

ارائه مدل‌های تلفیقی MARS-PSO و ELM-PSO در تخمین مقاومت فشاری بتن در ستون‌های بتنی دایره‌ای محصور شده با الیاف پلیمری FRP

مجتبی حنطه (دکتر)

دانشکده مهندسی عمران، دانشگاه سمنان

هانیه ملک (کارشناس ارشد)

دانشکده عمران، دانشگاه صنعتی خواجه نصرالدین طوسی، تهران

محمود اکبری* (دانشیار)

دانشکده مهندسی عمران، دانشگاه کاشان

مهندسی عمران شریف، تابستان ۱۴۰۱ (دوره ۲ - ۳۸، شماره ۱/۲، ص. ۱۱۷-۱۲۹، یادداشت‌شده)

هدف از پژوهش حاضر، استفاده از مدل‌های هوش مصنوعی رگرسیون اسپلاین چندمتغیره‌ی تطبیقی (MARS) و ماشین یادگیری سریع (ELM) جهت تخمین مقاومت فشاری بتن در ستون‌های بتنی دایره‌ای محصور شده با FRP است. به علاوه، برای بهبود دقت مدل‌های ذکر شده، از الگوریتم ازدحام ذرات (PSO) نیز در تلفیق با آنها استفاده و دقت مدل‌ها در جهت تخمین مقاومت بررسی و ارزیابی شده است. نتایج نشان می‌دهند که به طور کلی مدل‌های هوش مصنوعی استفاده شده، مقاومت فشاری ستون‌های محصور شده با FRP را نسبت به مدل‌های تحلیلی موجود با دقت بیشتری تخمین می‌زنند. به ویژه مدل تلفیقی MARS-PSO، عملکرد بهتری در مقایسه با دیگر مدل‌های استفاده شده داشته است، به نحوی که ضریب‌های همبستگی آن در مرحله‌ی آموزش، 0.9972 و در مرحله‌ی آزمایش، 0.9961 بوده است. همچنین تلفیق الگوریتم PSO با دو مدل MARS و ELM، باعث بهبود دقت آنها به ترتیب به اندازه‌ی $6/13$ و $4/68$ درصد شده است.

واژگان کلیدی: رگرسیون اسپلاین چندمتغیره‌ی تطبیقی، ماشین یادگیری سریع، مقاومت فشاری ستون‌های بتنی دایره‌ای، هوش مصنوعی، الگوریتم فراابتکاری ازدحام ذرات.

mhenteh@semnan.ac.ir
H.malek@email.kntu.ac.ir
makbari@kashanu.ac.ir

۱. مقدمه

ستون‌های بتن‌آرمه، اعضاء اصلی مقاوم در برابر بارهای افقی و عمودی در سازه‌های بتنی هستند. از این رو، مقاومت آنها، نقش مهمی در مقاومت کلی سازه ایفا می‌کند. از جمله روش‌های مقاوم‌سازی ستون‌های بتن‌آرمه، استفاده از سیستم‌های: پیش‌تشدگی خارجی، غلاف‌های فولادی یا پلیمرهای تقویت شده با بتن و الیاف (FRP) ^۱ است. مقاوم‌سازی سازه‌های بتنی مسلح با استفاده از کامپوزیت‌های FRP، در مقایسه با سایر روش‌های ذکر شده، به دلیل دست‌یابی به مقاومت بیشتر و همچنین عدم تغییرشکل و ابعاد ساختار تشکیل‌دهنده، به عنوان روشی رایج در سراسر جهان پذیرفته شده است. ^۱

اولین ایده‌ی استفاده از کامپوزیت‌های FRP برای محصورکنندگی، توسط فردیس و خلیلی ^{۱۹۸۱} ارائه شده است. ایشان با استفاده از فایبرگلاس بتن را

دورپیچ کردند. از آن زمان تاکنون، آزمایش‌های متعدد و قابل ملاحظه‌ی در رابطه با بررسی رفتار ستون‌های بتنی محصور شده با ورق‌های FRP توسط دیگر پژوهشگران صورت گرفته است. ^۲ محصور کردن، یکی از روش‌های مؤثر برای افزایش مقاومت فشاری ستون‌های بتنی است، که در گذشته رواج زیادی داشته و امروزه هنوز جزء روش‌های متداول است. ^۳ در اثر محصورشدگی، مدل رفتاری بتن تحت فشار کاملاً تغییر می‌کند. هنگامی که ستون بتنی محصور شده، تحت نیروی فشاری محوری قرار می‌گیرد، پوشش محصورکننده به دلیل اتساع جانبی ستون تحت کشش قرار می‌گیرد و تنش‌های محصورکننده به هسته‌ی بتنی اعمال می‌شود؛ به این ترتیب باربری هسته‌ی بتنی ادامه می‌یابد و ستون در تنش فشاری بالاتری منهدم می‌شود. ^۴ اگرچه روش‌های ذکر شده در افزایش ظرفیت سازه مؤثر هستند، اما نیاز به تجهیزات و نیروی کار نسبتاً زیاد و گاهی نیز در پیاده‌سازی مشکلاتی دارند؛ از این رو، یک سیستم مقاوم‌سازی ابتکاری، پایدار، آسان برای نصب و مقرون به صرفه در عوض روش‌های قدیمی‌تر نیاز است. ^۴ همچنین، به دلیل محبوبیت استفاده از FRP، مدل‌های

* نویسنده مسئول

تاریخ: دریافت ۱۴۰۰/۹/۲۷، اصلاحیه ۱۴۰۰/۱۱/۹، پذیرش ۱۴۰۰/۱۱/۱۲

DOI:10.24200/J30.2022.59497.3053

گوناگونی برای تخمین مقاومت فشاری ستون‌های محصور شده با FRP ارائه شده است. در بیشتر الگوهای طراحی، روابط تجربی و معادلاتی مبتنی بر آنالیز رگرسیون داده‌های آزمایشگاهی معرفی شده است. برای توسعه‌ی چنین مدل‌هایی باید ابتدا ترکیب و قالبی برای روابط تجربی فرض و سپس پارامترهای مجهول به دست آورده شوند. وجود شمار زیاد پارامترهای تأثیرگذار در مقاومت فشاری ستون‌های محصور شده با FRP، موفقیت یک چنین روندی را با مشکل مواجه می‌سازد. در مقابل، استفاده از مدل‌های هوش مصنوعی، یک روش جایگزین را فراهم می‌آورد که بتواند بر مشکلات اخیر غلبه کند و نیز رفتار پیچیده‌ی کلی تعیین شده‌ی از ارتباط بین عناصر پردازش و پارامترهای سیستم را نمایش دهد. حتی این امر برای مسائلی که مدل‌های ریاضی و فیزیکی آنها چندان شناخته شده نیست، صادق است.

تاپکو و ساریدمیر^۲ (۲۰۰۸)، یک روش مبتنی بر شبکه‌ی عصبی مصنوعی (ANN)^۳ و منطق فازی (FL)^۴ برای تعیین مقاومت فشاری بتن حاوی خاکستر^۵ و روشی دیگر برای پیش‌بینی مقاومت فشاری بتن حاوی برخی از مواد افزودنی پیشنهاد داده‌اند.^۶ آلتون^۵ و همکاران (۲۰۰۸)، یک شبکه‌ی عصبی مصنوعی مبتنی بر روش رگرسیون چندخطی برای تخمین مقاومت فشاری بتن الیافی پیشنهاد داده‌اند.^۷ کاسکاردی^۶ و همکاران (۲۰۱۷)، یک مدل تحلیلی برای پیش‌بینی مقاومت بتن محدود با FRP برای ستون‌های دایره‌ی ارائه کرده‌اند، که پارامتر بخشی جدیدی را در مقایسه با مدل‌های فعلی با استفاده از شبکه‌های عصبی مصنوعی با در نظر گرفتن یک پایگاه داده‌ی تجربی بزرگ ارائه داده است.^۸ مطالعات زیادی با استفاده از روش‌های محاسبات نرم، مانند: پیش‌بینی مقاومت ستون‌های کوتاه لوله‌ی بتنی محصور شده (CCFT)^۷ تحت بار محوری انجام شده است،^۹ که در آن مدلی برای پیش‌بینی ظرفیت فشاری لوله‌ی فولادی دایره‌ی پر از بتن پیشنهاد شده است.^{۱۰} و علاوه بر این، پیش‌بینی سهم برشی تیرهای بتن مسلح^۸ محدود با FRP با روش پیوند خارجی با استفاده از سیستم استنتاج عصبی فازی (ANFIS)^۹ نیز بررسی شده است.^{۱۱} برآورد مقاومت فشاری در بتن سازگار با محیط زیست،^{۱۲} تعیین مقاومت فشاری بتن توسط مدل‌های ANN و ANFIS^{۱۳} و پیش‌بینی مقاومت فشاری ملات‌هایی که کانی‌های اینوسیلیکات کلسیم^{۱۰} دارند،^{۱۴} از دیگر مطالعات بوده است.

