

پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی خاکستر پوسته برنج با استفاده از مدل‌های داده مینا

محمدجواد طاهری امیری^۱، علی اشرفیان^{۲*}، فرشیدرضا حقیقی^۳، مائده جواهری بارفروشی^۴

- ۱- استادیار گروه عمران موسسه آموزش عالی پردیسان، مازندران
- ۲- کارشناس ارشد مهندسی و مدیریت، ساخت موسسه آموزش عالی طبری بابل
- ۳- استادیار گروه عمران، دانشگاه صنعتی نوشیروانی بابل
- ۴- دانشجوی دکتری مهندسی و مدیریت ساخت دانشگاه آزاد اسلامی واحد اراک

ali_ashrafian@yahoo.com

تاریخ پذیرش [۹۷/۱۲/۲۲]

تاریخ دریافت [۹۷/۰۵/۲۲]

چکیده

ساخت و نگهداری روکش‌های بتنی از مسائل مهم و پرهزینه در دهه اخیر بوده است. از این رو، استفاده از بتن خودتراکم به عنوان بتنی با ویژگی‌های مقاومتی مطلوب و آلاینده‌گی پایین مورد توجه قرار گرفته است. خواص مقاومتی بتن خودتراکم به فاکتورهای مهمی از نسبت‌های اختلاط وابسته بوده که لزوم پژوهش‌های آزمایشگاهی و آنالیزهای کامپیوتری هوشمند در ساخت آن را نمایان ساخته است. تعیین میزان بهینه مواد تشکیل‌دهنده بتن به منظور رسیدن به مقاومت مطلوب، صرفه‌جویی در تعداد دفعات آزمایش و کاهش هزینه‌های انجام آزمایش‌ها ارائه مدل‌های رگرسیونی محاسباتی برای تخمین خواص مقاومتی بتن را مورد توجه قرار داده است. هدف اصلی در این مطالعه ارائه رابطه‌ای محاسباتی برای تخمین مقاومت فشاری بتن خودتراکم حاوی خاکستر پوسته برنج (RHA) با استفاده از رویکرد قدرتمندی به نام برنامه‌نویسی بیان ژن (GEP) است. برای ارزیابی عملکرد مدل پیشنهادی GEP مطالعه‌ای مقایسه‌ای با استفاده از روش‌های کلاسیک مدل‌سازی داده مبنای شبکه عصبی مصنوعی (ANN) و رگرسیون خطی چندگانه (MLR) نیز انجام شد. مجموعه داده‌های قابل اطمینان و مناسبی شامل ۱۵۶ نمونه مقاومت فشاری حاوی RHA از مقالات معتبر جمع‌آوری و استفاده شد. عملکرد مدل‌های پیشنهادی ارائه شده با استفاده از شاخص‌های خطای ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) محاسبه و ارزیابی شد. نتایج شاخص‌های خطا در ارزیابی عملکرد مدل‌های توسعه داده شده نشان داد روش GEP دقت قابل توجه و مقادیر خطای کمتری در محاسبه داشته است. همچنین رابطه محاسباتی براساس عبارات بیان ژنی در روش GEP برای پیش‌بینی مقاومت فشاری در سنین مختلف ارائه شد که با شاخص همبستگی ۰/۹۴ و مقادیر خطای ۴- ۵ مگاپاسکال دقت قابل توجهی را نشان داده است. رابطه ارائه شده به آسانی می‌تواند برای پیش‌طراحی نسبت‌های اختلاط و همچنین کنترل سریع راه‌حل‌هایی قطعی مورد استفاده قرار گیرد. تحلیل حساسیت برای مشخص کردن مقادیر تاثیرگذار در مدل مقاومت فشاری ارائه شده نشان داد، متغیر چسباننده در این مدل‌سازی نسبت‌های اختلاط بیشترین تاثیر عملکردی را ایفا نموده است.

کلمات کلیدی: بتن خودتراکم، برنامه نویسی بیان ژن، شبکه عصبی مصنوعی، رگرسیون خطی چندگانه، مقاومت فشاری، پیش‌بینی

۱- مقدمه

بتن خودتراکم یکی از گام‌های رو به جلو در زمینه بتن است. این بتن پدیده جدیدی در علم مصالح ساختمانی است که تقریباً سه دهه از عمر آن می‌گذرد. پیدایش فوق‌روان‌کننده‌ها به عنوان نوع جدیدی از افزودنی‌ها زمینه را برای ظهور بتن خودتراکم فراهم کرده است. بتن خودتراکم شاخه جدید بتن با مقاومت متوسط به بالا است که بدون نیاز به ویرنه کردن و تحت وزن خود داخل قالب را پر می‌کند [1]. در اوایل دهه هشتاد میلادی به دنبال کاهش نیروی کار ماهر در صنعت ساخت و ساز ژاپن و تراکم نامناسب ناشی از افزایش حجم آرماتورهای مصرفی باعث کاهش کیفیت کارهای اجرایی شد [2]. نظر به اینکه با رشد روزافزون جمعیت در دنیا و افزایش نیازهای آدمی، روز به روز بر میزان ضایعات صنعتی و کشاورزی افزوده می‌شود، پس یکی از صنایعی که امکان بهره‌وری از این ضایعات را فراهم می‌کند، صنعت ساختمان است. در این پژوهش به بررسی نقش کاربرد پسته برنج (زایده‌ای کشاورزی) و خاکستر آن (به عنوان ماده‌ای پوزولانی دارای سیلیس فعال) در صنعت ساختمان پرداخته شده است. افزودن مناسب خاکستر پسته برنج به عنوان ماده‌ای پوزولانی، در بالا بردن دوام بتن در برابر محیط اسیدی و نیز کاهش خرابی آرماتورهای بتن آرمه موثر بوده و همچنین نقش چشمگیری در تثبیت خاک و ساخت بلوک‌های سیمانی و بتنی و حتی در ساخت آجر و بتن‌های عایق سبک دارد [3]. [4] در سال‌های اخیر، مواد جدید و فن‌آوری‌های ساخت نوین در بتن به وجود آمده که تعداد پارامترهای موثر در نسبت‌های اختلاط بتن را تا دو برابر افزایش می‌دهد بر این اساس مدل‌هایی مبتنی بر روش‌های هوش مصنوعی ساخته شده از داده‌های آزمایشگاهی مورد توجه پژوهشگران شاخه-های گوناگون قرار گرفته است. روش‌هایی کلاسیک مدلسازی از جمله رگرسیون چندگانه خطی (MLR) و شبکه‌های عصبی مصنوعی (ANNs) با قابلیت حل مسائل مسایل تکنولوژی بتن مورد توجه پژوهشگران بوده است. چن [5] از روش MLR برای پیش‌بینی مقاومت فشاری با استفاده از خواص فیزیکی استفاده نمود. براین اساس پنج سری ترکیب

