP برای تخمین مقاومت فشاری بتن حاوی خاکستر بادی را نمایش می‌دهد. استفاده از این رابطه برای کاربران بدون نیاز به استفاده از رایانه نیز ممکن می‌باشد.

$$f_c = \frac{(0.153d)}{\log Ca} - 0.0767C - 2.74 \times 10^{-4} (C - W)(Si - Fa) - 2.74 \times 10^{-4} (Fa + Si)(C - FA) + 17.5 \log(\log d)^2 + 0.0767\sqrt{FA} + \frac{(4.44 \times 10^{-16} (4.68 \times 10^{15} C - 4.68 \times 10^{15} Ca)) (1.88 \times 10^{15} W \times Ca (\sqrt{Fa \times d}))}{\sqrt{W} (FA - 2Si) 1.84 \times 10^{19} C + 1.84 \times 10^{19} Si} + 28.9 \quad (18)$$

در این رابطه C ، FA ، W ، Si ، Ca ، Fa ، d به ترتیب به عنوان سیمان، خاکستر بادی، میزان آب، روان کننده، درشت‌دانه، ریزدانه و سن عمل‌آوری تعریف می‌شوند.

۵-۲- مقایسه عملکرد مدل‌ها

به‌منظور مقایسه جامع دقت شش مدل GP، ANFIS، MLP، RBF، Kriging و ELM، شاخص‌های آماری عملکرد این مدل‌ها برای نمونه‌های آموزش (۴۱۹ داده) و آزمایش (۱۸۰ داده) به‌صورت جداگانه محاسبه و در جدول ۳ ارائه شده است. نتایج نشان می‌دهد که هر شش مدل از دقت قابل قبولی در تخمین مقاومت فشاری بتن‌های حاوی خاکستر بادی برخوردارند. با این حال، مقایسه کمی شاخص‌های عملکردی در هر دو دسته نمونه‌های آموزش و آزمایش بیانگر آن است که مدل Kriging در تمامی معیارهای آماری، مقادیر مطلوب‌تری (R^2) بالاتر و خطاهای کمتر) نسبت به سایر مدل‌ها ارائه کرده است؛ از این‌رو، این مدل دارای بیشترین دقت و قابلیت تعمیم‌پذیری در میان روش‌های مورد بررسی است.

بر اساس نتایج جدول ۳، در شاخص‌های آماری نمونه‌های آموزش، مدل ELM با ضریب تعیین R^2 برابر با ۰/۹۹ پس از مدل Kriging، عملکرد بهتری نسبت به سایر مدل‌ها نشان داده است. با این حال، در شاخص‌های آماری نمونه‌های آزمایش که معیار اصلی ارزیابی قابلیت تعمیم‌پذیری مدل‌ها محسوب می‌شود، مدل RBF با R^2 برابر با ۰/۸۶۸ پس از مدل Kriging، عملکرد دقیق‌تری نسبت به سایر مدل‌ها داشته است. با توجه به اینکه ارزیابی نهایی مدل‌ها باید بر اساس شاخص‌های آماری داده‌های آزمایش صورت گیرد، می‌توان نتیجه گرفت که مدل RBF در مقایسه با ELM (پس از Kriging) از قابلیت تعمیم‌پذیری بالاتری برای پیش‌بینی مقاومت فشاری بتن حاوی خاکستر بادی برخوردار است.

به‌طور کلی، بر اساس جدول ۳، مدل‌های Kriging، RBF، ELM، MLP، ANFIS و GP به‌ترتیب از بیشترین تا کمترین دقت رتبه‌بندی می‌شوند. هرچند مدل GP در مقایسه با سایر مدل‌ها از دقت کمتری برخوردار است، اما مزیت اصلی آن ارائه یک رابطه صریح و کاربردی است که امکان تخمین مقاومت فشاری بتن حاوی خاکستر بادی را بدون نیاز به ابزارهای محاسباتی پیشرفته فراهم می‌کند.

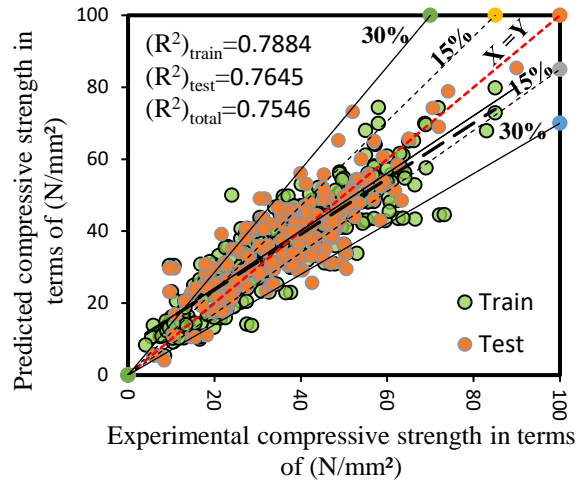

در شکل ۶، مقادیر مقاومت فشاری آزمایشگاهی در برابر مقادیر پیش‌بینی‌شده توسط مدل‌های مختلف نمایش داده شده و ضرایب همبستگی مربوط به داده‌های آموزش و آزمایش نیز ارائه شده است. با توجه به اینکه نزدیکی نقاط به خط نیم‌ساز بیانگر دقت بیشتر مدل

است، نتایج این شکل نشان می‌دهد که مدل‌های Kriging و RBF تطابق بهتری با داده‌های آزمایشگاهی دارند. همچنین در شکل ۷، نسبت مقادیر آزمایشگاهی به مقادیر پیش‌بینی‌شده برای داده‌های آموزش و آزمایش به‌طور جداگانه ترسیم شده است. بر اساس این شکل، بازه تغییرات این نسبت برای مدل Kriging در محدوده (۰/۷۳-۱/۴۱) و برای مدل ELM در محدوده (۰/۵۱-۱/۸۰) قرار دارد که بیانگر پراکندگی کمتر و پایداری بیشتر پیش‌بینی‌های مدل Kriging است. در مجموع، با استناد به نتایج جدول ۳ و تحلیل شکل‌های ۶ و ۷، می‌توان نتیجه گرفت که مدل Kriging دقیق‌ترین و پایدارترین عملکرد را در پیش‌بینی مقاومت فشاری بتن حاوی خاکستر بادی ارائه می‌دهد. در راستای اهداف این پژوهش، مقایسه‌ای نظام‌مند با مطالعات پیشین صورت پذیرفت. احسانی و همکاران [۲۶] با به‌کارگیری طیف وسیعی از مدل‌های یادگیری ماشین از جمله رگرسیون خطی، رگرسیون تصادفی، رگرسیون چندجمله‌ای درجه دو، الگوریتم ژنتیک و الگوریتم رقابت لیگ فوتبال بر روی ۱۰۳۰ نمونه (شامل ۲۳۹ نمونه بتن حاوی خاکستر بادی)، به پیش‌بینی مقاومت فشاری و ارائه طرح‌های مخلوط بهینه پرداختند. در بین روش‌های مذکور، الگوریتم رقابت لیگ فوتبال با ضریب تبیین (R^2) معادل ۰/۸۳۳ به‌عنوان بهترین عملکرد گزارش شده است. در مطالعه‌های دیگر، سونگ و همکاران [۲۷] با استفاده از مدل‌هایی چون شبکه عصبی مصنوعی، الگوریتم ژنتیکی پیشرفته، درخت تصمیم و بوستینگ بر روی ۹۸ نمونه، تأثیر خاکستر بادی بر مقاومت فشاری را مدلسازی نمودند. در این تحقیق، روش بوستینگ با کسب ضریب تبیین ۰/۹۵، بالاترین دقت پیش‌بینی را از خود نشان داد. همچنین، جیانگ و همکاران [۲۹] در پژوهشی بر پایه ۲۷۰ نمونه، عملکرد الگوریتم‌هایی نظیر یادگیری افراطی ماشین، جنگل تصادفی، رگرسیون برداری پشتیبانی و جستجوی شبکه‌ای را مورد ارزیابی قرار دادند که در آن، مدل جنگل تصادفی با R^2 برابر ۰/۹۳۶ به‌عنوان مؤثرترین روش شناسایی گردید. در نهایت، اقبال و همکاران [۳۲] با تمرکز بر ۳۱۰ نمونه و استفاده از مدل‌های شبکه عصبی مصنوعی و الگوریتم ژنتیکی پیشرفته، مدل شبکه عصبی مصنوعی را با ضریب تبیین ۰/۹۴ به‌عنوان کارآمدترین روش معرفی نمودند. به‌طور کلی، در این تحقیق مدل Kriging با ضریب همبستگی ۰/۹۹۹ برای داده‌های آموزش و ۰/۹۶ برای داده‌های آزمایش بهترین عملکرد را در مقایسه با مدل‌های دیگر داشته است. مجموعه داده به‌کاررفته در این تحقیق با ۵۹۹ نمونه آزمایشگاهی، از نظر حجم و جامعیت پارامترهای ورودی، از اغلب مطالعات پیشین (عموماً با کمتر از ۳۰۰ نمونه) گسترده‌تر است. این امر موجب افزایش قابلیت اطمینان و تعمیم‌پذیری مدل‌ها شده است.