محمودآبادی و سخانی‌پور (۲۰۲۰)، به کمک تحلیل عددی با نرم‌افزار آباکوس به بررسی اثر شکل مقطع در ستون‌های محصور شده با پلیمرهای تقویت شده با الیاف کربن (CFRP)^{۱۱} پرداخته و نشان داده‌اند که شکل مقطع ستون در ظرفیت باربری محوری اثری ندارد؛ اما، در ظرفیت باربری جانبی مؤثر است.^{۱۵} ساجدی و همکاران (۲۰۲۰)، با انجام آزمایش در بررسی رفتار ستون‌های بتن مسلح محصور شده با FRP ساخته شده از بتن با مقاومت بالا، نشان داده‌اند که اثر غلاف تقویت شده با الیاف شیشه (GRP)^{۱۲} در افزایش مقاومت بیشتر است.^{۱۶}

سان^{۱۳} و همکاران (۲۰۱۹)، در ارزیابی مقاومت فشاری بتن حاوی خاکستر بادی و دوده‌ی سیلیسی با استفاده از الگوریتم کلونی زنبورعسل، از ۷ ورودی به عنوان پارامترهای ورودی برای ارزیابی و پیش‌بینی مقاومت فشاری استفاده کردند، که نتیجه‌ی آن ایجاد روابط جدید برای مقاومت فشاری بتن بوده است.^{۱۷} آستریس^{۱۴} و همکاران (۲۰۱۹)، در مطالعه‌ی در ارتباط با ارائه‌ی روابط محاسباتی جهت پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی پوزولان متاکاتولن، از دو روش مارس و مدل درخت استفاده کرده و مقادیر مقاومت را توسط شاخص‌های خطا و تحلیل اعتبارسنجی خارجی تخمین زده‌اند.^{۱۸} دروسو^{۱۵} و همکاران (۲۰۱۹)، برای تخمین مقاومت فشاری بتن درجا، با استفاده از روش‌های هوشمند مختلف رگرسیونی درخت تصمیم، کرنلی و چندگانه، مدل‌های مختلفی ارائه داده و مقایسه‌ی کمی آنها را

با استفاده از شاخص‌های خطا بررسی کرده‌اند.^{۱۹} گل‌افشانی و همکاران (۲۰۲۰)، با استفاده از پارامترهای طرح اختلاط، به پیش‌بینی مقاومت فشاری ۲۸ روزه بتن بازافزایی و بتن پرتلند پرداخته و با ترکیب الگوریتم فراابتکاری گرگ خاکستری و روش‌های شبکه‌ی عصبی مصنوعی و ANFIS، مدل‌های بهینه شده‌ی رگرسیونی را توسعه داده‌اند.^{۲۰} فنگ^{۱۶} و همکاران (۲۰۲۰)، مقاومت فشاری بتن را با استفاده از روش تقویت سازگار و روش‌های ماشین یادگیری پیش‌بینی کرده‌اند. روش تقویت سازگار باعث ایجاد یک یادگیرنده‌ی قوی می‌شود، که با یادگیرنده‌های ضعیف ترکیب می‌شود و یک الگوی مناسب بین مقادیر ورودی و خروجی ایجاد می‌کند.^{۲۱} اکبری و دلگانی (۲۰۲۰)، با استفاده از مدل‌های داده‌کاوی، مقاومت فشاری بتن را در دماهای بالا ارزیابی و پیش‌بینی کرده‌اند. همچنین ایشان از سه روش: رگرسیون خطی چندگانه، شبکه‌ی عصبی مصنوعی و الگوریتم عصبی فازی استنتاجی برای ۲۰۷ داده‌ی آزمایشگاهی استفاده کرده‌اند.^{۲۲} سویم^{۱۷} و همکاران (۲۰۲۱)، به منظور مدل‌سازی و پیش‌بینی خواص سخت شده و مقاومت فشاری بتن حاوی خاکستر بادی، از روش‌های هوش مصنوعی ANN و ANFIS استفاده کرده‌اند. اگر چه مدل‌های هوش مصنوعی، دقت قابل قبولی داشتند، اما آنها از الگوریتم ژنتیک نیز برای ترکیب با روش‌های هوشمند مذکور، به منظور ارتقاء دقت مدل‌ها استفاده کرده‌اند، که نتایج نیز حاکی از افزایش دقت مدل‌های ترکیبی پیشنهادی بوده است.^{۲۳}

استفاده از روش‌های هوش مصنوعی بهینه شده با الگوریتم‌های فراابتکاری برای مدل‌سازی و پیش‌بینی مسائل در مهندسی و مدیریت پروژه‌های عمرانی به علت مزایای قابل تأمل آن، از جمله: صرفه‌جویی در زمان و هزینه، رفع مشکلات و محدودیت‌های موجود فراگیر شده است. در پژوهش حاضر، ۲۸۱ داده از مراجع مختلف،^{۲۴-۲۳} استفاده شده است، که در آنها برای تعیین مقاومت فشاری بتن محصور شده در ستون‌های بتنی محصور شده با FRP، از نمونه‌های بتنی استوانه‌ی محصور شده با FRP استفاده شده است.

در ادامه‌ی نوشتار حاضر، مدل‌های محاسباتی مبتنی بر رویکرد هوش مصنوعی برای تخمین مقاومت فشاری ستون‌های بتنی با مقاطع دایره‌ی محصور شده با الیاف پلیمری FRP، معرفی و روش‌های اسپلین رگرسیونی چندمتغیره‌ی انطباقی و ماشین یادگیری سریع جهت انجام فرایند مدل‌سازی استفاده شده است. همچنین جهت بهینه‌سازی مقادیر پارامترهای تنظیمی هر دو روش، الگوریتم ازدحام ذرات با روش‌های مذکور تلفیق شده است، تا کارایی مدل و سرعت همگرایی نتایج بهبود یابد.

همچنین با استفاده از روابط متداول برای سنجش خطای مدل‌ها و با توجه به معیارهای تعیین خطا، مقایسه‌ی میان روش‌های مذکور با هوش مصنوعی و مدل‌های تخمین مطالعات پیشین انجام شده است. فلوجارت پژوهش حاضر، مطابق شکل ۱ است.

۲. مقاومت فشاری ستون‌های بتنی با مقطع دایره‌ی

محصور شده با FRP

مطابق شکل ۲، دورپیچ کردن انواع معینی از اعضاء فشاری توسط سیستم‌های FRP، اعضاء مذکور را محصور می‌کند و منجر به افزایش مقاومت فشاری آنها می‌شود.

هنگامی که ستون یا عضو فشاری تحت بارهای لرزه‌ی قرار گیرد، مسئله‌ی

$$f_{lfrp} = \frac{2 N_b \phi_{frp} f_{frpu} t_{frp}}{D_g} \quad (1)$$

که در آن، f_{lfrp} فشار محصورشدگی نهایی به سبب مقاومسازی با FRP بر حسب مگاپاسکال، N_b تعداد لایه‌های تقویتی FRP، ϕ_{frp} ضریب جزئی ایمنی مصالح FRP، f_{frpu} مقاومت کششی نهایی مصالح FRP بر حسب مگاپاسکال، t_{frp} ضخامت یک لایه تقویت‌کننده FRP بر حسب میلی‌متر و D_g قطر خارجی ستون گرد بر حسب میلی‌متر است. همچنین مقاومت فشاری بتن محصور شده مطابق رابطه ۲ محاسبه می‌شود:

$$f_{cc} = f_c (1 + \alpha_{pc} \omega_w) \quad (2)$$

که در آن، f_{cc} مقاومت فشاری بتن محصور شده بر حسب مگاپاسکال، f_c مقاومت فشاری مشخصه بتن بر حسب مگاپاسکال و ω_w نسبت حجمی مقاومت FRP ورق‌ها به مقاومت بتن هستند.

همچنین، α_{pc} ضریب عملکرد برای یک ستون گرد، به سختی و کرنش نهایی FRP، مقاومت بتن، کیفیت اجرا و چسبندگی بتن - رزین - الیاف بستگی دارد. در مطالعه‌ی حاضر، مقدار $\alpha_{pc} = 1$ در نظر گرفته شده است.^[۴۱]

در برخی از مطالعات پیشین، به منظور پیش‌بینی مقاومت فشاری از روابط ۳ الی ۱۰ استفاده شده است؛ که در آنها، پارامترهای ورودی شامل قطر استوانه‌ای بتنی (d)، طول استوانه‌ای بتنی (L)، مقاومت فشاری نهایی بتن محصور نشده (f'_{co})، مقاومت فشاری نهایی بتن محصور شده (f'_{cc})، ضخامت لایه‌ی FRP (t)، فشار نهایی محصور شده (f_i)، کرنش گسیختگی نمونه‌ی محصور شده با FRP ($\epsilon_{h,rup}$)، نسبت سختی محصور شدگی (ρ_k)، نسبت کرنش (ρ_ϵ) و مدول کشسانی FRP (E_l) هستند.^[۴۹-۴۲]

$$\frac{f'_{cc}}{f'_{co}} = 1 + 3 \left(\frac{f_i}{f'_{co}} \right)^{\frac{1}{3}} \quad (3)$$

$$\frac{f'_{cc}}{f'_{co}} = 1 + \frac{(2.75 - 0.75 f'_{co}) E_l \epsilon_{h,rup}}{f'_{co}} \quad (4)$$

$$\frac{f'_{cc}}{f'_{co}} = 1 + (3.023 - 4.78 (\rho_k)^{2.75}) \left(\frac{f_i}{f'_{co}} \right)^{0.95} \quad (5)$$

$$\frac{f'_{cc}}{f'_{co}} = 1 + (2.77 \rho_k^{1.77} - 0.75 \gamma) \rho_\epsilon^{0.91} \quad (6)$$

$$\frac{f'_{cc}}{f'_{co}} = 0.75 + 1.8 \frac{f_i}{f'_{co}} + 5.7 \frac{t}{d} \frac{f_i}{f'_{co}} + \frac{13}{f'_{co}} \quad (7)$$

$$\frac{f'_{cc}}{f'_{co}} = 1 + 3.49 \left(\frac{f_i}{f'_{co}} \right)^{0.86} \quad (8)$$

$$f'_{cc} = (f'_{cc})_{chart} \times C(d) \times C(L) \times C(f'_{co}) \times C(t) \times C(f_i)$$

$$C(f_i) = -0.213 \left(\frac{f_i}{1500} \right)^2 + 0.901 \left(\frac{f_i}{1500} \right)^2$$