ورودی از متغیرهای مورد بررسی با استفاده از این روش بررسی و نتایج در غالب شاخص‌های خطا بررسی شد. قابلیت روش شبکه عصبی مصنوعی برای تخمین خواص بتن مورد ارزیابی سونبی و همکاران [6] و سیپوس و همکاران [7] قرار گرفت. آنها گزارش کردند روش شبکه عصبی، جایگزینی برای برنامه آزمایشگاهی برای پیش‌بینی خواص سخت شده و تازه خواهد بود. همچنین ونگ و همکاران [8] از دو روش شبکه عصبی مصنوعی، رگرسیون چندگانه خطی برای تخمین گسترش رفتار بتن استفاده و نتایج آن را در غالب تحلیل‌های آماری ارائه کردند. روش‌های کلاسیک داده مینا، قابلیت ارائه روابط منتج از خروجی را نداشته‌اند. از این روش‌های نوین مدلسازی مانند برنامه‌نویسی بیان ژن (GEP) با قابلیت ارائه فرمول‌هایی با دقت بالا مورد استفاده پژوهشگران قرار گرفته است [9]. غلامپور و همکاران [10] با جمع‌آوری مجموعه داده‌هایی از بتن بازیافتی و توسعه روش GEP، روابط محاسباتی برای پیش‌بینی خواص این نوع بتن از جمله مقاومت فشاری، مقاومت کششی و مدول الاستیسیته ارائه نمودند. در این مطالعه برای پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی پودر خاکستر پسته برنج از روش GEP به عنوان ابزاری با اطمینان بالا استفاده و با روش‌های کلاسیک مدلسازی از جمله ANN و MLR بصورت کمی و کیفی مقایسه صورت پذیرفت.

۲- روش‌شناسی

۲-۱- معرفی رگرسیون چندگانه خطی

آنالیز رگرسیون روشی آماری برای محاسبه و یافتن رابطه بین یک متغیر وابسته با یک یا چند متغیر وابسته است. آنالیز رگرسیون به فهم چگونگی تغییر یک متغیر وابسته زمانی که هر یک از متغیرهای مستقل آن تغییر می‌کنند در حالی که سایر متغیرهای وابسته ثابت هستند، کمک می‌کند. در بیشتر موارد، هدف از آنالیز رگرسیون محاسبه تابعی از متغیرهای مستقل برای پیش‌بینی متغیر وابسته است [11, 12]. آنالیز رگرسیون امروزه به صورت گسترده برای پیش‌بینی استفاده می‌شود. تکنیک‌های زیادی برای انجام آنالیز رگرسیون وجود

است که برای جلوگیری از ایجاد افراد معیوب از نظر قواعد، برخی عملیات بدون نقص را اجرا می‌نماید. در این مدل از ترکیب تک نقطه‌ای، دو نقطه‌ای و ژنی استفاده می‌شود [17]. از آن جایی که ترکیب دو نقطه‌ای قادر است نواحی کدگذاری نشده داخل کروموزوم‌ها را به دفعات بیشتری روشن و خاموش کند، مطلوب‌تر است. در این روش، پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و ترمینال‌ها، مدل‌سازی می‌شوند. در این پژوهش برای به کارگیری مدل برنامه‌نویسی بیان ژن از نرم‌افزار *GeneXpro tools 5.0* استفاده شد.

۳- مجموعه داده‌های استفاده شده در

این پژوهش

برآورد مقاومت فشاری بتن خود تراکم حاوی خاکستر پوسته برنج با استفاده از مدل‌های مذکور نیازمند مجموعه‌ای از داده‌های آزمایشگاهی مختلف است. بدین منظور ۱۵۶ سری داده آزمایشگاهی برای مدل‌سازی مقاومت فشاری بتن خودتراکم حاوی خاکستر پوسته برنج از پژوهش‌های ساکر [19]، گانسان و همکاران [20]، بوی و استون [21] و رمضانیانپور و همکاران [22] جمع‌آوری شده است که از کل داده‌ها به ترتیب ۷۵٪ و ۲۵٪ برای اجرای مراحل آموزش و تست در نظر گرفته شده است. مصالح مورد استفاده برای ساخت نمونه‌ها، شامل ریزدانه (FA)، درشت دانه (CA)، سیمان (C)، خاکستر پوسته برنج (RHA)، فوق‌روان‌کننده (SP) و آب (W) است.

برای هر نسبت‌های اختلاط، تعدادی نمونه آزمایشی ساخته شده و مقاومت‌های ۱، ۳، ۷، ۲۸، ۵۶ و ۹۰ روزه از بتن مذکور، اندازه‌گیری شده است. همچنین در جدول (۱) محدوده داده‌های مورد استفاده، در این پژوهش ارائه شده است. تعداد پایگاه داده‌های مورد مطالعه برای توسعه مدل‌های داده مینا نقش اساسی در اعتمادپذیری مدل‌های توسعه داده شده دارد. همچنین برای ارزیابی مجموعه داده‌های جمع‌آوری شده تحلیل‌های آماری در غالب کنترل بیشینه و کمینه، میانگین و انحراف معیار متغیرها برای تحلیل کیفیت داده‌های استفاده شده انجام شد که در جدول (۲) ارائه شده است.

دارد. روش‌های رگرسیون خطی و رگرسیون کمترین مربعات از پرکاربردترین این روش‌ها هستند. سبحانی [13] در تعریف آنالیز رگرسیون این گونه بیان می‌دارد که رگرسیون خطی شکلی از آنالیز رگرسیون است که رابطه بین یک یا چند متغیر مستقل و وابسته مدل شده با یک معادله رگرسیون خطی را نشان می‌دهد، در حالی که هدف کلی از رگرسیون غیرخطی پیدا کردن یک معادله غیرخطی مناسب برای این رابطه است.

۲-۲- معرفی شبکه عصبی مصنوعی

شبکه عصبی مصنوعی پرسپترون توسط فرانک روزنبلت در سال ۱۹۵۸ میلادی ابداع شد [14]. این شبکه‌ها دارای سه لایه ورودی، پنهان و خروجی می‌شوند. در شبکه‌های عصبی پیش‌خور سیگنال‌های ورودی از واحدهای ورودی به سمت واحدهای خروجی در جریان هستند [15]. تعداد عصب‌های موجود در لایه ورودی و خروجی به ترتیب در ارتباط مستقیم با تعداد پارامترهای ورودی و خروجی است. برای تعیین تعداد عصب‌ها در لایه خروجی قانون و اصول مدونی تاکنون طرح نشده است و این تعداد با توجه به پیچیدگی مسئله و آزمون و خطا به دست می‌آید [16]. برای کمینه کردن مقدار خطا وزن‌های بین اعصاب از لایه آخر به سمت لایه ورودی به‌روز می‌شوند. این روند تا رسیدن به مقدار مطلوب خروجی تکرار می‌شود.