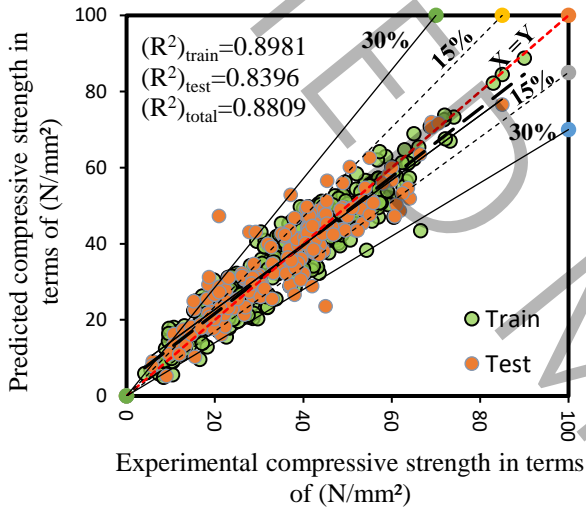
جدول ۳. مقایسه مدل‌های مورد بررسی

Table 3. Comparison of the studied models.

نمونه‌های آزمایش				نمونه‌های آموزش				مدل
SD	MAE	RMSE	R^2	SD	MAE	RMSE	R^2	
۰/۳۲۵	۶/۰۳۴	۷/۵۹۶	۰/۷۵۱	۰/۳۱۳	۵/۶۷۷	۷/۳۵۴	۰/۷۶۵	GP
۰/۳۴۴	۵/۹۵۱	۷/۱۶۶	۰/۷۶۵	۰/۳۰۱	۵/۳۶	۶/۸۳	۰/۷۸۸	ANFIS
۰/۲۱۴	۴/۴۶۵	۵/۹۹	۰/۸۴	۰/۱۷۷	۳/۷۷۷	۴/۸۴۱	۰/۸۹۸	MLP
۰/۱۸۹	۳/۷۹۱	۵/۴۳۴	۰/۸۶۸	۰/۰۹۹	۱/۸۷۱	۲/۵۷۶	۰/۹۷۱	RBF
۰/۱۱۳	۲/۰۸۵	۲/۹۹۹	۰/۹۶	۰/۰۱۷	۰/۱۱۶	۰/۴۵۶	۰/۹۹۹	Kriging
۰/۱۸۷	۴/۳۸	۶/۲۸۳	۰/۸۵۳	۰/۰۴۸	۱/۴۹	۰/۸۷	۰/۹۹	ELM





الف



ج

د



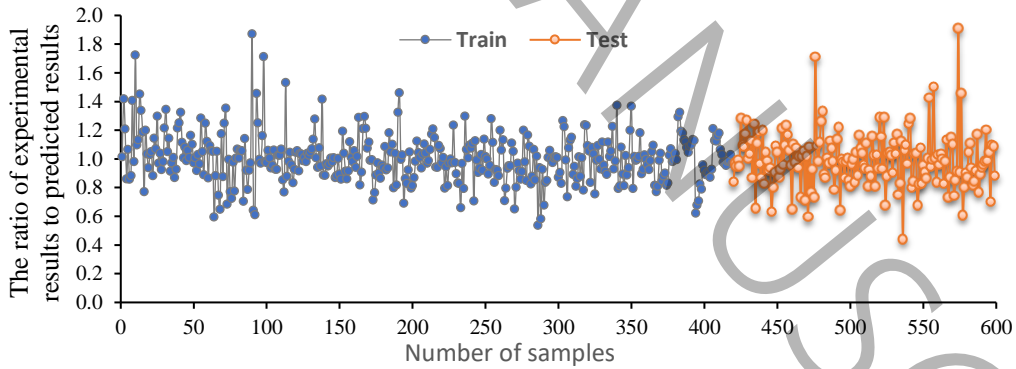
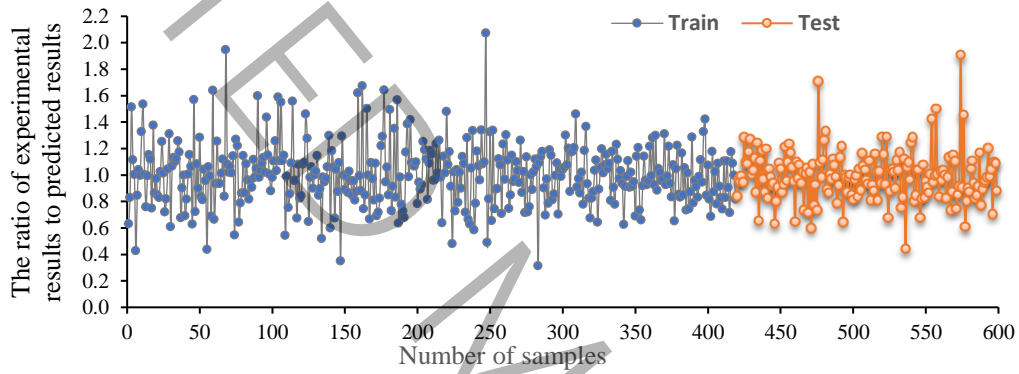

هـ


و

شکل ۶. نمودار نتایج پیش بینی شده در مقابل نتایج آزمایشگاهی با مدل‌ها الف: مدل ANFIS، ب: مدل GP،

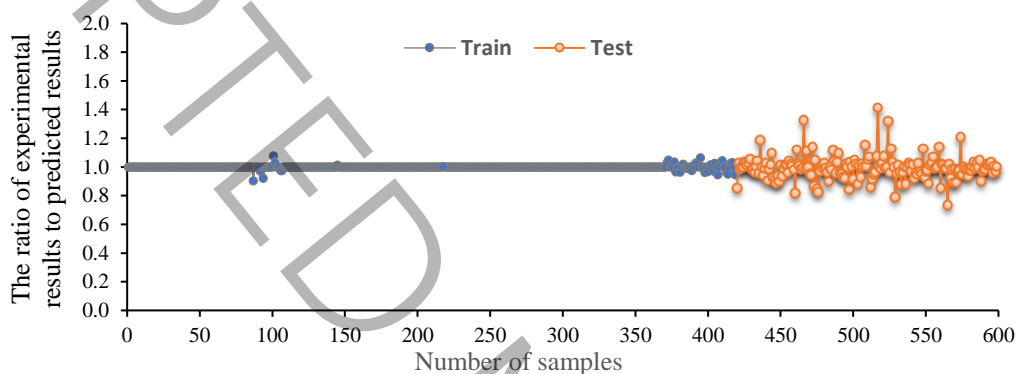
پ: مدل RBF، ت: مدل MLP، ث: مدل Kriging، ج: مدل ELM.