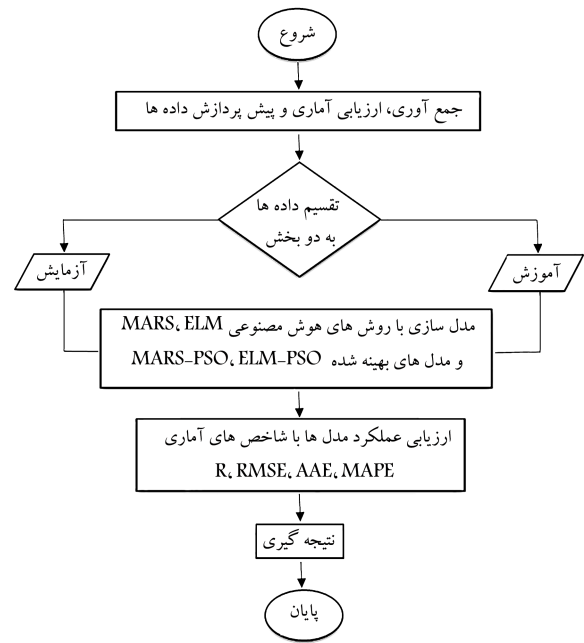
$$-1.008 \left(\frac{f_i}{1500} \right)^2 + 0.723 \left(\frac{f_i}{1500} \right) + 0.604$$

$$C(t) = -0.064 \left(\frac{t}{1.2} \right)^2 + 0.669 \left(\frac{t}{1.2} \right) + 0.387$$


$$C(f'_{co}) = 1.082 \left(\frac{f'_{co}}{35} \right)^4 - 5.071 \left(\frac{f'_{co}}{35} \right)^2 +$$

$$8.209 \left(\frac{f'_{co}}{35} \right)^2 - 5.029 \left(\frac{f'_{co}}{35} \right) + 1.798$$

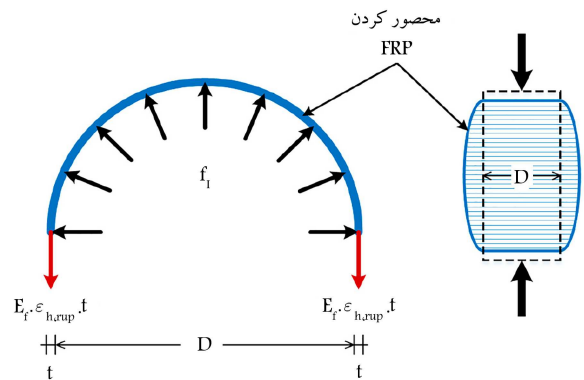
$$C(L) = 0.159 \ln \left(\frac{L}{300} \right) + 1.009 \quad (9)$$



شکل ۱. فلوچارت مراحل پژوهش.



شکل ۲. استوانه‌ی بتنی تحت فشار.



شکل ۳. مکانیسم بتن‌های محصور شده با پلیمرهای تقویتی (FRP).

ظرفیت جذب انرژی و شکل‌پذیری ستون اهمیت می‌یابد. در این ارتباط، مقاومسازی یا بهسازی آن عضو با افزایش شکل‌پذیری انجام می‌گیرد (شکل ۳). محصورشدگی از طریق اتصال ورق‌های FRP، که در آنها به منظور محدود کردن کرنش‌های محیطی ستون، راستای الیاف عمود بر محور ستون است، فراهم می‌شود. فشار محصورشدگی نهایی به سبب مقاومسازی مقطع گرد با مصالح FRP بر اساس رابطه‌ی ۱ بیان می‌شود:

$$f(x) = h(x)\beta = \sum_{i=1}^L \beta_i h_i(x) \quad (12)$$

که در آن، تابع $h(x)$ در واقع فضای d بُعدی، ورودی را به یک فضای L بُعدی نگاشت می‌کند. بین لایه‌های نهان و خروجی نیز وزن وجود دارد.

۳.۳. الگوریتم بهینه‌سازی ازدحام ذرات (PSO) ۲۴

الگوریتم ازدحام ذرات (PSO)، برای اولین بار توسط کندی و ابره‌ه‌ارت ۲۵ (۱۹۹۵) ارائه و جزئیات ریاضی آن در مراجعی مانند کارک و لازینیکا ۲۶، به طور مفصل شرح داده شده است. [۵۲، ۵۳] الگوریتم ازدحام ذرات (PSO)، نوعی الگوریتم بهینه‌سازی مبتنی بر رفتار گروهی جانوران در طبیعت است. جانوران در طبیعت، بسیاری از نیازهای خود از جمله جستجوی غذا را به صورت دسته‌جمعی و با کمک یکدیگر و با استفاده از خرد جمعی انجام می‌دهند. الگوریتم PSO در مقایسه با روش‌های بهینه‌سازی مشابه دیگر برای رسیدن به نتایج مناسب، به فراخوانی تابع کمتری نیاز دارد. از جمله مزایای دیگر الگوریتم PSO می‌توان به پیاده‌سازی رایانه‌ی آسان آن اشاره کرد، که به آسانی با شرایط قیود و متغیرها در یک مسئله‌ی خاص منطبق می‌شود. [۵۵] یکی دیگر از ویژگی‌های الگوریتم ازدحام ذرات این است که از گزاردیان تابع استفاده نمی‌کند. این امر بدین معنی است که در الگوریتم ازدحام ذرات (PSO)، نیازی به مشتق‌پذیر بودن تابع هدف نیست؛ این شرط در بسیاری از روش‌های کلاسیک بهینه‌سازی، مانند: شبه‌نیوتن و گزاردیان کاهش‌ی جزء شرط‌های لازم برای حل مسئله است. از دیگر مزایای الگوریتم PSO این است که هیچ فرضی در حل مسئله صورت نمی‌گیرد و الگوریتم مذکور می‌تواند ناحیه‌ی بسیار وسیعی از جواب‌های احتمالی را جستجو کند. در الگوریتم PSO هر جواب مسئله، یک ذره در فضای جستجو با یک مقدار شایستگی است، که توسط تابع شایستگی مسئله به دست می‌آید. در فرمول‌بندی الگوریتم، ذره‌ی i ام در موقعیت x و در تکرار $k+1$ ام از طریق رابطه‌ی ۱۳، موقعیت خود را بهبود می‌بخشد؛ که در رابطه‌ی مذکور، v_{k+1}^i سرعت اصلاح شده‌ی ذره‌ی i ام است، که از رابطه‌ی ۱۴ به دست می‌آید و Δt ، گام زمانی است که با استفاده از رابطه‌ی ۱۵ تعیین می‌شود. در پژوهش حاضر مقدار Δt برابر واحد فرض شده است. [۵۶]

$$x_{k+1}^i = x_k^i + v_{k+1}^i \Delta t \quad (13)$$

$$v_{k+1}^i = w v_k^i + c_1 r_1 \frac{(p_k^i - x_k^i)}{\Delta t} + c_2 r_2 \frac{(p_k^g - x_k^i)}{\Delta t} \quad (14)$$

$$\Delta t = \frac{1}{k_{Max}} \quad (15)$$

در روابط اخیر، v_k^i مقدار بردار سرعت در تکرار k ام، r_1 و r_2 اعداد تصادفی بین صفر و یک و p_k^i نشان‌دهنده‌ی بهترین موقعیت ذره‌ی i ام و p_k^g موقعیت بهترین ذره در تمام جامعه تا تکرار k ام است و دیگر ضرایب، پارامترهای وابسته به مسئله هستند. برای مثال c_1 (شتاب شناسایی) و c_2 (شتاب جمعی)، پارامترهای شناختی و اجتماعی نامیده می‌شوند و تعیین‌کننده‌ی میزان اطمینان به جریان ذرات و یا حرکت جامعه هستند و w پارامتر اینرسی وزنی نامیده می‌شود، که نقش مهمی در رفتار همگرایی الگوریتم PSO ایفا می‌کند؛ به طوری که مقدارهای زیاد w باعث افزایش مقدار بردار سرعت می‌شوند و در هر تکرار، گام‌های بزرگ‌تری برداشته خواهد شد و با کوچک شدن w ، گام‌های اخیر کوچک‌تر می‌شود که برای رسیدن به حالت بهینه در گام‌های آخر مفید است. از این رو، با قرار دادن یک رابطه مطابق رابطه‌ی ۱۶ جای مقداری ثابت برای w می‌توان به این مهم دست یافت. [۵۵] انتخاب مقدار مناسب

$$C(d) = -0.490 \left(\frac{d}{\sqrt{40}} \right) + 1.494 \quad (10)$$

$$\frac{f'_{cc}}{f'_{co}} = 1 + 2.18 \left(\frac{f_l}{f'_{co}} \right)$$

۳. روش‌های هوش مصنوعی مطالعه شده

۱.۳. رگرسیون اسپلاین چندمتغیره‌ی تطبیقی (MARS) ۱۸

رگرسیون اسپلاین چندمتغیره‌ی تطبیقی (MARS)، روش رگرسیونی غیرخطی و غیرپارامتریک است، که اولین بار توسط فریدمن ۱۹ معرفی شده است. MARS، پاسخ‌های غیرخطی را بین ورودی‌ها و خروجی یک سیستم به وسیله‌ی مجموعه‌ی از توابع خطی چندقطعه‌ی 2^0 با گزاردیان‌های متفاوت مدل‌سازی می‌کند. نقاط انتهایی توابع چندقطعه‌ی مذکور، گره نامیده می‌شوند. [۵۰] گره، انتهای یک ناحیه از داده‌ها و ابتدای ناحیه‌ی دیگر از داده‌ها را مشخص می‌کند. توابع چندقطعه‌ی خطی، انعطاف‌پذیری بیشتری را به مدل می‌دهند و انحنایها، آستانه‌ها و دیگر انحراف‌های حاصل از توابع خطی را نیز در نظر می‌گیرند. [۵۱] روش MARS، توابع محاسباتی را با جستجوی دو مرحله‌ی ایجاد می‌کند:

در مرحله‌ی اول، توابع محاسباتی چندقطعه‌ی جمع بسته می‌شوند و گره‌های احتمالی برای بهبود عملکرد مدل و برازش کامل‌تر مشخص می‌شوند. مرحله‌ی دوم نیز در برگزیده‌ی حذف کمترین جمله‌های حقیقی جهت جدا کردن توابع زائد و ارتقاء کیفیت و سرعت مدل است.