۲-۳- معرفی برنامه‌نویسی بیان ژن

برنامه‌نویسی بیان ژن توسط فریرا (۱۹۹۹) ارائه شد [17]. با توجه به اینکه GEP با استفاده از جمعیت افراد براساس تابع برازش، آنها را انتخاب می‌کند و به کمک یک یا چند عملگر ژنتیکی، عملیات ژنتیکی را معرفی می‌نماید، می‌توان گفت که یک الگوریتم ژنتیکی است. برنامه‌نویسی بیان ژن مانند الگوریتم ژنتیک عمل می‌کند، با این تفاوت که الگوریتم ژنتیک روی رشته‌های بیتی ولی برنامه‌نویسی بیان ژن از ساختار درختی برای تولید جواب بهینه استفاده می‌کند [18]. فریرا، در برنامه‌ریزی بیان ژن از عملگرهای مختلفی مانند جهش و ترکیب استفاده کرده است. ویژگی این عملگر آن

جدول ۱. محدوده متغیرهای آزمایشگاهی مورد استفاده

C'S	FA	CA	SP	RHA	W	C	AS	Variables
106.5	815	1324	7.34	134	340	550	90	Max
16.5	540	995	0	0	120	0	1	Min
28.92	608.26	1249.67	4.76	52.93	161.61	435.65	59.19	Mean
33.98	100.34	92.73	2.68	36.90	14.13	59.11	23.71	Standard deviation

Table1. Descriptive statistics of the used variables

شکل ۱. نمودار سری زمانی پیش‌بینی مقاومت فشاری بتن برای حالات بررسی شده

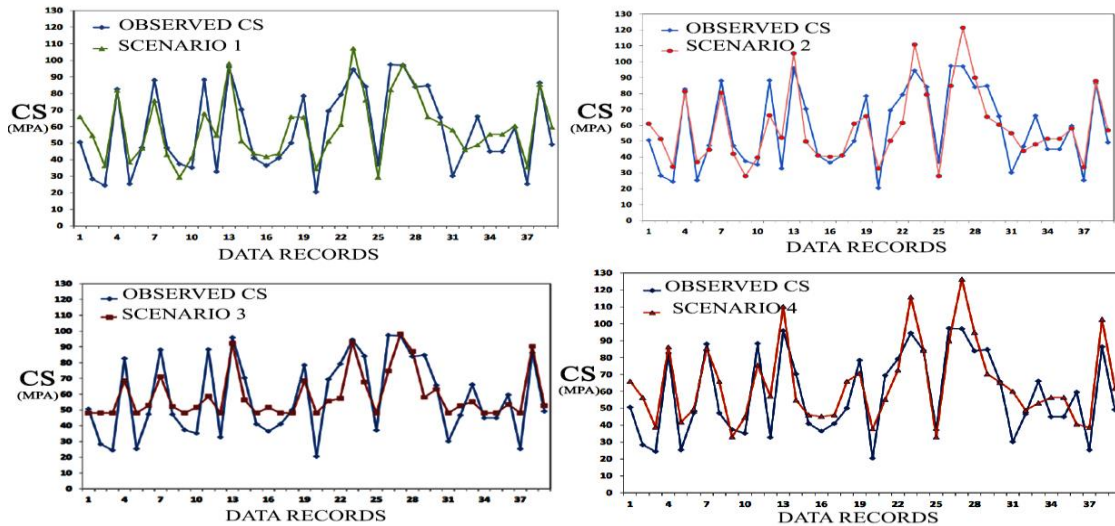


Fig. 1. Time series plots of the proposed scenarios

جدول ۲. شاخص‌های آماری مورد استفاده برای ارزیابی مدل‌ها

جدول ۲. شاخص‌های آماری مورد استفاده برای ارزیابی مدل‌ها

Equation	No.
$R = \frac{\sum_{i=1}^M (O_i - \bar{O}) \cdot (P_i - \bar{P})}{\sqrt{\sum_{i=1}^M (O_i - \bar{O})^2 \sum_{i=1}^M (P_i - \bar{P})^2}}$	(1)
$RMSE = \frac{\sum_{i=1}^M (P_i - O_i)^2}{M}$	(2)
$MAE = \frac{\sum_{i=1}^M P_i - O_i }{M}$	(3)

Table 2. Error measure used for models evaluation

۴- مقایسه و ارزیابی مدل‌های پیشنهادی

۴- مقایسه و ارزیابی مدل‌های پیشنهادی

در این پژوهش برای دستیابی به بهترین پارامترهای ورودی برای توسعه مدل‌های پیشنهادی، ۴ نوع چینش مختلف از پارامترهای ورودی پیشنهاد شده است که شامل پارامترها به صورت با بعد و بی بعد است. باید گفته شود که در نظر گرفتن این نوع چینش، با مطالعه متعدد در مقالات مدل‌سازی بتن‌ها حاوی هرگونه پوزولان، سرباره کوره‌ها، مواد مضاف، گوگرد، مواد افزودنی، پلیمرها، الیاف و غیره بدست آمده است. از همین رو، ۴ حالت پیشنهادی به صورت زیر معرفی می‌شود:

برای مقایسه عملکرد مدل‌های ارائه شده در مراحل آموزش و آزمایش، شاخص‌های آماری شامل ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) در جدول (۲) نشان داده شده است. که O_i مقدارهای مشاهده‌ای، P_i مقدارهای پیش‌بینی، \bar{O} میانگین داده‌های مشاهده‌ای، \bar{P} میانگین داده‌های پیش‌بینی و M تعداد داده‌ها است. همچنین مدل‌های توسعه داده شده با مدل‌های داده مبنای پژوهشگران دیگر نیز مقایسه و ارزیابی شد. از این رو، مدل‌های ارائه شده برای مقاومت فشاری بتن خودتراکم دوما و همکاران (۲۰۱۶)، کاوه و همکاران (۲۰۱۷)، الیچیا

(۱) مقاومت فشاری: آب، سیمان، ریزدانه، درشت‌دانه، فوق روان کننده، خاکستر پوسته برنج، سن نمونه،