Figure 6. Chart of predicted results versus experimental results using the models. (a) ANFIS model , (b) GP model, (c) RBF model, (d) MLP model, (e) Kriging model, (f) ELM model.

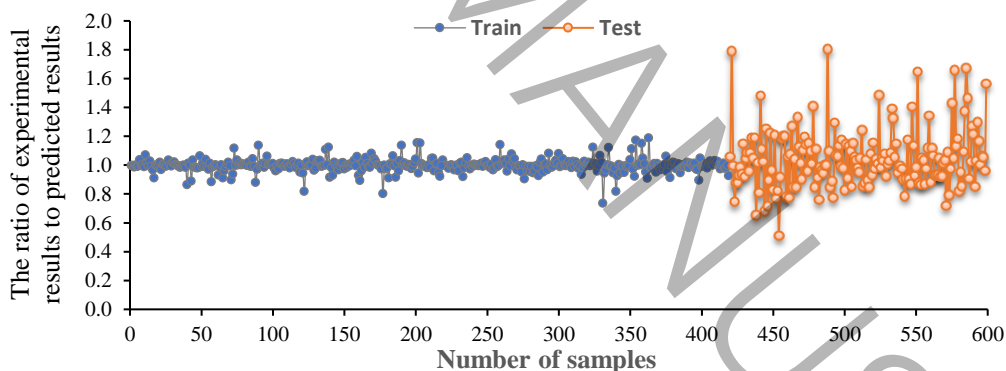




ت



ث



ج

شکل ۷. نسبت نتایج آزمایشگاهی به نتایج پیش بینی شده توسط مدل‌ها. الف: مدل ANFIS، ب: مدل GP، پ: مدل RBF، ت: مدل MLP، ث: مدل Kriging، ج: مدل ELM.

Figure 7. Ratio of experimental results to predicted results by the models. (a) ANFIS model, (b) GP model, (c) RBF model, (d) MLP model, (e) Kriging model, (f) ELM model.


۳-۵- نمودار تیلور

با استفاده از نمودار تیلور، می‌توان مقایسه‌ای بین مدل‌های مختلف یادگیری ماشین انجام داد و عملکرد آنها را با تطبیق مقادیر پیش‌بینی شده با اندازه‌گیری‌های واقعی ارزیابی کرد. نمودار تیلور بر اساس ترکیب سه شاخص عملکردی RMSE (خطای مربعات میانگین ریشه‌ای)، انحراف معیار استاندارد و ضریب همبستگی طراحی شده است [۷۷]. در شکل ۸، نمودار تیلور برای تمامی نمونه‌ها نمایش داده شده است. با توجه به نمودار تیلور، مشاهده می‌شود که نقطه مربوط به نتیجه مدل Kriging نسبت به سایر مدل‌ها به نقطه Observed نزدیک‌تر

است، که این امر نشان‌دهنده دقت بالاتر این مدل در تخمین مقاومت فشاری بتن حاوی خاکستر بادی می‌باشد. همچنین به عنوان دومین مدل می‌توان مدل RBF را بیان نمود، زیرا نسبت به سایر مدل‌های باقی‌مانده به نقطه Observed نزدیک‌تر است.

۴-۵- تحلیل حساسیت

با توجه به روش پیشنهادی نیک‌بین^۱ و همکاران [۷۸]، در این مطالعه به بررسی اهمیت تأثیر نسبی متغیرهای ورودی بر مقدار مقاومت فشاری بتن‌های حاوی خاکستر بادی پرداخته شده است. برای تحلیل حساسیت، توسط مدل Kriging استفاده شده است. در این تحلیل، تمام پارامترهای ورودی در نقطه میانگین آن‌ها ثابت در نظر گرفته شده و تنها پارامتر مد نظر از مقدار L (کمترین مقدار مشاهده‌شده برای کمیت مورد نظر در بانک داده‌ها) تا H (بیشترین مقدار مشاهده‌شده برای کمیت مورد نظر در بانک داده‌ها) تغییر می‌کند. در جدول ۴، مقادیر متناظر با پارامترهای ورودی نشان داده شده است. به‌طور خاص L، M، ML، H و MH به ترتیب به عنوان کمترین پارامتر مورد نظر، میانگین پارامتر مورد نظر، متوسط بین مقدار L و M، بیشترین پارامتر مورد نظر و متوسط بین M و H تعریف می‌شوند. در جدول ۵، مقاومت فشاری مشاهده می‌شود که در هر ستون، با تغییر یک پارامتر در نقاط L، M، ML، H و MH و ثابت نگه‌داشتن بقیه پارامترها، مقاومت فشاری به‌دست آمده است.



شکل ۸. نمودار تیلور روش‌های GP، ANFIS، MLP، RBF، ELM، Kriging.

Figure 8. Taylor diagram of the Kriging, ELM, RBF, MLP, ANFIS, and GP methods.

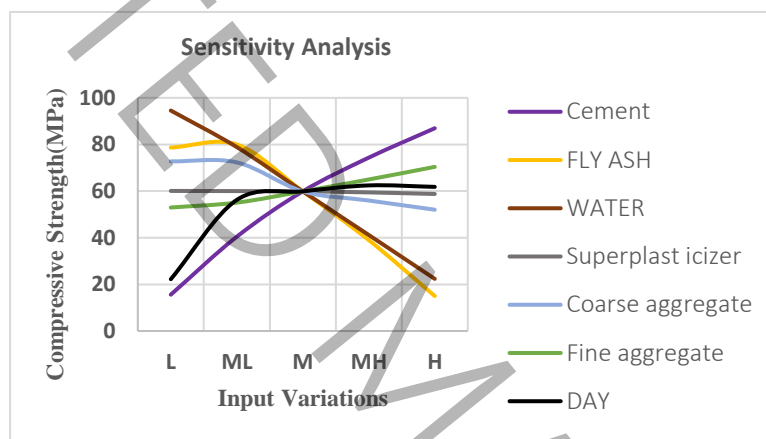
جدول ۴. مقادیر متناظر با پارامترهای ورودی

Table 4. Values corresponding to the input parameters.