مدل MARS، به عنوان ترکیب خطی توابع و روابط متقابل آنها ایجاد و به صورت رابطه‌ی ۱۱ بیان می‌شود:

$$f(x) = \beta_0 + \sum_{m=1}^M \beta_m \lambda_m(x) \quad (11)$$

که در آن $\lambda_m(x)$ ، پارامتر هموارسازی نامیده می‌شود. هر $\lambda_m(x)$ ، یک تابع محاسباتی چندقطعه‌ی است، که می‌تواند از گزاردیان‌های مختلف تشکیل شود. مجموعه‌ی پارامترهای β ، ضرایب توابع هستند، که با استفاده از روش کمترین مربعات خطا برآورد می‌شوند. [۵۰]

۲.۳. ماشین یادگیری سریع (ELM) ۲۱

ماشین یادگیری سریع (ELM)، یک شبکه‌ی عصبی پیش‌خور برای طبقه‌بندی آماری و تحلیل رگرسیون با یک لایه‌ی پنهان به صورتی است که نیازی به تنظیم پارامترهای گره‌های پنهان نباشد. گره‌های پنهان می‌توانند به صورت تصادفی تخصیص داده شوند و وزن‌ها متناسب با آنها، برای فرایند مدل‌سازی برآورد شوند. در اغلب موارد، وزن خروجی گره‌های پنهان، معمولاً در یک مرحله گنجانده می‌شود، که اساساً به یادگیری یک مدل به صورت خطی می‌پردازد. روش ماشین یادگیری سریع توسط هوانگ ۲۲ معرفی و ارائه شده است. مدل ELM در ابتدا برای شبکه‌ی عصبی پیش‌خور پیشنهاد شده و سپس برای شبکه‌ی عصبی پیش‌خور تعمیم یافته گسترش یافته است. [۵۲] برخلاف روش‌های معمول یادگیری، مدل ELM نه فقط سعی می‌کند خطای داده‌های آموزش را کمینه سازد، بلکه سعی در کمینه‌سازی مقادیر وزن‌های خروجی نیز دارد. با توجه به تئوری بارلت ۲۳، برای شبکه‌های عصبی پیش‌خور، کاهش مقادیر وزن‌ها در کنار کاهش خطای آموزش به تعمیم‌پذیری بهتری می‌رسد. تابع خروجی‌های تعمیم‌یافته به صورت رابطه‌ی ۱۲ بیان می‌شود:

جدول ۱. پارامترهای ورودی و خروجی.

نوع	پارامتر	تعریف
	$d(mm)$	قطر استوانه‌ی بتنی
	$L(mm)$	طول استوانه‌ی بتنی
ورودی	$f'_{co}(MPa)$	مقاومت فشاری نهایی بتن محصور نشده
	$t(mm)$	ضخامت لایه‌ی FRP
	$f_i(MPa)$	فشار نهایی محصور شده
	$f_f(MPa)$	مقاومت کششی نهایی ورق FRP
خروجی	$f'_{cc}(MPa)$	مقاومت فشاری نهایی بتن محصور شده

جدول ۲. خصوصیات آماری برای داده‌های تجربی جمع‌آوری شده از برخی مطالعات پیشین. [۲۴-۴۰]

متغیر	بیشینه	میانگین	کمینه	انحراف معیار
$d(mm)$	۲۱۹	۱۳۳/۸۵۴	۵۱	۲۷/۲۸۳
$L(mm)$	۴۳۸	۲۷۲/۰۱۴	۱۰۲	۵۸/۲۵۰
$t(mm)$	۵/۹	۰/۸۳۵	۰/۰۸۹	۱/۱۳۳
$f'_{co}(MPa)$	۱۰۳	۴۲/۶۴۲	۱۹/۴	۱۷/۱۱۰
$f_i(MPa)$	۹۴/۵۷	۱۵/۸۵۷	۲/۳۳	۱۲/۴۶۳
$f_f(MPa)$	۳۸۲۰/۳۵۹	۲۱۲۳/۱۷۴	۲۲۹/۷۶۲	۱۱۱۲/۳۴۳
$f'_{cc}(MPa)$	۳۰۳/۶	۸۰/۴۴۸	۳۳/۸	۲۹/۱۷۳

داده‌ی آزمایشگاهی جهت ارائه‌ی مدل‌های محاسباتی تحلیل رفتار مقاومتی از برخی پژوهش‌های آزمایشگاهی، [۲۴-۴۰] جمع‌آوری شده است. سپس داده‌های جمع‌آوری شده به پارامترهای ورودی و خروجی تقسیم و در جدول ۱ ارائه شده‌اند.

مقادیر کمینه، بیشینه، میانگین و انحراف معیار داده‌های جمع‌آوری شده در جدول ۲ ارائه شده است. از کل داده‌ها به ترتیب ۷۰٪ (۱۹۷ داده) برای مرحله‌ی آموزش و ۳۰٪ (۸۴ داده) برای مرحله‌ی آزمایش استفاده شده است.

۲.۴. مدل‌سازی

۱.۲.۴. مدل MARS

به منظور ارزیابی اثرگذار بودن پارامترهای روش MARS (بیشترین مقدار گرادبان توابع^۳، بیشترین مقدار توابع^{۳۱} و پارامتر جریمه^{۳۲} جهت بهینه‌سازی ضرایب توابع) با استفاده از روش سعی و خطا بررسی شده‌اند. تعداد توابع ۱۰-۲۰۰ و گرادبان توابع از درجه‌های ۲ و ۳ انتخاب و در نهایت ۶۵ مدل ارزیابی شده‌اند، که با هر بار آنالیز گرفتن از مدل مذکور در نرم‌افزار متلب^{۳۳}، نتایج مختلفی با جواب‌های متفاوت ارائه شده است. ۱۰ مدل که بهترین عملکرد را در مرحله‌ی آزمایش داشتند، در شکل ۴ مشاهده می‌شوند، که مطابق آن، مدل MARS شماره‌ی ۶ با مقدار تابع بهینه‌ی ۳۱، گرادبان تابع بهینه از درجه‌ی ۲ و ضریب همبستگی ۰/۹۵۵۴ در مرحله‌ی آزمایش، بهترین عملکرد را داشته و به عنوان مدل نهایی انتخاب شده است.

در مدل‌سازی روش MARS، برازش در هر تابع پایه به صورت جداگانه صورت می‌پذیرد و رابطه‌ی مرتبط به برازش ارائه می‌شود. متغیرها و محل‌های گره برای هر متغیر، از طریق روش جستجوی سریع اما متمرکز تعیین می‌شوند. همچنین انتخاب

برای پارامترهای ذکر شده منجر به تسریع همگرایی الگوریتم و جلوگیری از همگرایی زودرس در بهینه‌های محلی می‌شود. [۵۷]

$$W_{k+1} = W_{max} - \frac{W_{max} - W_{min}}{k_{max}} k \quad (16)$$

همان‌طور که در مطالعات اخیر عنوان شده است، مقادیر W_{max} و W_{min} به ترتیب برابر با ۹/۰ و ۴/۰ هستند. همچنین بهترین مقادیر برای پارامترهای c_1 و c_2 برابر با ۱ و ۲ است. در الگوریتم PSO، موقعیت اولیه‌ی پرندگان به صورت تصادفی در فضای مجاز طراحی $[X^u X^l]$ انتخاب می‌شود. سپس سرعت اولیه‌ی پرندگان (V_1) در بازه‌ی $[v_{min}, v_{max}]$ به طور تصادفی مقداردهی می‌شود. در ماتریس ذکر شده، p تعداد ذرات و n تعداد متغیرهای طراحی است؛ v_{min} ، v_{max} و V_1 با استفاده از روابط ۱۷ و ۱۸ تعیین می‌شوند. [۵۶]

$$v_{min} = -\frac{1}{p}(x^u - x^l), \quad v_{max} = \frac{1}{p}(x^u - x^l) \quad (17)$$

$$V_1 = v_{min} \begin{bmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 1 \end{bmatrix} + \begin{bmatrix} r_{1,1} & \dots & r_{1,i} & \dots & r_{1,n} \\ \vdots & & \vdots & & \vdots \\ r_{p,1} & \dots & r_{p,i} & \dots & r_{p,n} \end{bmatrix}_{p \times n} \cdot (v_{max} - v_{min}) \quad (18)$$

همچنین در رابطه‌ی اخیر، $r_{p,n}$ مقادیر تصادفی بین صفر و یک است.

۴.۳. عوامل ارزیابی مدل‌ها

برای مقایسه‌ی عملکرد مدل‌های ارائه شده در مراحل آموزش و آزمایش، از شاخص‌های آماری مطابق روابط ۱۹ الی ۲۱، شامل ضریب همبستگی (R)^{۲۷}، ریشه‌ی میانگین مربعات خطا (RMSE)^{۲۸} و میانگین مطلق درصد خطا (MAPE)^{۲۹} استفاده شده است. [۵۸، ۵۹]

$$R = \frac{\sum_{i=1}^N (q_i - \bar{q})(\hat{q}_i - \bar{\hat{q}})}{\sqrt{\sum_{i=1}^N (q_i - \bar{q})^2 \sum_{i=1}^N (\hat{q}_i - \bar{\hat{q}})^2}} \quad (19)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (q_i - \hat{q}_i)^2} \quad (20)$$

$$MAPE = \frac{100}{N} \sum_{i=1}^N \frac{|q_i - \hat{q}_i|}{q_i} \quad (21)$$

در روابط اخیر، N تعداد داده‌ها، q_i مقدار مشاهداتی و \hat{q}_i مقدار برآورد شده توسط مدل است.


۴. بحث و نتایج

۱.۴. داده‌های آزمایشگاهی

مطالعات آزمایشگاهی بسیاری بر روی بتن محصور شده با FRP انجام شده است. بررسی رفتار مقاومتی بتن محصور شده با FRP با استفاده از مدل‌های هوش مصنوعی، نیازمند یک پایگاه داده‌ی آزمایشگاهی جامع است. بدین منظور، ۲۸۱

جدول ۳. پارامترهای الگوریتم فراابتکاری ازدحام ذرات جهت بهینه‌سازی.


پارامتر	مقدار
تعداد تکرار	۱-۱۰۰
تعداد ذرات	۱۰-۵۰
نسبت میرایی وزن اینرسی	۰/۹۹
شتاب شناسایی	۱
شتاب جمعی	۲
وزن اینرسی اولیه	۱




شکل ۶. روند همگرایی نتایج.