۵-۲- توسعه مدل شبکه عصبی مصنوعی برای پیش‌بینی مقاومت فشاری بتن

پس از تعیین بهترین حالت پارامترهای ورودی، حال به مدلسازی بتن خود تراکم حاوی خاکستر پوسته برنج پرداخته می‌شود. در این پژوهش از شبکه عصبی چندلایه پرسپترون استفاده شده است. این شبکه دارای دولایه پنهان است که برای تعیین تعداد عصب بهینه در لایه‌های پنهان، ۱۰ مدل شبکه عصبی ساخته و مورد ارزیابی قرار گرفت. برای انجام این مهم بر تعداد عصب‌ها در لایه اول پنهان تک تک افزوده شد (۱-۱۰ عدد) و عملکرد هر مدل بررسی شد. برای آموزش شبکه عصبی از الگوریتم لونیگ-مارکواد استفاده شد. این الگوریتم اغلب سریع‌ترین الگوریتم پس انتشار خطا است و قویا به عنوان اولین انتخاب در الگوریتم‌های آموزش نظارت شده توصیه می‌شود. برای تعیین تابع تحریک مناسب در لایه پنهان و خروجی از توابع تانژانت سیگموئیدال، لگاریتم سیگموئیدال و خطی استفاده شد که بهترین نتیجه را تابع تانژانت سیگموئیدال در لایه پنهان و تابع خطی در لایه خروجی داده است. برای آموزش و آزمایش شبکه‌ها به ترتیب از ۷۵ درصد (۱۱۷ عدد) و ۲۵ درصد (۳۹ عدد) اطلاعات استفاده شده است که ارزیابی عملکرد هر مرحله در جدول (۴) ملاحظه می‌شود. همان‌گونه که از جدول‌های ارائه شده قابل استنباط است، ۴ عصب در لایه پنهان بهترین نتایج را در برداشته است و مدل $ann4$ بهترین مدل شبکه عصبی مصنوعی است. شکل (۲) معیارهای ارزیابی در هر مدل شبکه عصبی مصنوعی را در قالب نمودار نشان می‌دهد. ملاک تعیین مدل نهایی، عملکرد آن در مرحله آزمایش است. لازم به ذکر است که با هر بار آنالیز مدل شبکه عصبی مصنوعی در نرم-افزار متلب، وزن‌های متفاوتی به شبکه اختصاص داده می‌شود، در نتیجه با هر بار آنالیز جواب متفاوتی حاصل می‌شود. برای مرتفع کردن این مسئله برای هر مدل شبکه عصبی مصنوعی، ۵۰ بار با تغییرات متغیرهای بهینه تنظیمات کاربر آنالیز شده است و بهترین جواب به عنوان مدل نهایی انتخاب شده است. در این مطالعه مدل شبکه عصبی مصنوعی برگزیده دارای نرخ آموزش ۳٪، مومنتوم ۱٪ و تعداد تکرار ۵۰۰۰ بوده است.

۲) مقاومت فشاری: نسبت آب به سیمان، نسبت ریز دانه به درشت دانه، فوق روان کننده، خاکستر پوسته برنج، سن نمونه،

۳) مقاومت فشاری: آب، سیمان، نسبت ریزدانه به درشت دانه، نسبت فوق روان کننده به مجموع درشت دانه و ریزدانه، نسبت خاکستر پوسته برنج به سیمان، سن نمونه،

۴) مقاومت فشاری: نسبت آب به سیمان، نسبت ریزدانه به آب، نسبت درشت دانه به آب، نسبت فوق روان کننده به سیمان، نسبت خاکستر پوسته برنج به سیمان، سن نمونه.

در این پژوهش از رگرسیون خطی چندگانه برای تعیین بهترین حالت پارامترهای ورودی برای پیاده‌سازی مدل‌های پیشنهادی استفاده شده است. استفاده از رگرسیون خطی برای پیش‌بینی مقاومت‌های سنین مختلف بتن خودتراکم حاوی خاکستر پوسته برنج، مستلزم آموزش و تست شبکه با استفاده از داده‌های واقعی است.

خطاهای بسیار کم حاصل از این روش، نشان می‌دهد که استفاده از رگرسیون خطی، برای طرح اختلاط بتن خود تراکم، می‌تواند بسیار مفید باشد و تعداد آزمایش‌های لازم برای رسیدن به یک نسبت اختلاط بهینه را به حداقل برساند. با توجه به جدول (۳) که چهار حالت از پارامترهای ورودی مختلف و عملکردشان را نشان می‌دهد، حالت اول از این حالات دارای بهترین عملکرد است. در این حالت ضریب همبستگی با داشتن ۰/۹۲ و ریشه میانگین مربعات خطا $6/364$ بهترین دقت از پیش‌بینی مقاومت فشاری بتن خودتراکم را از میان دیگر حالت‌های تعریف شده، داشته است. بر این اساس، شکل (۱) چگونگی پیش‌بینی مقاومت فشاری بتن برای هر ۴ حالت پیشنهادی را برای مرحله آزمایش نشان می‌دهد که با توجه به مقادیر پیش‌بینی، حالت اول نشانگر دقت بالایی نسبت به ۳ حالت دیگر است.

جدول ۳. ارزیابی حالت‌های پیشنهادی انتخاب بهترین ترکیب ورودی

Inputs	Error measures		
	R	RMSE	MAE
Scenario 1	0.91	6.364	7.762
Scenario 2	0.89	7.524	7.968
Scenario 3	0.82	10.174	11.324
Scenario 4	0.85	9.275	9.596

Table 3. Evaluation of proposed scenarios for selection of the optimum input variables.

جدول ۴. معیارهای ارزیابی عملکرد شبکه عصبی در مرحله آموزش و آزمایش

	Training stage			Testing Stage		
	R	RMSE	MAE	R	RMSE	MAE
ann 1	0.680	15.59	16.62	0.601	15.59	16.62
ann 2	0.725	11.14	12.76	0.785	13.26	13.96
ann 3	0.934	5.26	5.89	0.921	7.54	8.26
ann 4	0.943	4.53	5.11	0.932	5.13	5.62
ann 5	0.920	5.37	5.76	0.920	6.42	6.89
ann 6	0.925	5.76	6.75	0.918	6.86	7.46
ann 7	0.930	4.86	5.34	0.898	7.10	7.86
ann 8	0.910	6.45	7.54	0.853	9.86	10.16
ann 9	0.925	6.35	7.64	0.856	8.46	9.52
ann 10	0.854	9.75	10.86	0.826	1.86	11.46

Table.4 Statistical indicators of the ANN models for training and testing stages

که هر چه این نقاط به خط صفر نزدیک باشد، بیانگر دقت بالای مدل است. با توجه به این شکل، نتایج نشان می‌دهد که عمده بازه خطای موجود در بازه ۸ و ۸- است.

جدول ۵. پارامترهای مربوط به برنامه‌نویسی بیان ژن

Parameters	Setting
Function set	+, -, ×, /, exp, power
Mutation rate	0.138
Inversion rate	0.546
One/two point recombination rate	0.277
Gene recombination rate	0.277
Gene transposition rate	0.277
Head size	6
Number of genes	3
Number of chromosomes	30

Table 5. Optimum parameter settings for GEP model

از این رو تلاش شد بر پایه پژوهش‌های پژوهشگران گذشته و تکرار سعی و خطا، بهترین ترکیب پارامترهای ورودی مدنظر قرار گیرد. با توجه به جدول (۵)، برای پیش‌بینی شکل (۴) درخت بیان ژن مدل توسعه داده شده مقاومت فشاری را نمایش داده که در آن مقادیر ضرایب ثابت در جدول ۶ گزارش شده است. در این بیان درختی، $d_0=C$ ، $d_1=RHA$ ، $d_2=W$ ، $d_3=SP$ ، $d_4=FA$ ، $d_5=CA$ و $d_6=AS$ می‌باشد که در آن C ، RHA ، W ، SP ، FA ، CA و AS به ترتیب بیانگر سیمان، خاکستر پسته برنج، آب، فوق روان کننده، ریزدانه، درشت دانه و سن نمونه است.