سن عمل‌آوری	ریزدانه	درشت دانه	روان کننده	آب	خاکستر بادی	سیمان	دامنه
۳	۲۴/۲	۳۷/۳۸	۰	۷/۸۳	۰/۷۸	۱۲/۴۶	L
۲۷/۸۹	۳۵۳/۴۱	۴۵۵/۴۲	۱/۶۹۵	۸۴/۶۱	۴۷/۴۶	۱۳۰/۵	ML
۵۲/۷۸	۶۸۲/۶۲	۸۷۳/۴۶	۳/۹۳	۱۶۱/۳۹	۹۴/۱۴	۲۴۸/۵۳	M
۳۳۸/۸۹	۹۸۷/۸۱	۱۱۴۶/۳۸	۱۱/۶۹۵	۲۳۶/۱۹۵	۱۸۷/۰۷	۳۷۶/۷۶۵	MH
۶۲۵	۱۲۹۳	۱۴۱۹/۳	۲۰	۳۱۱	۲۸۰	۵۰۵	H

^۱ Nikbin

شکل ۹ نتایج تحلیل حساسیت متغیرهای ورودی با استفاده از مدل Kriging را نشان می‌دهد. در این تحلیل، برای کلیه ورودی‌ها شامل مقدار سیمان، مقدار خاکستر بادی، میزان آب، مقدار روان‌کننده، مقدار درشت‌دانه، میزان ریزدانه و سن عمل‌آوری، یکی از متغیرهای ورودی در بازه‌های L و H (بر اساس جدول ۴) تغییر داده شده و بقیه ورودی‌ها در نقطه میانگین ثابت در نظر گرفته شده است. بررسی نتایج ارائه شده در شکل ۹، در رابطه با تأثیر ورودی‌ها بر مقاومت فشاری بتن حاوی خاکستر بادی نشان می‌دهد که افزودن سیمان بیشترین تأثیر را در افزایش مقاومت فشاری دارد. همچنین، افزایش مقدار درشت‌دانه باعث کاهش مقاومت فشاری این نوع بتن می‌شود، در حالی که افزایش میزان ریزدانه موجب افزایش مقاومت فشاری می‌گردد. مدت زمان عمل‌آوری تأثیر مثبتی بر مقاومت فشاری دارد، به طوری که در زمان‌های اولیه نرخ رشد مقاومت بیشتر است. افزون بر این، افزایش میزان روان‌کننده تأثیر ناچیزی بر میزان مقاومت فشاری دارد. همچنین، با افزودن آب به این نوع بتن، کاهش مقاومت فشاری مشاهده می‌شود. نمودار حساسیت خاکستر بادی ابتدا افزایش و سپس کاهش مقاومت فشاری بتن را نشان می‌دهد. این رفتار می‌تواند به دلایل مختلفی بستگی داشته باشد. با افزایش درصد خاکستر بادی به سیمان تا حدود ۳۶ درصد، افزایش تدریجی مقاومت فشاری مشاهده می‌شود. اما پس از رسیدن به این مقدار، با ادامه افزایش درصد خاکستر بادی، کاهش مقاومت فشاری به تدریج مشاهده خواهد شد.



شکل ۹. اثر پارامترهای ورودی بر مقاومت فشاری پیش‌بینی شده با مدل GP
Figure 9. Effect of input parameters on compressive strength predicted by the GP model.

۶- نتایج

از آنجا که تولید سیمان باعث انتشار مقدار زیادی گازهای گلخانه‌ای و آسیب به محیط زیست می‌شود، برای کاهش اثرات منفی آن بر طبیعت، استفاده از خاکستر بادی به‌عنوان جایگزین سیمان مطرح شده است. با این حال، انجام مطالعات آزمایشگاهی نیاز به زمان و هزینه زیادی دارد. بنابراین، در سال‌های اخیر، از تکنولوژی‌های پیشرفته مانند هوش مصنوعی و روش‌های یادگیری ماشین برای پیش‌بینی خواص بتن استفاده شده است. در این تحقیق، یک مجموعه داده معتبر حاوی ۵۹۹ نمونه آزمایشگاهی از مطالعات آزمایشگاهی مرتبط با مقاومت فشاری بتن حاوی خاکستر بادی جمع‌آوری شد. با استفاده از سیستم برنامه‌ریزی ژنتیک (GP)، سیستم استنتاج منطقی فازی-عصبی (ANFIS)، پرسپترون چندلایه (MLP)، شبکه عصبی شعاعی پایه (RBF)، کریجینگ (Kriging) و شبکه‌های عصبی تک‌لایه (ELM) مدل‌های هوشمند برای پیش‌بینی مقاومت فشاری بتن‌های حاوی خاکستر بادی توسعه داده شد. سپس، براساس سیستم برنامه‌ریزی ژنتیک، رابطه‌ای برای تخمین مقاومت فشاری بتن حاوی خاکستر بادی ارائه شد. نتایج کلی به شرح زیر است:

- به ترتیب مدل‌های Kriging, ELM, RBF, MLP, ANFIS, GP دارای دقت خوبی برای پیش‌بینی مقاومت فشاری هستند.
- در این تحقیق با استفاده از الگوریتم ازدحام ذرات، قابلیت یادگیری (برای داده‌های آموزش) و قدرت تعمیم‌پذیری (با توجه به داده‌های آزمون) مدل‌ها را بهبود داده و مقادیر خطا و انحراف معیار پاسخ را نیز کاهش داده است. به طور کلی، برای داده‌های مورد استفاده در این تحقیق مدل Kriging با ضریب همبستگی ۰/۹۶ بهترین عملکرد را در مقایسه با مدل‌های ELM, RBF, MLP, ANFIS, GP داشته است.

- اگر چه ضریب همبستگی مدل GP نسبت به مدل‌های دیگر کمتر می‌باشد، ولی مدل GP رابطه‌ای ساده برای کاربران پیشنهاد می‌دهد که می‌توان برای تخمین مقاومت فشاری بتن‌های حاوی خاکستر بادی از آن استفاده نمود. با استفاده از این رابطه می‌توان بدون نیاز به محاسبات پیچیده، تحلیل حساسیت و مطالعه پارامتری برای تعیین میزان تاثیر متغیرهای ورودی بر مقاومت فشاری بتن حاوی خاکستر بادی انجام داد. نتایج محاسبه شده با این رابطه دارای $R^2=0.751$ و $SD=0.325$ می‌باشند.
- نتایج تحلیل حساسیت با استفاده از رابطه پیشنهادی نشان داد که سیمان، ریزدانه و مدت زمان عمل‌آوری بیشترین تاثیر مثبت و آب تاثیر منفی بر مقاومت فشاری بتن حاوی خاکستر بادی دارند نمودار حساسیت خاکستر بادی ابتدا افزایش و سپس کاهش مقاومت فشاری را نشان می‌دهد. با افزایش درصد خاکستر بادی نسبت به سیمان تا حدود ۳۶ درصد، افزایش تدریجی مقاومت فشاری ادامه می‌یابد؛ اما پس از این مقدار، با افزایش بیشتر درصد خاکستر بادی به سیمان، کاهش تدریجی مقاومت فشاری مشاهده می‌شود. ایجاد روابطی برای پیش‌بینی مقاومت فشاری بتن با استفاده از هوش مصنوعی و انواع دیگر مدل‌های یادگیری ماشین می‌تواند به‌عنوان یکی از پیشنهادات برای مطالعات آینده مورد بررسی قرار گیرد.