را بیابد. در پژوهش حاضر، جهت افزایش دقت مدل‌های هوش مصنوعی استفاده شده، الگوریتم فراابتکاری ازدحام ذرات به عنوان بهینه‌ساز شبکه‌ی مدل‌ها استفاده شده است. اختصاص مقادیر پارامترهای تنظیمی مدل، یکی از عوامل بسیار تأثیرگذار در میزان عملکرد آموزش است. هر ذره در مدل MARS، شامل: تعداد توابع، درجه‌ی توابع و ضرایب توابع است؛ در حالی که در مدل ELM، وزن و بایاس در هر ذره در فرایند بهینه‌سازی قرار می‌گیرد. به جهت بررسی و تنظیم مقادیر پارامترهای الگوریتم ازدحام ذرات، پس از بررسی محدوده‌ی تنظیمی مقادیر مذکور از برخی مطالعات مشابه^[۵۷، ۶۰-۶۳] از روش سعی و خطا جهت تعیین مقادیر بهینه‌ی پارامترهای الگوریتم استفاده شده است. بدین ترتیب، برنامه‌ی در نرم‌افزار متلب راه‌اندازی شد، که فرایند سعی و خطا را به صورت خودکار و با هدف تعیین بهترین معماری اجرا کند. برنامه‌ی مذکور با ارزیابی تعداد مختلف پارامترهای مدل، معماری مناسب را با شرط کمینه‌سازی خطا به عنوان تابع هدف در داده‌های مرحله‌ی آزمایش پیدا می‌کند. برای این منظور، تعداد جمعیت در محدوده‌ی ۱۰ تا ۵۰ و تعداد تکرار در محدوده‌ی ۱-۱۰۰ بررسی و ارزیابی شده است. در جدول ۳، محدوده‌ی بررسی پارامترهای تنظیمی الگوریتم ازدحام ذرات پس از بررسی در مطالعات اشاره شده‌ی پیشین و سعی و خطا ارائه شده است (شکل ۶). همان‌طور که مشخص است، روند کاهش خطا در تعداد جمعیت ۳۰ به علت به کمینه رسیدن میزان خطا و روند نزولی آن با شیب بیشتر، قابل بررسی است. در نهایت مشاهده می‌شود که الگوریتم در تکرار ۵۴ با خطای ۰/۰۶۱ ثابت شده است. ارزیابی‌ها نشان می‌دهند که مدل MARS-PSO با مقدار تابع بهینه‌ی ۴۳ و گرادیان تابع بهینه از درجه‌ی ۲ و مدل ELM-PSO با تعداد ۱۳ نوروں بهترین نتیجه را حاصل کرده‌اند.

جهت بررسی روند تخمین مقاومت فشاری ستون‌های بتنی با مقاطع دایره‌یی



شکل ۴. منتخب مدل‌های ارزیابی شده‌ی روش MARS.



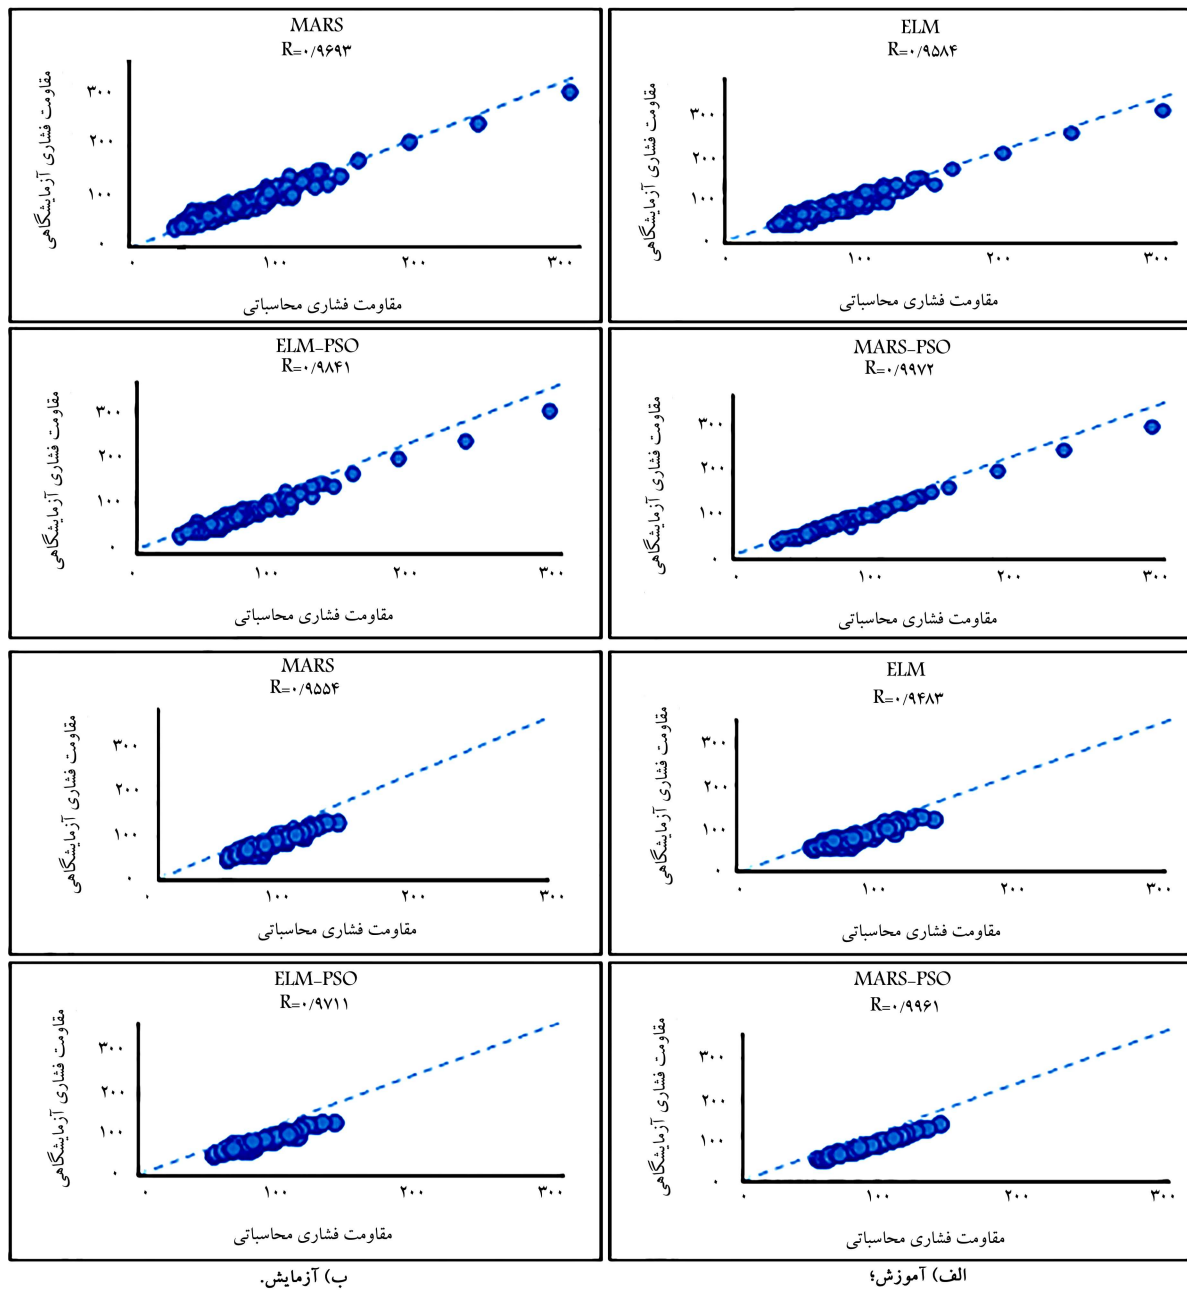
شکل ۵. مقادیر درصد خطا در نوروں‌های مختلف روش ELM.

مقدم و روش حذفی مؤخر، به عنوان تضمین‌کننده‌ی مدل بهینه تشخیص داده می‌شود. یکی از مزیت‌های روش MARS سرعت همگرایی آن است، که در زمان پردازش آن مشهود است. شبکه‌های عصبی به لحاظ ساختار الگوریتم، کارآمد نبودن در انجام سریع محاسبات و فرایند طولانی تعیین پیکربندی شبکه‌ی بهینه، انتقاد شده‌اند؛ چرا که الگوریتم مذکور از راه قیاس شناخته نمی‌شود، بلکه از طریق رویکرد آزمون و خطا تعیین می‌شود.^[۵۰]

۲.۲.۴. مدل ELM

روش ELM، رویکردی بسیار ساده، با سرعت یادگیری بالا است و سرعت یادگیری آن در مقایسه با شبکه‌ی عصبی بسیار بیشتر است. به منظور مدل‌سازی روش ELM از رویکرد یادگیری عمیق با بهبود روش شبکه‌ی عصبی مصنوعی استفاده شده است. از این رو، از یک لایه‌ی مخفی برای پیش‌بینی مقاومت فشاری و یک تابع سیگموئید با تعداد نوروں ۱-۱۰۰ برای فرایند یادگیری مدل استفاده شده است. برای اجرای پارامترهای تنظیمی مدل نیز، تعداد تکرار ۲۰۰۰ در نظر گرفته شده و مقدار خطای میانگین برای لایه‌ی مخفی محاسبه شده است. در نهایت مدلی به عنوان بهترین مدل انتخاب می‌شود که در مرحله‌ی آزمایش مقدار خطای کمتری داشته باشد. افزایش تعداد نوروں‌ها از محدوده‌ی خاص، به عنوان مثال بالای ۳۰ نوروں، باعث افزایش درصد خطا و ضعف در عملکرد مدل می‌شود. عملکرد مدل‌های انجام شده از ۱ الی ۳۰ نوروں در مرحله‌ی آزمایش، در شکل ۵ مشاهده می‌شود. بدین ترتیب مدل نهایی با تعداد ۲۶ نوروں و ضریب همبستگی ۰/۹۴۸۳ و درصد خطای ۵/۴۱ در مرحله‌ی آزمایش، به عنوان بهترین مدل انتخاب شده است.