شکل ۲. معیارهای ارزیابی مدل‌های شبکه عصبی مصنوعی

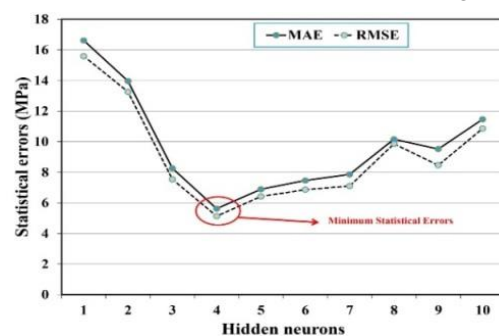


Fig. 2. Evaluation of the hidden neurons in ANN models

۳-۵- توسعه روش برنامه‌نویسی بیان ژن برای پیش‌بینی مقاومت فشاری بتن

در این پژوهش، از مدل برنامه‌ریزی بیان ژن برای تخمین مقاومت فشاری بتن حاوی خاکستر پسته برنج استفاده شده است. این مدل براساس یک سری از پارامترهای اولیه‌ای که برای آن مشخص شده، شروع به کار کرده و در نهایت براساس معیار توقف، متوقف می‌شود.

همانطور که در جدول (۵) مشخص است، مقادیر مربوط به هر پارامتر در برنامه‌نویسی بیان ژن نشان داده شده است. انتخاب مناسب‌ترین پارامترهای ورودی، اثر مستقیمی بر دقت و کارایی مدل پیشنهادی در تخمین مقاومت فشاری بتن حاوی خاکستر پسته برنج خواهد داشت.

مقاومت فشاری بتن حاوی خاکستر پسته برنج، بهترین تعداد افراد در هر نسل ۳۰ کروموزوم و مقدار تابع برازش ۶۳۳/۶۸ در نظر گرفته شد. همچنین، شکل (۳) میزان خطای پیش‌بینی شده با استفاده از روش برنامه‌نویسی بیان ژن نسبت به مقادیر مقاومت فشاری بتن خود تراکم در حالت آزمایشگاهی است

شکل ۴- بیان درختی روش برنامه‌نویسی بیان ژن

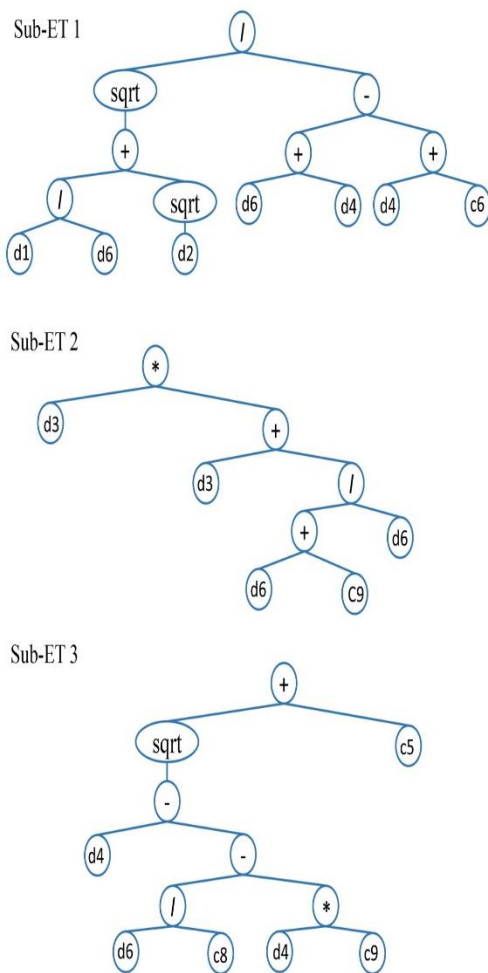


Fig. 4. Expression tree for the compressive strength

در این پژوهش، شکل‌های (۵) مقادیر مقاومت فشاری مشاهده‌ای و پیش‌بینی شده مانند آن توسط مدل پیشنهادی ANN، MLR و GEP را برای مراحل آموزش نشان می‌دهد. در یک مقایسه‌ی کیفی، بیشتر مقادیر مقاومت فشاری در روش GEP بر روی خط نیمساز متمرکز هستند و فقط تعداد اندکی از این نقاط خارج از منطقه تمرکز است. در صورتی که در روش MLR با بیشترین پراکندگی (خطا) روبرو هستیم که بیانگر دقت پایین روش رگرسیون خطی در مقابل دیگر روش‌های پیشنهادی بوده است. همچنین شکل (۶) مقدارهای مشاهده‌ای در آزمایشگاه و پیش‌بینی شده مانند آن در مرحله آزمایش را نشان می‌دهد که در این مرحله از مدلسازی نیز، روش برنامه‌نویسی بیان ژن با برتری نسبی نسبت به شبکه عصبی مصنوعی دارای دقت بالاتری است.

شکل ۳. توزیع خطای ایجاد شده در روش برنامه‌نویسی بیان ژن




Fig. 3. Error distribution of the GEP model

جدول ۶. مقادیر مربوط به ضرایب ثابت در روش GEP

G1C6	G2C9	G3C5	G3C8	G3C9	Numerical constant
3.494	-7.26	6.80	-0.234	7.90	Value

Table 6. Numerical constant of the developed GEP model

در نهایت نیز، بهترین رابطه پیشنهادی برای تخمین مقاومت فشاری بتن خود تراکم حاوی خاکستر پسته برنج در سنین مختلف با توجه به پارامترهای نام برده به صورت زیر است:

$$CS = \left\{ \left(\left(\frac{RHA}{c} \right) + W^{0.5} \right)^{0.5} \times ((AS + FA) - (FA + 3.49)^{-1}) \right\} + \{ SP \times (CA + (AS - 7.26)) \} + \left\{ \left(FA + \left(\frac{AS}{0.234} \right) - 7.9AS \right)^{0.5} + 6.8 \right\} \quad (4)$$

همان‌گونه که جدول (۷) نشان می‌دهد، ضریب همبستگی در مرحله آموزش برای رگرسیون خطی، شبکه عصبی مصنوعی و روش برنامه‌نویسی بیان ژن به ترتیب ۰/۹۱، ۰/۹۴ و ۰/۹۷ است. همچنین مقدار شاخص آماری RMSE برای مدل پیشنهادی ANN، MLR و GEP در این مرحله به ترتیب ۶/۳۶۴، ۴/۵۳۶ و ۳/۸۷۲ حاصل شده است. همچنین شاخص آماری MAE برای روش برنامه‌نویسی بیان ژن (۴/۵۰۱) به مراتب بهتر از روش‌های ANN (۵/۱۱۲) و MLR (۷/۷۶۲) بوده است. بدین ترتیب، شاخص‌های آماری نشان می‌دهند که مدل پیشنهادی GEP از عملکرد خوب و دقت بالایی در مرحله آموزش و آزمایش برخوردار بوده است. در مقایسه با مدل‌های داده مبنای پژوهشگران دیگر که در جدول (۷) نتایج آنها گزارش شده، مدل GEP مقاومت فشاری بتن خودتراکم در این مطالعه، خطای محاسباتی کمتری داشته که این مورد در نتایج شاخص‌های خطا قابل مشاهده بوده است.