۷. مراجع

- [1] E. Possan, W.A. Thomaz, G.A. Aleandri, E.F. Felix, A.C.P. dos Santos, CO₂ uptake potential due to concrete carbonation: A case study, *Case Stud. Constr. Mater.* 6 (2017) 147–161. <https://doi.org/10.1016/j.cscm.2017.01.007>
- [2] A.R. Khaloo, M. Dehestani, P. Rahmatabadi, Mechanical properties of concrete containing a high volume of tire-rubber particles, *Waste Manag.* 28 (12) (2008) 2472–2482. <https://doi.org/10.1016/j.wasman.2008.01.015>
- [3] F. Farooq, M.N. Amin, K. Khan, M.R. Sadq, M.F. Javed, F. Aslam, R. Alyousef, A Comparative Study of Random Forest and Genetic Engineering Programming for the Prediction of Compressive Strength of High Strength Concrete (HSC), *Appl. Sci.* 10 (20) (2020) 7330. <https://doi.org/10.3390/app10207330>
- [4] X. Qian, J. Wang, Y. Fang, L. Wang, Carbon dioxide as an admixture for better performance of OPC-based concrete, *J. CO₂ Util.* 25 (2018) 31–38. <https://doi.org/10.1016/j.jcou.2018.03.007>
- [5] H. Yan, Q. Shen, L.C.H. Fan, Y. Wang, L. Zhang, Greenhouse gas emissions in building construction: A case study of One Peking in Hong Kong, *Build. Environ.* 45 (4) (2010) 949–955. <https://doi.org/10.1016/j.buildenv.2009.09.014>
- [6] S. Monkman, M. MacDonald, On carbon dioxide utilization as a means to improve the sustainability of ready-mixed concrete, *J. Clean. Prod.* 167 (2017) 365–375. <https://doi.org/10.1016/j.jclepro.2017.08.194>
- [7] H. Xiao, Z. Duan, Y. Zhou, N. Zhang, Y. Shan, X. Lin, G. Liu, CO₂ emission patterns in shrinking and growing cities: A case study of Northeast China and the Yangtze River Delta, *Appl. Energy* 251 (2019) 113384. <https://doi.org/10.1016/j.apenergy.2019.113384>
- [8] R. Kajaste, M. Hurme, Cement industry greenhouse gas emissions – management options and abatement cost, *J. Clean. Prod.* 112 (Part 5) (2016) 4041–4052. <https://doi.org/10.1016/j.jclepro.2015.07.055>
- [9] A. Akbar, K.M. Liew, Assessing recycling potential of carbon fiber reinforced plastic waste in production of eco-efficient cement-based materials, *J. Clean. Prod.* 274 (2020) 123001. <https://doi.org/10.1016/j.jclepro.2020.123001>
- [10] E. Benhelal, G. Zahedi, E. Shamsaei, A. Bahadori, Global strategies and potentials to curb CO₂ emissions in cement industry, *J. Clean. Prod.* 51 (2013) 142–161. <https://doi.org/10.1016/j.jclepro.2012.10.049>
- [11] A.A. Shubbar, H. Jafer, A. Dulaimi, K. Hashim, W. Atherton, M. Sadique, The development of a low carbon binder produced from the ternary blending of cement, ground granulated blast furnace slag and high calcium fly ash: An experimental and statistical approach, *Constr. Build. Mater.* 187 (2018) 1051–1060. <https://doi.org/10.1016/j.conbuildmat.2018.08.021>
- [12] V.C. Li, S. Wang, C. Wu, Tensile Strain-Hardening Behavior of Polyvinyl Alcohol Engineered Cementitious Composite (PVA-ECC), *ACI Mater. J.* 98 (6) (2001) 483–492. <https://doi.org/10.14359/10851>
- [13] P.K. Mehta, P.J.M. Monteiro, *Concrete: Microstructure, Properties, and Materials*, 3rd ed., McGraw-Hill, 2006.
- [14] M.G. Lee, D. Kang, H. Jo, J. Park, Carbon dioxide utilization with carbonation using industrial waste-desulfurization gypsum and waste concrete, *J. Mater. Cycles Waste Manag.* 18 (3) (2016) 407–412. <https://doi.org/10.1007/s10163-015-0461-0>
- [15] M. Ahmaruzzaman, A review on the utilization of fly ash, *Prog. Energy Combust. Sci.* 36 (3) (2010) 327–363. <https://doi.org/10.1016/j.pecs.2009.11.003>
- [16] ACI Committee 211, Guide for selecting proportions for high-strength concrete with Portland cement and fly ash, *ACI Mater. J.* 90 (3) (1993) 272–283.
- [17] S. Wang, V.C. Li, Engineered Cementitious Composites with High-Volume Fly Ash, *ACI Mater. J.* 104 (3) (2007) 233–241. <https://doi.org/10.14359/18668>
- [18] ASTM C618-12, Standard Specification for Coal Fly Ash and Raw or Calcined Natural Pozzolan for Use in Concrete, ASTM International, 2012.
- [19] R. Siddique, Performance characteristics of high-volume Class F fly ash concrete, *Cem. Concr. Res.* 34 (3) (2004) 487–493. <https://doi.org/10.1016/j.cemconres.2003.09.002>
- [20] M. Ehsani, H. Naseri, R. Saeedi Nezhad, M. Etebari Ghasbeh, F. Moghadas Nejad, Compressive strength prediction of ordinary concrete, fly ash concrete, and slag concrete by novel techniques and presenting their optimal mixtures, *Amirkabir J. Civ. Eng.* 53 (10) (2022) 4105–4124. <https://doi.org/10.22060/ceej.2020.17649.6631>
- [21] D. Ravina, P.K. Mehta, Compressive strength of low cement/high fly ash concrete, *Cem. Concr. Res.* 18 (4) (1988) 571–583. [https://doi.org/10.1016/0008-8846\(88\)90050-6](https://doi.org/10.1016/0008-8846(88)90050-6)
- [22] M.D.A. Thomas, J.D. Matthews, Carbonation of fly ash concrete, *Mag. Concr. Res.* 44 (160) (1992) 217–228. <https://doi.org/10.1680/macrc.1992.44.160.217>
- [23] L. Lam, Y.L. Wong, C.S. Poon, Effect of fly ash and silica fume on compressive and fracture behaviors of concrete, *Cem. Concr. Res.* 28 (2) (1998) 271–283. [https://doi.org/10.1016/S0008-8846\(97\)00269-X](https://doi.org/10.1016/S0008-8846(97)00269-X)
- [24] A. Oner, S. Akyuz, R. Yildiz, An experimental study on strength development of concrete containing fly ash and optimum usage of fly ash in concrete, *Cem. Concr. Res.* 35 (6) (2005) 1165–1171. <https://doi.org/10.1016/j.cemconres.2004.09.031>
- [25] A.H. Gandomi, X.S. Yang, S. Talatahari, A.H. Alavi (Eds.), *Metaheuristic Applications in Structures and Infrastructures*, Elsevier, 2013. <https://doi.org/10.1016/C2011-0-08778-1>