۳.۲.۴. مدل‌های تلفیقی بهینه شده با الگوریتم فراابتکاری ازدحام ذرات هر روش بهینه‌سازی تلاش می‌کند که از میان تمامی پاسخ‌های شدنی، پاسخ بهینه



شکل ۷. نمودار پراکندگی مقادیر مقاومت فشاری مدل‌های توسعه‌یافته در دو مرحله.

محصور شده با الیاف پلیمری FRP، مدل‌های هوشمند توسعه یافته و بررسی و ارزیابی کمی و کیفی شده‌اند. طبق جدول ۴، ضریب همبستگی در مرحله‌ی آموزش برای مدل MARS و ELM به ترتیب 0.9693 و 0.9584 بوده است؛ در حالی که ضریب همبستگی در مدل‌های بهینه شده‌ی تلفیقی MARS-PSO و ELM-PSO به ترتیب به مقادیر 0.9972 و 0.9841 رسیده است؛ همان‌طور که مشاهده می‌شود، مدل‌های مذکور، به درستی آموزش دیده و ضعف اشاره شده در مدل‌های پایه‌ی را بهبود بخشیده و عملکرد خوبی از خود نشان داده‌اند. نتایج نشان می‌دهند که مدل MARS بهبودیافته با الگوریتم ازدحام ذرات

در پی داشته است. همچنین نتایج نشان می‌دهند استفاده از الگوریتم فراابتکاری، ضعف‌های آموزشی در مدل را بهبود بخشیده و باعث افزایش همگرایی نتایج شده است.

در شکل ۷، مقادیر مقاومت فشاری آزمایشگاهی و پیش‌بینی شده‌ی نظیر آن توسط مدل‌های هوش مصنوعی استفاده شده در پژوهش حاضر برای مراحل

نتایج نشان می‌دهند که مدل MARS بهبودیافته با الگوریتم ازدحام ذرات (MARS-PSO) با مقادیر بهینه‌ی ۴۲ تابع و بیشترین مقدار درجه‌ی تابع ۲ و مقدار تابع جریمه‌ی ۳، ضریب همبستگی 0.9961 در مرحله‌ی آموزش داشته و

جدول ۴. ارزیابی عملکرد مدل‌های پیشنهادی.

مراحل	مدل‌ها	R	RMSE	MAPE(%)
آموزش	MARS	۰/۹۶۹۳	۸/۲۰	۱۰/۱۲
	ELM	۰/۹۵۸۴	۱۰/۱۲	۱۳/۱۵
	MARS-PSO	۰/۹۹۷۲	۲/۴۵	۲/۶۸
	ELM-PSO	۰/۹۸۴۱	۶/۰۱	۷/۱۱
آزمایش	MARS	۰/۹۵۵۴	۵/۸۹	۵/۰۶
	ELM	۰/۹۴۸۳	۶/۲۸	۵/۴۱
	MARS-PSO	۰/۹۹۶۱	۱/۹۹	۲/۰۱
	ELM-PSO	۰/۹۷۱۱	۴/۸۷	۳/۹۳

جدول ۵. زمان پردازش مدل‌ها.

مدل	MARS	ELM	MARS - PSO	ELM - PSO
زمان (ثانیه)	۳۹/۱۲	۵۳/۲۷	۹۱/۰۵	۸۷/۶۴

جدول ۶. مقایسه‌ی عملکرد مدل‌ها با برخی مطالعات پیشین.

مدل‌ها	R (کل)	RMSE (کل)	MAPE(%) (کل)
MARS	۰/۹۶۷۳	۷/۵۸	۸/۶۱
ELM	۰/۹۵۶۱	۹/۱۴	۱۰/۸۴
MARS-PSO	۰/۹۹۷۰	۲/۳۲	۲/۴۸
ELM-PSO	۰/۹۸۲۱	۵/۶۹	۶/۱۶
رازا ^{۳۴} و همکاران ^[۲۲]	۰/۹۵۳۹	۳/۱۸	۲/۹۳
فلاح‌پور و همکاران ^[۲۳]	۰/۷۴۱۵	۱۴/۹۰	۱۲/۳۰
کشتگر و همکاران ^[۲۴]	۰/۹۵۲۰	۳/۴۰	۳/۷۴
صادقیان و فام ^[۲۵]	۰/۹۴۹۷	۳/۷۷	۴/۱۸
فام و هادی ^[۲۶]	۰/۹۳۸۱	۲/۳۶	۹/۸۸
رتالفونسو و ناپولی ^[۲۷]	۰/۷۴۵۳	۱۳/۸۰	۱۴/۵۵
نادرپور و همکاران ^[۲۸]	۰/۷۶۸۶	۱۲/۸۶	۸/۴۴
وینتزلیتو و پاناژیوتیدو ^[۲۹]	۰/۷۲۸۸	۲۰/۶۴	۱۵/۴۲

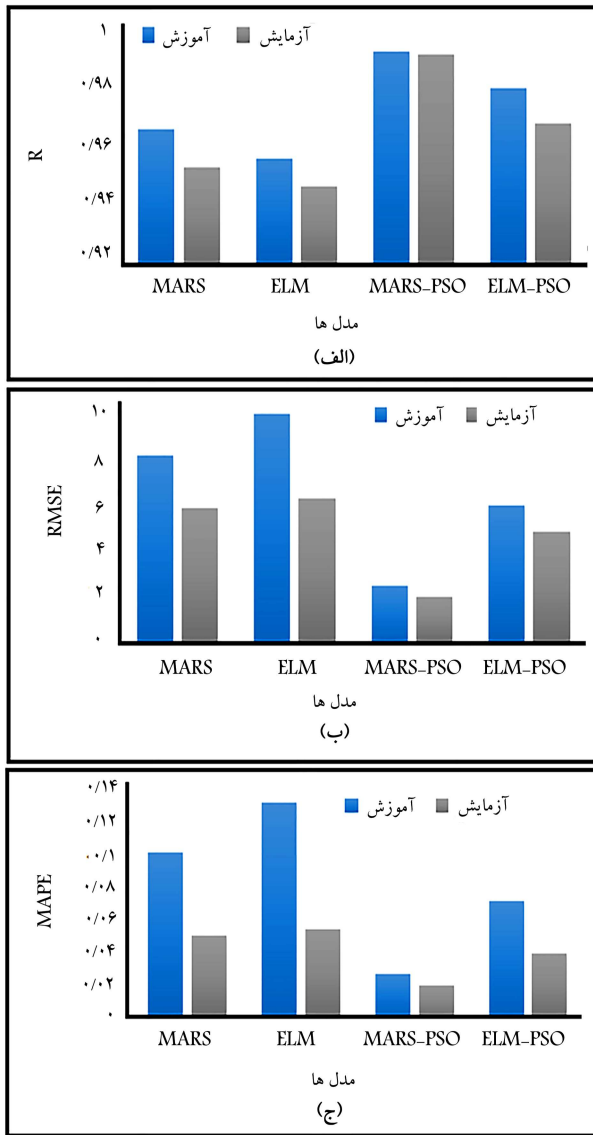
^{۳۴}Raza^{۳۵}Realfonso&Napoli^{۳۶}Vintzileou&Panagiottidou

آموزش و آزمایش مشاهده می‌شود؛ که مطابق آن، بیشتر مقادیر مقاومت فشاری بر روی خط نیمساز ربع اول محورهای مختصات، خط $(y=x)$ ، متمرکز است و فقط تعداد کمی از نقاط مذکور، خارج از منطقه تمرکز هستند، که میزان آنها با تلفیق فرایند الگوریتمی کاسته شده و این امر تصدیقی بر درستی فرایندها و دقت بالای آنها بوده است. در شکل مذکور مشخص است که تخمین مقاومت فشاری بتن محصور شده با FRP برای ستون‌های دایره‌ای با استفاده از مدل‌های هوش مصنوعی مناسب بوده و عملکرد خوبی داشته است. همچنین مقایسه‌ی انجام شده نشان می‌دهد روش MARS-PSO، عملکرد بهتری نسبت به سایر روش‌ها داشته است.

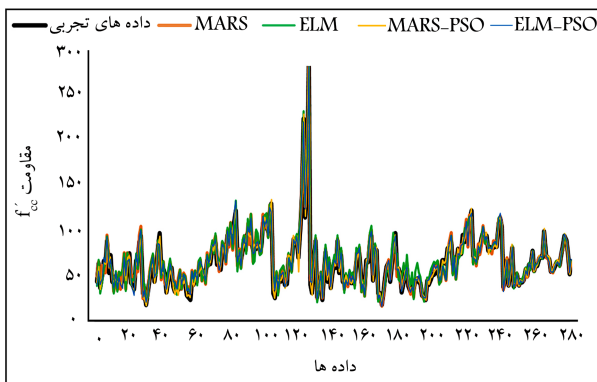
زمان پردازش مدل‌ها در جدول ۵ ارائه شده است، که مطابق آن مشخص است در الگوریتم فرابتنکاری ازدحام ذرات، به علت انجام فرایند بهینه‌سازی و ارتقاء مدل‌ها، زمان مدل‌سازی افزایش یافته است. در شکل ۸، مراحل خطای آموزش و آزمایش مدل‌ها در قالب نمودار هیستوگرام

مشاهده می‌شود، که مطابق آن در مدل MARS-PSO، بیشترین میزان خطا در محدوده‌ی $[۰/۶۸, ۰/۷۴]$ و در مدل MARS، در محدوده‌ی $[۰/۶۴, ۰/۸۹]$ بوده است. با بررسی بیشتر هیستوگرام مشاهده می‌شود که روند بهبود تعداد مقادیر خطا در مدل تلفیقی به جهت بهینه‌یابی درست پارامترهای تنظیمی بیشتر شده و تقریباً در تمامی محدوده‌های بررسی شده، میزان خطای مقادیر بالا، کاهش و خطاهای مقادیر پایین به همان نسبت افزایش یافته است.