بینی مقاومت فشاری بتن خود تراکم حاوی خاکستر پسته برنج است. از این رو، در مقایسه کمی میان روش‌های پیشنهادی که در شکل (۷) نشان داده شده است، روش رگرسیون خطی تقریباً پیش‌بینی‌های نادقیقی از مقاومت فشاری بتن خودتراکم حاوی خاکستر پسته برنج داشته است و نتوانسته مقادیر بیشینه و کمینه های محلی مقاومت فشاری را به خوبی پیش‌بینی نماید. بیش‌ترین میزان خطا در پیش‌بینی مقادیر مربوط به محدوده ۶۰-۴۰ مگاپاسکال بوده که بیشتر تخمین مقادیر کمتر برآورد شده از مقدار نتایج آزمایشگاهی است.

روش‌های کلاسیک داده مینا در این مطالعه مانند شبکه عصبی مصنوعی و رگرسیون خطی با توجه به رویکرد آزمایش و خطا در پیدا کردن شبکه بهینه و همچنین ضعف در حل مسائل پیچیده با توجه به تعداد متغیرهای تاثیرگذار بر فیزیک مسایل مختلف دچار خطاهای محاسباتی بوده است [23]. از این رو، استفاده از الگوریتم‌های فراابتکاری در بهبود این روش‌ها و همچنین روش‌های دیگر اجتناب ناپذیر بوده است. براساس نمودار بازه زمانی که در شکل (۷) نشان داده شده، پیش‌بینی‌های صورت گرفته از مقاومت فشاری با استفاده از روش MLR، دارای عملکرد نسبتاً ضعیف‌تر در مقایسه با روش شبکه عصبی مصنوعی و برنامه‌نویسی بیان ژن در پیش-

جدول ۷. ارزیابی عملکرد مدل‌های پیشنهادی برای تخمین مقاومت فشاری بتن خودتراکم

Models	Training stage			Testing stage		
	R	RMSE	MAE	R	RMSE	MAE
MLR	0.91	6.36	7.76	0.89	8.21	9.47
ANN	0.94	4.53	5.11	0.92	5.13	5.6
GEP	0.97	3.87	4.50	0.94	4.30	4.91
Douma et al. (2016)	0.95	-	-	0.94	-	-
Kave et al. (2017) - a	0.95	5.23	4.11	0.94	6.84	5.50
Kave et al. (2017) - b	0.96	4.45	3.45	0.94	4.51	5.56
Alyhya (2016)	0.22	772.52	23.11	0.32	813.98	22.20
Siddique et al. (2011)	-	-	-	0.91	4.43	5.57

Table 7. Comparison of the developed models to predict compressive strength of SCC

شکل ۵. نمودار پراکنندگی مقادیر مشاهده‌ای و محاسباتی در مرحله آموزش




Fig. 5. Scatterplots of the developed models for training performance

شکل ۶. نمودار پراکنندگی مقادیر مشاهده‌ای و محاسباتی برای مرحله آزمایش




Fig. 6. Scatterplots of the developed models for testing performance

مشخص نمودن آثار هر یک از پارامترهای ورودی به مدل پیشنهادی برای تخمین مقاومت فشاری بتن خود تراکم حاوی خاکستر پوسته برنج، آنالیز حساسیت روی روش برنامه نویسی بیان ژن به عنوان مدلی با عملکرد مطلوب در این پژوهش انجام شد.

شکل ۷- نمودار بازه زمانی مدل‌های توسعه داده شده در مرحله آزمایش

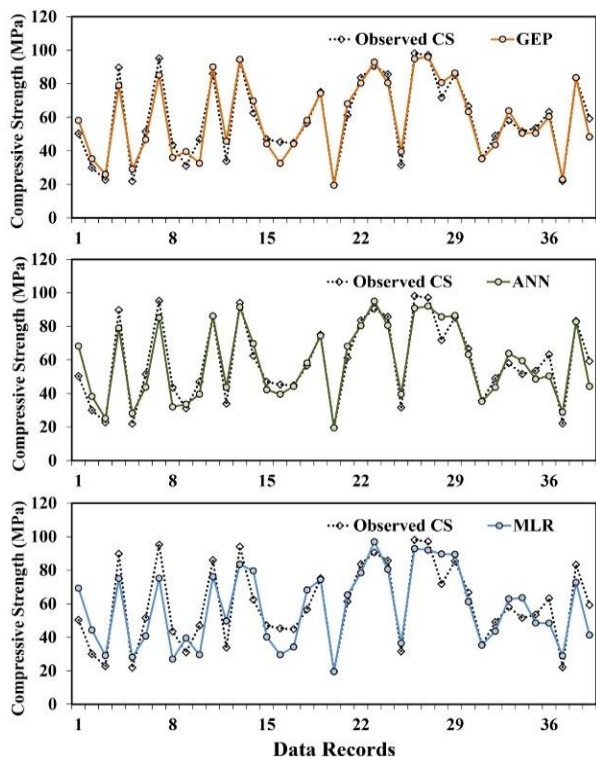


Fig. 7. Time series plots of the developed models in testing performance

نتایج جدول (۹) نشان می‌دهد که پارامتر C با داشتن ضریب همبستگی $R=0.72$ و شاخص‌های آماری دیگر مربوط به آن (MAE=11/25, RMSE= 10/36) موثرترین پارامتر روی تخمین مقاومت فشاری بتن است و پارامتر AS با داشتن ضریب همبستگی $R=0.93$ و شاخص‌های آماری دیگر مربوط به آن (MAE=4/21, RMSE= 4/16) کمترین تاثیر را روی مقاومت فشاری بتن حاوی خاکستر پوسته برنج داشته است. همچنین، متغیرهای مستقل CA, RHA, W, FA و SP به ترتیب بیشترین تاثیر را روی مقاومت فشاری ۲۸ روزه بتن خودتراکم حاوی خاکستر پوسته برنج دارند.