- [26] I.S. Alkroosh, P.K. Sarker, Prediction of the compressive strength of fly ash geopolymer concrete using gene expression programming, *Comput. Concrete* 24 (4) (2019) 295–302. <https://doi.org/10.12989/cac.2019.24.4.295>
- [27] L. Mahajan, S. Bhagat, An artificial neural network for the prediction of the strength of supplementary cementitious concrete, *Res. Eng. Struct. Mater.* 8 (2) (2022) 421–430. <https://doi.org/10.17515/resm2022.341st0918tn>
- [28] D.C. Feng, Z.T. Liu, X.D. Wang, Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach, *Constr. Build. Mater.* 230 (2020) 117000. <https://doi.org/10.1016/j.conbuildmat.2019.117000>
- [29] M.F. Iqbal, Q.F. Liu, I. Azim, X. Zhu, J. Yang, M.F. Javed, M. Rauf, Prediction of mechanical properties of green concrete incorporating waste foundry sand based on gene expression programming, *J. Hazard. Mater.* 384 (2020) 121322. <https://doi.org/10.1016/j.jhazmat.2019.121322>
- [30] L. Mahajan, S. Bhagat, Machine learning approaches for predicting compressive strength of concrete with fly ash admixture, *Res. Eng. Struct. Mater. (jresm.org)* (2022)
- [31] H. Song, A. Ahmad, F. Farooq, K.A. Ostrowski, M. Maślak, S. Czarniecki, F. Aslam, Predicting the compressive strength of concrete with fly ash admixture using machine learning algorithms, *Constr. Build. Mater.* 308 (2021) 125021. <https://doi.org/10.1016/j.conbuildmat.2021.125021>
- [32] M.M. Roshani, S.H. Kargar, V. Farhangi, M. Karakouzian, Predicting the Effect of Fly Ash on Concrete's Mechanical Properties by ANN, *Sustainability* 13 (3) (2021) 1469. <https://doi.org/10.3390/su13031469>
- [33] Y. Jiang, H. Li, Y. Zhou, Compressive Strength Prediction of Fly Ash Concrete Using Machine Learning Techniques, *Buildings* 12 (5) (2022) 690. <https://doi.org/10.3390/buildings12050690>
- [34] K. Khan, A. Ahmad, M.N. Amin, W. Ahmad, S. Nazar, A.M. Abu Arab, Comparative Study of Experimental and Modeling of Fly Ash-Based Concrete, *Mater.* 15 (11) (2022) 3762. <https://doi.org/10.3390/ma15113762>
- [35] A. Ghorbani, A New Estimation Approach for Fly Ash Incorporated High Strength Concrete Using Artificial Neural Network, *J. Struct. Constr. Eng. (JSECC)* 10 (4) (2023) 133–149. (in Persian)
- [36] M.N. Al-Hashem, M.N. Amin, M. Raheel, K. Khan, H.A. Alkadhim, M. Imran, Sh. Ullah, M. Iqbal, Predicting the Compressive Strength of Concrete Containing Fly Ash and Rice Husk Ash Using ANN and GEP Models, *Mater.* 15 (21) (2022) 7713. <https://doi.org/10.3390/ma15217713>
- [37] P.K. Mehta, O.E. Gj¸rv, Properties of portland cement concrete containing fly ash and condensed silica-fume, *Cem. Concr. Res.* 12 (5) (1982) 587–595. [https://doi.org/10.1016/0008-8846\(82\)90019-9](https://doi.org/10.1016/0008-8846(82)90019-9)
- [38] T.C. Hansen, Long-term strength of high fly ash concretes, *Cem. Concr. Res.* 20 (2) (1990) 193–196. [https://doi.org/10.1016/0008-8846\(90\)90071-5](https://doi.org/10.1016/0008-8846(90)90071-5)
- [39] C.D. Atis, High-volume fly ash concrete with high strength and low drying shrinkage, *J. Mater. Civ. Eng.* 15 (2) (2003) 153–156. [https://doi.org/10.1061/\(ASCE\)0899-1561\(2003\)15:2\(153\)](https://doi.org/10.1061/(ASCE)0899-1561(2003)15:2(153))
- [40] W. Chalee, T. Cheewaket, C. Jaturapitakkul, Utilization of fly ash concrete in marine environment for long term design life analysis, *Mater. Des.* 31 (2010) 1242–1249. <https://doi.org/10.1016/j.matdes.2009.09.024>
- [41] M.H. Liu, Y.F. Wang, Prediction of the Strength Development of Fly Ash Concrete, *Adv. Mater. Res.* 150–151 (2011) 1026–1033. <https://doi.org/10.4028/www.scientific.net/AMR.150-151.1026>
- [42] J. Pitroda, Prediction of strength for fly ash cement concrete through soft computing approaches, *Int. J. Adv. Res. Eng. Sci. Manag.* 1 (2014) 1–11.
- [43] P. Chopra, R.K. Sharma, M. Kumar, Prediction of Compressive Strength of Concrete Using Artificial Neural Network and Genetic Programming, *Adv. Mater. Sci. Eng.* 2016 (2016) 7648467. <https://doi.org/10.1155/2016/7648467>
- [44] T. Fantu, G. Alemayehu, G. Kebede, Y. Abebe, S.K. Selvaraj, V. Paramasivam, Experimental investigation of compressive strength for fly ash on high strength concrete C-55 grade, *Mater. Today Proc.* 46 (2021) 7507–7517. <https://doi.org/10.1016/j.matpr.2021.01.213>
- [45] A. Alaj, V. Krelani, T. Numao, Effect of Class F Fly Ash on Strength Properties of Concrete, *Civ. Eng. J.* 9 (9) (2023) 2249–2258. <https://doi.org/10.28991/CEJ-2023-09-09-011>
- [46] N. Kabay, M.M. Tufekci, A.B. Kizilkanat, D. Oktay, Properties of concrete with pumice powder and fly ash as cement replacement materials, *Constr. Build. Mater.* 85 (2015) 1–8. <https://doi.org/10.1016/j.conbuildmat.2015.03.026>
- [47] F. Farooq, W. Ahmed, A. Akbar, F. Aslam, R. Alyousef, Prediction of Compressive Strength of Fly Ash Based Concrete Using Individual and Ensemble Algorithm, *Mater.* 14 (4) (2021) 794. <https://doi.org/10.3390/ma14040794>
- [48] A.K. Saha, Effect of class F fly ash on the durability properties of concrete, *Sustain. Environ. Res.* 28 (1) (2018) 25–31. <https://doi.org/10.1016/j.serj.2017.09.001>
- [49] S.A. Hosseini, A. Jabari Khamaneh, S.S. Hosseini, Experimental investigation of the effect of different percentages of fly ash and water-to-cement ratio on the compressive strength of concrete, in: *Proc. 8th Natl. Congr. Civ. Eng., Babol, Iran, 2014.* (in Persian)
- [50] M.N. Al-Hashem, M.N. Amin, M. Raheel, K. Khan, H.A. Alkadhim, M. Imran, Sh. Ullah, M. Iqbal, Predicting the Compressive Strength of Concrete Containing Fly Ash and Rice Husk Ash Using ANN and GEP Models, *Mater.* 15 (21) (2022) 7713. <https://doi.org/10.3390/ma15217713>
- [51] S. Silva, GPLAB: A Genetic Programming Toolbox for MATLAB, (2007).
- [52] H. Hakimi Khansar, J. Parsa, O. Momeni Keleshteri, N. Karami, M. Khoshdel Sangdeh, Extended Estimation of daily inflow of Sefidroud dam using meta-heuristic algorithms combined with fuzzy neural inference system, *Amirkabir J. Civ. Eng.* 56 (1) (2024) 3–6. <https://doi.org/10.22060/ceej.2024.21634.7784>
- [53] H. Citakoglu, M. Cobaner, T. Haktanir, O. Kisi, Estimation of monthly mean reference evapotranspiration in Turkey, *Water Resour. Manag.* 28 (1) (2014) 99–113. <https://doi.org/10.1007/s11269-013-0474-1>
- [54] Q. Zhou, F. Zhu, X. Yang, F. Wang, B. Chi, Z. Zhang, Shear capacity estimation of fully grouted reinforced concrete masonry walls using neural network and adaptive neuro-fuzzy inference system models, *Constr. Build. Mater.* 153 (2017) 937–947. <https://doi.org/10.1016/j.conbuildmat.2017.07.171>
- [55] N. Safaeian Hamzehkolaei, F. MiarNaeimi, A new hybrid multi-level cross-entropy-based moth-flame optimization algorithm, *Soft Comput.* 25 (21) (2021) 14245–14279. <https://doi.org/10.1007/s00500-021-06109-1>
- [56] N. Safaeian Hamzehkolaei, N. Kadkhoda, An efficient ranked Voronoi diagram-based hybrid method for reliability-based structural analysis and design optimization, *Soft Comput.* 27 (19) (2023) 13889–13910. <https://doi.org/10.1007/s00500-023-08450-z>
- [57] M. Amiri, H. Bakhshandeh Amnieh, M. Hasanipanah, L. Mohammad Khanli, A new combination of artificial neural network and K-nearest neighbors models to predict blast-induced ground vibration and air-overpressure, *Eng. Comput.* 32 (4) (2016) 631–644. <https://doi.org/10.1007/s00366-016-0442-5>
- [58] D.A. Salas, A.D. Ramirez, C.R. Rodríguez, D.M. Petroche, A.J. Boero, J. Duque-Rivera, Environmental impacts, life cycle assessment and potential improvement measures for cement production: a literature review, *J. Clean. Prod.* 113 (2016) 114–122. <https://doi.org/10.1016/j.jclepro.2015.11.078>
- [59] S. Moosazadeh, E. Namazi, H. Aghababaei, A. Marto, H. Mohamad, M. Hajihassani, Prediction of building damage induced by tunnelling through an optimized artificial neural network, *Eng. Comput.* 35 (2) (2019) 579–591. <https://doi.org/10.1007/s00366-018-0615-5>
- [60] J.J. Moré, The Levenberg–Marquardt algorithm: Implementation and theory, *Lect. Notes Math.* 630 (1978) 105–116. <https://doi.org/10.1007/BFb0067700>
- [61] J. Li, J.-h. Cheng, J.-y. Shi, F. Huang, Brief Introduction of Back Propagation (BP) Neural Network Algorithm and Its Improvement, in: D. Jin, S. Lin (Eds.), *Advances in Computer Science and Information Engineering, Advances in Intelligent and Soft Computing*, vol. 169, Springer, Berlin, Heidelberg, 2012. https://doi.org/10.1007/978-3-642-30223-7_87
- [62] F. Girosi, T. Poggio, Networks and the Best Approximation Property, *Biol. Cybern.* 63 (3) (1990) 169–176. <https://doi.org/10.1007/BF00195855>
- [63] E.J. Hartman, J.D. Keeler, J.M. Kowalski, Layered Neural Networks with Gaussian Hidden Units as Universal Approximations, *Neural Comput.* 2 (2) (1990) 210–215. <https://doi.org/10.1162/neco.1990.2.2.210>