نمودار مقایسه‌ی عملکرد مدل‌های ارائه شده در دو مرحله‌ی آموزش و آزمایش با ۳ شاخص آماری MAPE, RMSE, R در شکل ۹ مشاهده می‌شود، که مطابق آن برای مدل‌های MARS و ELM در هر دو مرحله‌ی آموزش و آزمایش، مقادیر RMSE و MAPE در حالت بیشینه‌ی خود، یعنی بیشترین میزان خطا و ضریب همبستگی در پایین‌ترین مقدار خود قرار دارد، که این امر ضعف دو مدل مذکور را نشان می‌دهد. اما در مدل‌های بهینه‌یابی تلفیقی MARS-PSO و ELM-PSO، ضعف اشاره شده با افزایش ضریب همبستگی و کاهش میزان

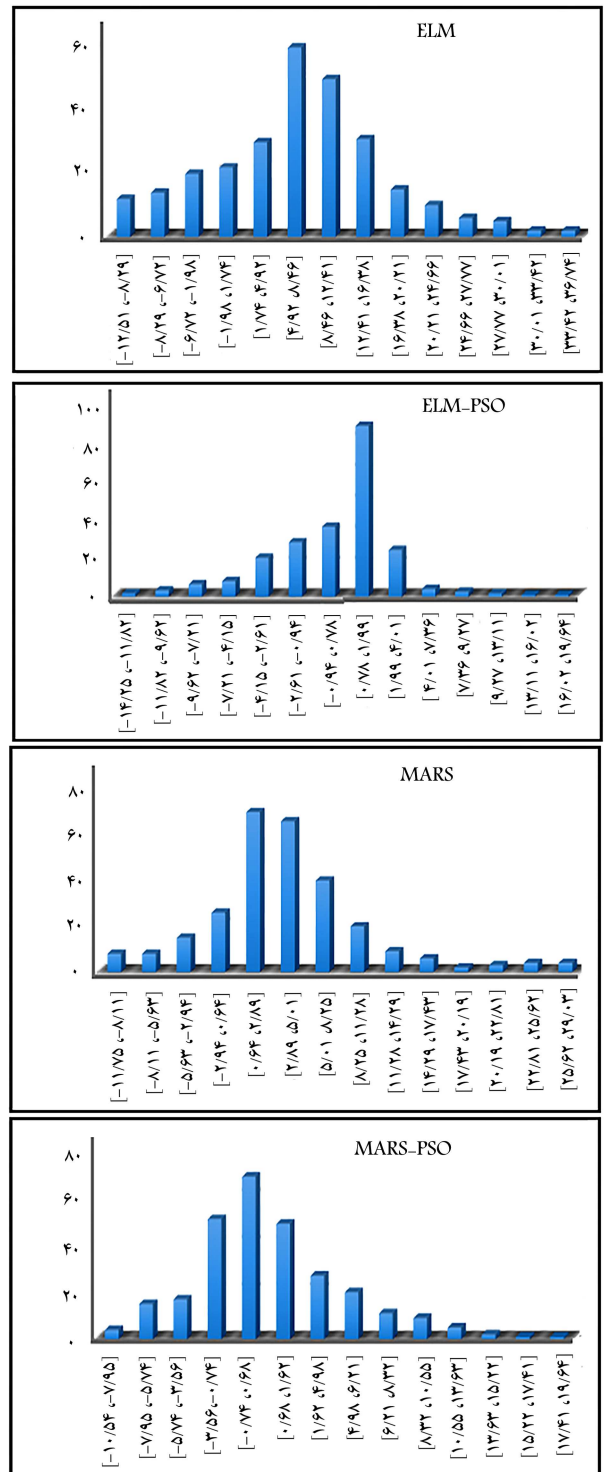


شکل ۹. نمودار مقایسه‌ی عملکرد مدل‌ها.



شکل ۱۰. نمودار مقایسه‌ی مدل‌ها با داده‌های تجربی.

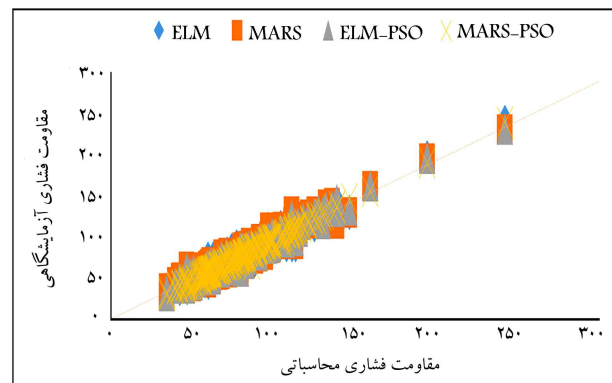
هستند و نشان‌دهنده‌ی کارایی مطلوب مدل‌های ارائه شده در پیش‌بینی مقاومت فشاری بتن محصور شده با FRP است. مقایسه بین نتایج شبیه‌سازی شده و تجربی برای تخمین مقاومت فشاری در



شکل ۸. هیستوگرام توزیع خطای نسبی در مدل‌ها.

خطا بهبود یافته است. بدین ترتیب، با بررسی نمودارها مشخص می‌شود که روش MARS-PSO در مقایسه با سایر روش‌ها، بیشترین همبستگی و کمترین میزان خطا را داشته است.

نمودار مقایسه‌ی مقاومت فشاری مدل‌ها با داده‌های تجربی در شکل ۱۰ مشاهده می‌شود، که مطابق آن، مقادیر مقاومت فشاری حاصل از خروجی مدل‌ها بسیار نزدیک به داده‌های تجربی و آزمایشگاهی استفاده شده در پژوهش حاضر



شکل ۱۱. نمودار پراکندگی نتایج شبیه‌سازی شده برای تخمین مقاومت فشاری.

شکل ۱۱ مشاهده می‌شود، که مطابق آن، نتایج شبیه‌سازی شده کاملاً با نتایج تجربی مطابقت دارند. همچنین لازم ذکر است که می‌توان از مدل‌های مذکور در پروژه‌های عملی برای ارزیابی میزان مقاومت فشاری ستون تقویت شده توسط ورق‌های FRP در طراحی اولیه استفاده کرد.

۵. تفسیر نتایج و مقایسه با سایر مطالعات

به منظور مقایسه‌ی عملکرد مدل‌های پیشنهادی با روش‌های موجود و بررسی صحت مدل‌های ذکر شده در پیش‌بینی نتایج تجربی، مقادیر ضریب همبستگی مدل‌های اخیر و محدوده‌ی خطای هر پیش‌بینی در جدول ۶ ارائه شده است. بررسی و مقایسه‌ی عملکرد مطالعات انجام شده در پژوهش حاضر با برخی مطالعات پیشین، نشان می‌دهد که استفاده از روش‌های پیشنهادی برای پیش‌بینی مقاومت فشاری بتن محصور شده، در مقایسه با سایر روش‌های موجود در برخی مطالعات پیشین، قادر به ارائه‌ی نتایج دقیق‌تری بوده است. بدین ترتیب، استفاده از روش‌های پیشنهادی، بالاخص روش بهینه‌ی تلفیقی MARS-PSO، باعث افزایش ضریب همبستگی و کاهش میزان خطا نسبت به میانگین ضریب همبستگی و درصد خطا در روش‌های تجربی پیشین شده است.

۶. نتیجه‌گیری

در پژوهش حاضر، برای تخمین مقاومت فشاری ستون‌های بتنی دایره‌ی محصور شده با FRP، از روش‌های هوش مصنوعی که شامل روش‌های اسپلاین رگرسیون چندمتغیره‌ی انطباقی و ماشین یادگیری سریع هستند، استفاده شده است. به جهت بهبود ضعف‌های مشاهده شده در مدل‌ها و بهینه‌یابی ضرایب و وزن‌ها از الگوریتم فراابتکاری ازدحام ذرات در جهت تلفیق با مدل‌ها و ارائه‌ی روابط محاسباتی هوشمند

تلفیقی استفاده شده است. برای توسعه‌ی مدل‌ها، تعداد ۲۸۱ داده از نمونه‌های بتنی استوانه‌ی محصور شده با FRP به عنوان مدل‌های آزمایشگاهی از ستون‌های بتنی محصور شده با FRP استفاده شده‌اند. سپس از روش‌های ذکر شده برای تخمین مقاومت فشاری استفاده شده است. در نهایت با استفاده از روابط متداول برای سنجش خطای مدل‌ها و با توجه به معیارهای تعیین خطا، مقایسه‌ی میان روش‌های ذکر شده با هوش مصنوعی و مدل‌های تخمین مطالعات پیشین انجام شده است. نتایج حاصل از پژوهش حاضر به این صورت خلاصه شده است:

۱. برای مدل‌های ELM و MARS در هر دو مرحله‌ی آموزش و آزمایش، مقادیر RMSE، MAPE در حالت بهینه‌ی خود، یعنی بیشترین میزان خطا و ضریب همبستگی در پایین‌ترین مقدار خود قرار داشته‌اند، که این امر ضعف دو مدل مذکور را نشان می‌دهد؛ اما استفاده از الگوریتم ازدحام ذرات، ضعف‌های آموزشی در مدل را بهبود بخشیده و همگرایی نتایج را افزایش داده است، به طوری که در مدل‌های بهینه‌ی تلفیقی ELM-PSO و MARS-PSO، میزان خطا در مرحله‌ی آموزش به ترتیب ۳/۰۵ و ۱/۴۸ درصد نسبت به مدل‌های MARS و ELM کاهش یافته است.

۲. مقایسه‌ی ضریب همبستگی (R) در مدل‌های ELM، MARS، MARS-PSO و PSO نشان می‌دهد در میان مدل‌های ارائه شده، مدل MARS-PSO بیشترین ضریب همبستگی (۰/۹۹۷۲) در مرحله‌ی آموزش و (۰/۹۹۶۱) در مرحله‌ی آزمایش را با نتایج آزمایشگاهی داشته است.

۳. مقایسه‌ی مقادیر مقاومت فشاری پیش‌بینی شده توسط روش‌های هوش مصنوعی و مقادیر آزمایشگاهی نشان می‌دهد که بیشتر مقادیر مقاومت فشاری بر روی خط $(y=x)$ ، متمرکز بوده است، که این امر تصدیق بر درستی فرایندها و دقت بالای آنهاست.