۴-۵- بررسی معناداری مدل‌های رگرسیونی توسعه داده شده برای آزمون ضرایب رگرسیون می‌توان از آماره فیشر (F-value) به شکل زیر استفاده نمود:

معادله رگرسیون معنادار است $H_1: \beta_i \neq 0 : i = 1, 2, \dots, k$ در $H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$ معادله رگرسیون معنادار نیست

این عامل نشان دهنده عدم همبستگی بین متغیرهای مستقل و وابسته و در نتیجه معنادار نبودن معادله خواهد بود. در غیر این صورت معادله رگرسیون معنادار می‌باشد. در صورتی که سطح اطمینان تعیین شده آماره بدست آمده از آزمون کوچکتر از مقدار بحرانی آن در جدول باشد، فرض صفر پذیرفته و در صورتی که بزرگتر باشد فرض صفر رد و معنادار بودن رگرسیون تأیید می‌شود [24]. در این مطالعه، برای ارزیابی معناداری مدل‌های توسعه داده شده از آزمون فیشر با سطح معناداری ۰/۰۵ استفاده شده که نتایج آن در جدول ۸ گزارش شده. همانطور که در جدول نشان داده شده نتایج P-value مدل‌ها کمتر از مقدار ۰/۰۵ بوده در نتیجه فرض صفر در سطح معناداری ۵ درصد رد شده و مدل‌های توسعه داده شده معنادار می‌باشند. همچنین مقدار آماره فیشر مدل‌ها نیز از مقدار فیشر بحرانی (۹/۱۶) بیشتر است.

جدول ۸ نتایج معناداری مدل‌های پیشنهادی در آزمون فیشر

Model	F-value	P-value
GEP	21.82	0.009
ANN	14.60	0.018
MLR	8.37	0.037

Table 8. Fisher test result of the proposed models

۵-۵- تحلیل حساسیت

تحلیل حساسیت به مطالعه تاثیرپذیری متغیرهای ورودی یک مدل آماری گفته می‌شود. به عبارت دیگر روشی برای ایجاد تغییر در ورودی‌های یک مدل آماری به صورت سازمان یافته (سیستماتیک) است که بتوان آثار این متغیرها را در خروجی مدل پیش‌بینی کرد [25]. در این مطالعه، به منظور

جدول ۹. تحلیل حساسیت پارامترهای مربوط به مقاومت فشاری بتن

Input variables	R	RMSE	MAE
$CS = f(W, SP, F.A, C.A, AS, RHA)$	0.72	10.36	11.25
$CS = f(C, SP, F.A, C.A, AS, RHA)$	0.89	5.32	6.14
$CS = f(C, W, F.A, C.A, AS, RHA)$	0.92	4.21	4.16
$CS = f(C, W, SP, C.A, AS, RHA)$	0.90	4.67	5.26
$CS = f(C, W, SP, F.A, AS, RHA)$	0.78	9.72	10.35
$CS = f(C, W, SP, F.A, C.A, RHA)$	0.93	4.16	4.21
$CS = f(C, W, SP, F.A, C.A, AS)$	0.81	7.72	7.75

Table 9. Sensitivity analysis of the independent variables to predict compressive strength

۶- نتیجه گیری

در این پژوهش از یکی از جدیدترین روش‌های داده مبنای یعنی مدل برنامه‌نویسی بیان ژن برای تخمین پیش‌بینی مقاومت فشاری بتن خود تراکم حاوی خاکستر پوسته برنج، استفاده شد. برای استخراج کردن پارامترهای موثر بر مقاومت فشاری این نوع بتن، از تعریف چهار سناریو استفاده شده است و با استفاده از روش رگرسیون خطی به ارزیابی هر یک از حالت‌ها پرداخته شده است که در نهایت از ۷ پارامتر ورودی C, W, SP, FA, CA, AS و RHA یک پارامتر خروجی (مقاومت فشاری بتن) برای توسعه مدل‌های پیشنهادی استفاده شد. با توجه به ارزیابی‌های صورت گرفته از مدل‌های توسعه یافته پیشنهادی، نتایج زیر حاصل شده است:

- استفاده از مدل‌های ANN و GEP به عنوان معادلات صریح برای ارزیابی مقاومت فشاری بتن خودتراکم، ثابت کرده‌اند که دارای دقت بالاتری در مقایسه با روش‌های خطی ساده است. همچنین روش GEP با قابلیت فرموله کردن تخمین خروجی مورد نظر با دقت بالا نشان داد ابزار قدرتمندی برای پیش‌بینی و داده کاوی در مسائل تکنولوژی مهندسی و به ویژه تکنولوژی بتن است.
- معناداری مدل‌های پیشنهادی با استفاده از آزمون‌های فرض رگرسیونی از طریق آزمون فیشر نشان داد مقادیر شاخص فیشر همه مدل‌ها کمتر از مقدار بحرانی و شاخص اطمینان کمتر از ۰/۰۵ بوده که اعتبار مدل‌های ارائه شده را تصدیق می‌نماید.
- برای تاثیرپذیری متغیرهای خروجی از متغیرهای ورودی، از روش GEP (که بهترین عملکرد را در مرحله تست داشته است) استفاده شده است که نتایج حاکی از این بود که متغیر B دارای بیشترین تاثیر در تخمین مقاومت فشاری بتن و SP کمترین تاثیر را در خروجی مدل داشته‌اند.

References

- [1]. Okamora, H., Ouchi, M., 2003, Self-Compacting Concrete", *Journal of Advanced Concrete Technology*, 1(1), 5-15.
- [2]. Ramezani-pour, A. A., Samadian, M., & Mahdikhani, M., 2012, Engineering properties and durability of self-consolidating concretes (sc) containing volcanic pumice ash, *Asian journal of civil engineering (building and housing)*, 13(4), 521-530.

۷- مراجع

- عملکرد روش‌های هوشمند پیشنهادی برای مرحله آموزش و آزمایش با استفاده از مجموعه داده‌های آزمایشگاهی جمع‌آوری شده از مقالات پیشین، انجام شده است. با توجه به پارامترهای آماری خطا در مرحله آموزش، می‌توان بیان نمود که روش برنامه‌نویسی بیان ژن ($R=0/97$, $RMSE=3/364$) در مقایسه با روش‌های شبکه عصبی مصنوعی ($R=0/94$, $RMSE=4/536$) و رگرسیون خطی ($R=0/91$, $RMSE=6/762$) دارای عملکرد مناسب‌تری برای تخمین مقاومت فشاری بتن خودتراکم داشته است. علاوه بر این، عملکردهای هر یک از روش‌ها در مرحله آزمایش نشان می‌دهد که روش GEP ($R=0/94$, $RMSE=4/308$) در حالت معادلات غیرخطی، تخمین مناسب‌تری را نسبت به روش‌های ANN ($R=0/92$, $RMSE=5/136$) و MLR ($R=0/89$)