- [64] J. Park, I.W. Sandberg, Universal approximation using radial-basis-function networks, *Neural Comput.* 3 (2) (1991) 246–257. <https://doi.org/10.1162/neco.1991.3.2.246>
- [65] J. Park, I.W. Sandberg, Approximation and radial-basis-function networks, *Neural Comput.* 5 (2) (1993) 305–316. <https://doi.org/10.1162/neco.1993.5.2.305>
- [66] J. Moody, C.J. Darken, Fast learning in networks of locally-tuned processing units, *Neural Comput.* 1 (2) (1989) 281–294. <https://doi.org/10.1162/neco.1989.1.2.281>
- [67] F. Girosi, T. Poggio. Networks and the best approximation property. *Biol. Cybern.*, vol. 63, pp. 169–176, (1990). <https://doi.org/10.1007/BF00195855>
- [68] S. Lee, R.M. Kil, A Gaussian potential function network with hierarchically self-organizing learning, *Neural Netw.* 4 (2) (1991) 207–224. [https://doi.org/10.1016/0893-6080\(91\)90005-P](https://doi.org/10.1016/0893-6080(91)90005-P)
- [69] M.J. Er, S. Wu, J. Lu, H.L. Toh, Face recognition with radial basis function (RBF) neural networks, *IEEE Trans. Neural Netw.* 13 (3) (2002) 697–710. <https://doi.org/10.1109/TNN.2002.1000134>
- [70] A.Gh. Dehvari, M. Miri, M.R. Sohrabi, Determining Optimum Percent of Recycled Coarse Aggregates used in Corrosive Environment Based on Kriging Model, *Amirkabir J. Civ. Eng.* 53 (3) (2021) 197–200. <https://doi.org/10.22060/ceej.2019.16560.6299>
- [71] D.R. Jones, M. Schonlau, W.J. Welch, Efficient global optimization of expensive black-box functions, *J. Glob. Optim.* 13 (4) (1998) 455–492. <https://doi.org/10.1023/A:1008306431147>
- [72] F.A.C. Viana, T.W. Simpson, V. Balabanov, Metamodeling in Multidisciplinary Design Optimization: How Far Have We Really Come?, *AIAA J.* 52 (4) (2014) 670–690. <https://doi.org/10.2514/1.J052375>
- [73] A. Dumas, B. Echard, N. Gayton, O. Rochat, J.-Y. Dantan, S. Van Der Veen, AK-ILS: An Active learning method based on Kriging for the Inspection of Large Surfaces, *Precis. Eng.* 37 (1) (2013) 1–9. <https://doi.org/10.1016/j.precisioneng.2012.07.007>
- [74] Q. Guo, Y. Liu, Y. Zhao, B. Li, Q. Yao, Improved resonance reliability and global sensitivity analysis of multi-span pipes conveying fluid based on active learning Kriging model, *Int. J. Press. Vessels Pip.* 170 (2019) 92–101. <https://doi.org/10.1016/j.ijpvp.2019.01.016>
- [75] A.K. Al-Shamiri, J.H. Kim, T.F. Yuan, Y.S. Yoon, Modeling the compressive strength of high-strength concrete: An extreme learning approach, *Constr. Build. Mater.* 208 (2019) 204–219. <https://doi.org/10.1016/j.conbuildmat.2019.02.165>
- [76] M. Shariati, D.J. Armaghani, M. Khandelwal, J. Zhou, M. Khorami, Assessment of Longstanding Effects of Fly Ash and Silica Fume on the Compressive Strength of Concrete Using Extreme Learning Machine and Artificial Neural Network, *J. Adv. Eng. Comput.* 5 (1) (2021) 50. <https://doi.org/10.25073/jaec.202151.308>
- [77] Y. Moodi, M. Ghasemi, S.R. Mousavi, Estimating the compressive strength of rectangular fiber reinforced polymer-confined columns using multilayer perceptron, radial basis function, and support vector regression methods, *J. Reinf. Plast. Compos.* 41 (3–4) (2022) 130–146. <https://doi.org/10.1177/07316844211050168>
- [78] I.M. Nikbin, S. Rahimi, H. Allahyari, A new empirical formula for prediction of fracture energy of concrete based on the artificial neural network, *Eng. Fract. Mech.* 186 (2017) 466–482. <https://doi.org/10.1016/j.engfracmech.2017.11.010>