- [17]. Ferreira C, 2001, Gene Expression Programming; A New Adaptive Algorithm for Solving Problems, *Complex Systems*, 13, 87-129.
- [18]. Ferreria C, Gene-expression Programming: Mathematical Modeling by an Artificial Intelligence, Springer, Berlin, Heidelberg, New York, 2006.
- [19]. Sakr, K, 2006, Effects of silica fume and rice husk ash on the properties of heavy weight concrete, *Journal of materials in civil engineering*, 18(3), 367-376.
- [20]. Ganesan, K., Rajagopal, K., Thangavel, K, 2008, Rice husk ash blended cement: assessment of optimal level of replacement for strength and permeability properties of concrete. *Construction and building materials*, 22(8), 1675-1683.
- [21]. Bui, D. D., Hu, J., & Stroeven, P, 2005, Particle size effect on the strength of rice husk ash blended gap-graded Portland cement concrete, *Cement and concrete composites*, 27(3), 357-366.
- [22]. Ramezani pour, A. A., Mahdikhani, M., Ahmadibeni, G, 2009, The effect of rice husk ash on mechanical properties and durability of sustainable concretes, *International Journal of Civil Engineering*, 7(2), 83-91.
- [23]. Zhang, W. G., & Goh, A. T. C., 2013, Multivariate adaptive regression splines for analysis of geotechnical engineering systems, *Computers and Geotechnics*, 48, 82-95.
- [24]. Bluman, A.G, 2009, Elementary statistics: a step by step approach, 7th ed. McGraw-Hill, New York, USA.
- [25]. Najafzadeh, M., Balf, M. R., & Rashedi, E, 2016, Prediction of maximum scour depth around piers with debris accumulation using EPR, MT, and GEP models. *Journal of Hydroinformatics*, 18(5), 867-884
- [3]. The european guidelines for self-compacting concrete; specification production and use. EFNARC; May 2005.
- [4]. Zerbino, R., Giaccio, G., Isaia, G.C., 2011, Concrete incorporating rice-husk ash without processing, *Construction and Building Materials*, 25, 371-378.
- [5]. Chen, Li, 2010, A multiple linear regression prediction of concrete compressive strength based on physical properties of electric arc furnace oxidizing slag, *International Journal of Applied Science and Engineering* 7(2), 153-158.
- [6]. Sonebi, M., Grünewald, S., Cevik, A., Walraven, J, 2016, Modelling fresh properties of self-compacting concrete using neural network technique, *Computer & Concrete*, 4, 903-921.
- [7]. Šipoš, T. K., Miličević, I., & Siddique, R, 2017, Model for mix design of brick aggregate concrete based on neural network modelling, *Construction and Building Materials*, 148, 757-769.
- [8]. Wang, B., Man, T., & Jin, H, 2015, Prediction of expansion behavior of self-stressing concrete by artificial neural networks and fuzzy inference systems, *Construction and Building Materials*, 84, 184-191.
- [9]. Mousavi, S. M., Aminian, P., Gandomi, A. H., Alavi, A. H., & Bolandi, H, 2012, A new predictive model for compressive strength of HPC using gene expression programming, *Advances in Engineering Software*, 45(1), 105-114.
- [10]. Gholampour, A., Gandomi, A. H., & Ozbakkaloglu, T, 2017, New formulations for mechanical properties of recycled aggregate concrete using gene expression programming, *Construction and Building Materials*, 130, 122-145.
- [11]. Chithra S, Kumar SRRS, Chinnaraju K, Ashmita FA, 2016, A comparative study on the compressive strength prediction models for High Performance Concrete containing nano silica and copper slag using regression analysis and Artificial Neural Networks, *Construction and Building Materials*, 114:528-35.
- [12]. Ahmadi-nedushan B, 2012, Prediction of elastic modulus of normal and high strength concrete using ANFIS and optimal nonlinear regression models, *Construction and Building Materials*, 36, 665-73.A,
- [13]. Sobhani J, Najimi M, Pourkhorshidi AR, Parhizkar T, 2010, Prediction of the compressive strength of no-slump concrete: A comparative study of regression, neural network and ANFIS models, *Construction and Building Materials*, 24(5), 709-18.
- [14]. Ji T, Lin T, Lin X. A, 2006, concrete mix proportion design algorithm based on artificial neural networks, *Cement & Concrete Research*, 36(7), 1399-1408.
- [15]. Majumdar A, Mitra A, Banerjee D, Majumdar P. K, 2010, Soft Computing Applications in Fabrics and Clothing A Comprehensive Review, *Research Journal of Textile and Apparel*, 14, 1-17.
- [16]. Holland J. H, *Adaptation in Natural and Artificial Systems*, University of Michigan Press, 1975

Prediction of the Compressive Strength of Self-compacting Concrete Containing Rice Husk Ash using Data Driven Models

Mohammad Javad Taheri Amri¹, Ali Ashrafian^{2*}, Farshid Reza Haghighi³, Maedeh Javaheri-barforooshi⁴

- 1- Assistant Professor, Higher Education Institute of Pardisan, Mazandaran, Iran
- 2- M.Sc. of Civil Engineering, Tabari University, Babol, Iran (Corresponding Author)
- 3- Assistant Professor, Babol University of Technology, Babol, Iran
- 4- Ph.D. Candidate of Construction Engineering and Management, Islamic Azad University, Arak, Iran

*ali.ashrafian@tabari.ac.ir

Abstract

The construction and maintenance of structural pavement was a high-cost problem in last decade. The mechanical properties of self-compacting concrete (SCC) required important factors. From its mechanical properties, the compressive strength (CS) is necessary to investigate experimental and computational intelligence analysis in construction materials. Developing models with accurate estimation for this key property caused to saving costs and time and producing an optimal blend. Because of the many advantages, using of SCC in structures is increasing. Construction of precast-prefabricated components, with the use of concrete has also recently been considered. Concrete properties have significant role in precast-prefabricated girders behavior. Exact prediction of these properties is the base of member's analysis and design. The main purpose of this study is presents new formulation to estimate the compressive strength of self-compacting concrete containing rice husk ash (RHA) using robust variant of genetic programming, namely gene expression programming (GEP) method. To evaluate the performance of the GEP-based proposed model, prediction was also done using classical data driven methods named artificial neural network (ANN) and multiple linear regression (MLR) models. A large and reliable experimental database containing the results of 156 compressive strength of SCC incorporating RHA is collated through an extensive review of the literature. The performance of proposed models of CS is then assessed using the database, and the results of this evaluation are presented using selected performance measures. New expressions for the estimation of CS of SCC are developed based on the database. To evaluate the modeling performances of the proposed GEP models for CS, different statistical metrics were used. Correlation coefficient (R), root mean square error (RMSE), mean absolute error (MAE) were used as the measure of precision. The results showed that the models developed using the aforementioned methods have accuracy over 90 percent in prediction of CS of SCC. The results of testing datasets are compared to experimental results and their comparisons demonstrate that the GEP model (R=0/94, RMSE= 4/308 and MAE=4/916) outperforms ANN (R=0/92, RMSE= 5/136 and MAE=5/624) and MLR (R=0/89, RMSE= 8/212 and MAE=9/472). Proposed models have a strong potential to predict compressive strength of SCC incorporating rice husk ash with great precision. The importance of different input parameters is also given for predicting the compressive strengths at various ages using gene expression programming. Performed sensitivity analysis to assign effective parameters on compressive strength indicates that cementitious binder content is the most effective variable in the mixture. The proposed design equation can readily be used for pre-design purposes or may be used as a fast check on deterministic solutions.

Keywords: Self-Compacted Concrete, Gene Expression Programming, Artificial Neural Network, Multiple Linear Regression, Compressive Strength, Prediction