پیوست ۱

مقاومت فشاری (MPa)	سن	ریزدانه (kg/m ³)	درشت دانه (kg/m ³)	فوق روان کننده (kg/m ³)	آب (kg/m ³)	خاکستر بادی (kg/m ³)	سیمان (kg/m ³)	تعداد نمونه	مرجع
۱۰۳-۴۷/۷	۳-۱۰۰	۸۵۲/۱-۸۷۰/۳	۹۴۷/۰۴-۹۶۷/۰۸	۴/۴-۴/۵	۱۸۹/۲-۱۹۷/۸	۹۴/۵-۹۶/۶	۲۲۲/۳-۲۳۳/۸	۷	[۲۰]
۳۳-۵۳	۲۸	۵۱۴-۶۵۳	۱۲۳۳-۱۳۱۴	.	۱۶۲-۱۸۱	۴۰-۲۲۶	۱۶۲-۳۱۴	۱۵	[۲۲]
۲۴-۴۸/۹	۲۸	۵۳۶-۵۸۹	۱۱۳۲	.	۱۷۴/۲۵-۹۲/۲۵	۶۱/۵-۲۲۵/۵	۱۸۴/۵-۳۴۸/۵	۴	[۲۳]
۲۰-۴۲/۷	۲۸	۱۰۳۲-۱۲۹۳	۴۴۶-۵۵۸	.	۲۱۶-۲۵۵	۳۰-۱۸۵	۲۰۰-۳۲۰	۲۴	[۲۴]
۱۰۶-۷۳/۲	۳-۹۰	۶۹۰/۱-۹۰۸/۵	۸۰۴/۱-۱۱۲۱/۱	۰-۱۸/۲	۱۴۰/۸-۲۲۰/۲	۹۲/۶-۱۶۸/۸	۱۳۵/۹-۳۷۵/۸	۱۰۰	[۲۵]
۷۲/۱-۹/۵	۳-۹۰	۶۸۷-۹۰۵/۴	۸۰۱-۱۱۱۸	۰-۱۸	۱۴۱/۱-۲۲۰/۵	۹۲/۱-۱۶۸/۳	۱۳۶/۱-۳۷۶	۹۸	[۳۱]
۱۳/۴-۵۰	۲۸	۳۴۲-۱۱۴۶	۴۹۵-۱۴۱۹	.	۱۴۴-۲۳۶	۵۵-۱۴۶	۱۰۷-۳۷۹	۶	[۳۳]
۵/۸-۱۳/۱	۲۸	۸۰۵-۹۰۵	۱۱۶۰-۱۱۸۰	.	۱۴۰-۱۶۰	۷۰-۱۸۰	۱۰۵-۱۳۵	۱۶	[۳۷]
۸/۴-۲۵/۴	۲۸	۵۷۰-۶۴۴	۱۳۲۲-۱۳۳۴	.	۱۵۴	۱۴۶	۸۳-۱۶۷	۵	[۳۸]
۳۰/۵-۶۶/۵	۲۸	۶۰۰	۱۲۰۰	.	۱۱۶-۱۲۰	۲۰۰-۲۸۰	۱۲۰-۲۰۰	۲	[۳۹]
۱۶/۶-۴۷/۴	۲۸	۶۳۹	۸۴۰-۱۰۰۴	.	۲۱۵-۳۱۱	۷۲-۲۳۹	۲۳۹-۴۰۶	۱۲	[۴۰]
۴۳/۷-۵۴/۳	۲۸	۷۲۹-۸۴۲	۹۸۸-۱۰۵۰	.	۱۷۲-۱۷۵	۹۰-۱۴۴	۲۹۶-۲۹۰	۲	[۴۱]
۲۱/۶-۳۸/۲	۲۸	۳۴۱/۹۱	۱۴۱۹/۳	.	۱۰۸-۱۶۲	۴۷/۳-۱۸۹/۴	۲۸۴/۲-۴۲۶/۳	۴	[۴۲]
۳۵/۲-۴۸/۴	۲۸	۴۱۶/۵-۶۲۵/۵	۶۵۶/۶-۱۲۲۸/۵	.	۱۷۸/۵-۲۲۹/۵	۶۰-۷۱/۲۵	۴۰۰-۴۷۵	۲۷	[۴۳]
۳۳-۶۴/۱	۷-۲۸	۵۸۱/۷۶	۱۰۹۳/۶۵	.	۱۶۳/۷	۲۵/۶-۱۵۲/۶	۳۵۸/۴-۴۸۶/۴	۱۸	[۴۴]
۴/۱-۷۴/۱	۳-۶۲۵	۷۷۱-۷۸۷	۹۴۳-۹۶۱	۰-۴/۴	۱۷۶-۲۱۱/۶	۳۴-۱۳۲	۲۳۸-۳۹۶	۸۵	[۴۵]
۵۵-۹۰	۷-۱۸۰	۹۴۴/۱	۷۸۷/۹	۷/۵	۲۱۰	۵۰-۱۰۰	۴۰۰-۴۵۰	۸	[۴۶]
۱۵/۳-۶۶/۴	۳-۱۰۰	۸۱-۸۹۹/۸	۹۵/۱-۱۰۹۸	۰-۲۰	۱۴۲-۲۱۰	۵۹-۱۴۲	۵۵-۵۰۵	۷۰	[۴۷]
۲۸-۵۹	۷-۳۶۰	۷۰۰	۱۲۰۰	۴	۱۴۰	۴۰-۱۶۰	۲۴۰-۳۶۰	۲۴	[۴۸]
۱۵/۲-۶۱	۷-۴۲	۲۶/۸۵	۳۷/۳۸	.	۷/۸۴	۰/۸۶-۳/۴۶	۱۲/۴۶-۱۶/۴۴	۷۲	[۴۹]

Prediction of Compressive Strength of Fly Ash Concrete Using Machine Learning Models

Elahe Moazeni¹, Yaser Moodi^{2*}

¹ Master's student, Sirjan Industrial University

² Assistant Professor, Sirjan Industrial University

ABSTRACT

Fly ash is produced as a byproduct of the coal combustion process in thermal power plants. Fly ash consists of very fine and microscopic particles, typically composed of mineral compounds such as silicon dioxide, aluminum oxide, and iron oxide. These compounds make fly ash suitable for use in various industries, particularly in the construction industry. Applications of fly ash include additives in concrete, fillers in asphalt, production of bricks and concrete blocks, and pollutant absorption. As a pozzolanic material, fly ash helps reduce carbon dioxide emissions in the cement production process. In this study, a comprehensive database of previous studies on fly ash concrete was initially collected. This data included 599 samples from credible laboratory studies. The gathered dataset consisted of various input variables, including the water-to-cement ratio, amount of fly ash, cement content, coarse aggregate amount, fine aggregate amount, superplasticizer content, and curing age of the concrete. To predict the compressive strength of the concrete, various machine learning algorithms were utilized, including Genetic Programming (GP), Adaptive Neuro-Fuzzy Inference System (ANFIS), Multi-Layer Perceptron (MLP), Radial Basis Function Neural Network (RBF), Kriging, and Extreme Learning Machine (ELM). Furthermore, the accuracy of each model was evaluated using statistical indices, and the best model was identified. The results show that different machine learning models exhibit varying performances in predicting compressive strength. In particular, the Kriging method, with a correlation coefficient of 0.96, was selected as the best model.

KEYWORDS

Concrete, Fly Ash, Compressive Strength, Prediction Model, Machine Learning Techniques.

* y.moodi.civil@sirjantech.ac.ir