۴. مقادیر مقاومت فشاری حاصل از خروجی مدل‌ها بسیار نزدیک به داده‌های تجربی و آزمایشگاهی استفاده شده در پژوهش حاضر بوده است، که نشان‌دهنده‌ی کارایی مطلوب مدل‌های ارائه شده در پیش‌بینی مقاومت فشاری بتن محصور شده با FRP برای ستون‌های دایره‌ی است.

۵. بررسی و مقایسه‌ی عملکرد مطالعات انجام شده در پژوهش حاضر با سایر روش‌های موجود در برخی مطالعات پیشین نشان می‌دهد که استفاده از روش‌های پیشنهادی هوش مصنوعی و الگوریتم‌های فراابتکاری، بالاخص روش بهینه‌ی تلفیقی MARS-PSO، باعث افزایش ضریب همبستگی تا ۰/۹۹۷۰ و کاهش میزان خطا به مقدار ۶/۴۵ درصد نسبت به میانگین درصد خطا در مدل‌های تجربی گذشته شده است.

۶. در پروژه‌های عملی برای ارزیابی میزان مقاومت فشاری ستون تقویت شده توسط ورق‌های FRP می‌توان از مدل‌های ذکر شده، در طراحی اولیه استفاده کرد.

پانویس‌ها

1. fiber reinforced polymer
2. Topcu & Saridemir
3. artificial neural network

4. fuzzy logic
5. Altun
6. Cascardi
7. confined concrete filled tubular short columns
8. reinforced concrete beam
9. adaptive network-based fuzzy inference system

10. calcium inosilicate minerals
11. carbon fiber reinforced polymer
12. glassfiber reinforced polymer
13. Sun
14. Asteris
15. DeRousseau
16. Feng
17. Sevim
18. multivariate adaptive regression splines
19. Friedman
20. splines
21. extreme learning machine
22. Huang
23. Barlet's theory
24. particle swarm optimization
25. Kennedy and Eberhart
26. Clerc and Lazinica
27. correlation coefficient
28. root mean square error
29. mean absolute percentage error
30. max interaction
31. max BF
32. C parameter
33. Matlab

منابع (References)

1. Haji, M., Naderpour, H. and Kheyroddin, A. "Experimental study on influence of proposed FRPStrengthening techniques on RC circular short columns considering different types of damage index", *Compos. Struct.*, **209**, pp. 112-128 (2019).
2. Fardis, M.N. and Khalili, H. "Concrete encased in fiberglass-reinforced-plastic", *Journal of the American Concrete Institute*, **78**(6), pp. 440-446 (1981).
3. Fam, A. and Rizkalla, S.H. "Behavior of axially loaded concrete-filled circular FRP tubes", *ACI Structural Journal*, **98**(3), pp. 280-289 (2001).
4. Pessiki, S., Harries, K.A., Kestner, J.T. and et al. "Axial behavior of reinforced concrete columns confined with FRP Jjackets", *Journal of Composites for Construction*, **5**(4), pp. 237-245 (2001).
5. Topcu, B.I. and Sandemir, M. "Prediction of compressive strength of concrete containing fly ash using artificial neural networks and fuzzy logic", *Computational Materials Science*, **41**(3), pp. 305-311 (2008).
6. Topcu, B.I. and Sarıdemir, M. "Prediction of rubberized concrete properties using artificial neural network and fuzzy logic", *Construction and Building Materials*, **22**(4), pp. 532-540 (2008).
7. Altun, F., Kişi, Ö. and Aydın, K. "Predicting the compressive strength of steel fiber added lightweight concrete using neural network", *Computational Materials Science*, **42**(2), pp. 259-265 (2008).
8. Cascardi, A., Micelli, F. and Aiello, M.A. "An artificial neural networks model for the prediction of the compressive strength of FRP-confined concrete circular columns", *Eng. Struct.*, **140**, pp. 199-208 (2017).
9. Ahmadi, M., Naderpour, H. and Kheyroddin, A. "Utilization of artificial neural networks to prediction of the capacity of CCFT short columns subject to short term axial load", *Arch. Civ. Mech. Eng.*, **14**(3), pp. 510-517 (2014).
10. Ahmadi, M., Naderpour, H. and Kheyroddin, A. "ANN model for predicting the compressive strength of circular steel-confined concrete", *Int. J. Civ. Eng.*, **15**(2), pp. 213- 221 (2017).
11. Naderpour, H. and Alavi, S.A. "A proposed model to estimate shear contribution of FRP in strengthened RC beams in terms of adaptive neuro-fuzzy inference system", *Compos. Struct.*, **170**, pp. 215- 227 (2017).
12. Naderpour, H., Rafiean, A.H. and Fakharian, P. "Compressive strength prediction of environmentally friendly concrete using artificial neural networks", *J. Build. Eng.*, **16**, pp. 213- 219 (2018).
13. Keshavarz, Z. and Torkian, H. "Application of ANN and ANFIS models in determining compressive strength of concrete", *Soft. Comput. Civ. Eng.*, **2**(1-3), pp. 62-70 (2018).
14. Naderpour, H. and Mirrashid, M. "An innovative approach for compressive strength estimation of mortars having calcium inosilicate minerals", *J. Build. Eng.*, **19**, pp. 205-215 (2018).
15. Mahmoudabadi, M. and Sakhaeipour, F. "Numerical analysis on the influence of the cross section of ultimate capacity of reinforced concrete columns reinforced with CFRP", *Journal of Structural and Construction Engineering*, **7**(1-31), pp.107-125 (2020).
16. Sajedi, F., Shafieinia, M. and Razavi Toosi, V. "Investigation on the behaviour of reinforced concrete columns made of high-strength concrete, enclosed with GRP casing and CFRP sheets", *Journal of Structural and Construction Engineering*, **7**(4-6), pp.202-219 (2020).
17. Sun, L., Koopialipoor, M., Armaghani, D.J. and et al. "Applying a meta-heuristic algorithm to predict and optimize compressive strength of concrete samples", *Engineering with Computers*, **37**(13), pp. 1133-1145 (2019).
18. Asteris, P.G., Ashrafiyan, A. and Rezaie-Balf, M. "Prediction of the compressive strength of self-compacting concrete using surrogate models", *Computers and Concrete*, **24**(2), pp. 137-150 (2019).
19. DeRousseau, M.A., Laftchiev, E., Kasprzyk, J.R. and et al. "A comparison of machine learning methods for predicting the compressive strength of field-placed concrete", *Construction and Building Materials*, **228**, 116661 (2019).
20. Golafshani, E.M., Behnood, A. and Arashpour, M. "Predicting the compressive strength of normal and high-performance concretes using ANN and ANFIS hybridized with grey wolf optimizer", *Construction and Building Materials*, **232**, 117266 (2020).
21. Feng, D.C., Liu, Z.T., Wang, X.D. and et al. "Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach", *Construction and Building Materials*, **230**, 117000 (2020).
22. Akbari, M. and Deligani, V.J. "Data driven models for compressive strength prediction of concrete at high temperatures", *Frontiers of Structural and Civil Engineering*, **14**(2), pp. 311-321 (2020).

23. Sevim, U.K., Bilgic, H.H., Cansiz, O.F. and et al. "Compressive strength prediction models for cementitious composites with fly ash using machine learning techniques", *Construction and Building Materials*, **271**, 121584 (2021).
24. Saafi, M., Toutanji, H. and Li, Z. "Behavior of concrete columns confined with fiber reinforced polymer tubes", *Mater. J.*, **96**, pp. 500-509 (1999).
25. Toutanji, H. "Stress-strain characteristics of concrete columns externally confined with advanced fiber composite sheets", *Mater. J.*, **96**, pp. 397-404 (1999).
26. Kono, S., Inazumi, M. and Kaku, T. "Evaluation of confining effects of CFRP sheets on reinforced concrete members", *In Proceedings of the 2nd International Conference on Composites in Infrastructure National Science Foundation*, Tucson, AZ, USA (1998).
27. Ahmad, S., Khaloot, A. and Irshaid, A. "Behaviour of concrete spirally confined by fibreglass filaments", *Mag. Concr., Res.*, **43**(156), pp.143-148 (1991).
28. Fam, A.Z. and Rizkalla, S.H. "Concrete-filled FRP tubes for flexural and axial compression members", *In Proceedings of the 3rd International Conference on Advanced Composite Materials in Bridges and Structures*, Ottawa, ON, Canada (2000).
29. Harmon, T.G. and Slattery, K.T. "Advanced composite confinement of concrete", *In Proceedings of the 1st International Conference on Advanced Composite Materials in Bridges and Structures*, Sherbrooke, QC, Canada (1992).
30. La Tegola, A. and Manni, O. "Experimental investigation on concrete confined by fiber reinforced polymer and comparison with theoretical model", *Spec. Publ.*, **188**, pp. 243-254 (1999).
31. Matthys, S., Taerwe, L. and Audenaert, K. "Tests on axially loaded concrete columns confined by fiber reinforced polymer sheet wrapping", *Spec. Publ.*, **188**, pp. 217-228 (1999).
32. Micelli, F., Myers, J. and Murthy, S. "Effect of environmental cycles on concrete cylinders confined with FRP", *In Proceedings of the CCC2001 International Conference on Composites in Construction*, Porto, Portugal (2001).
33. Mirmiran, A. and Shahawy, M. "Behavior of concrete columns confined by fiber composites", *J. Struct. Eng.*, **123**(5), pp. 583-590 (1997).
34. Miyauchi, K. "Estimation of strengthening effects with carbon fiber sheet for concrete column", *In Proceedings of the 3rd International Symposium on Non-Metallic (FRP) Reinforcement for Concrete Structures*, Sapporo, Japan (1997).
35. Nanni, A. and Bradford, N.M. "FRP jacketed concrete under uniaxial compression", *Constr. Build. Mater.*, **9**(2), pp. 115-124 (1995).
36. Picher, F., Rochette, P. and Labossière, P. concrete cylinders with CFRP", *In Proceedings of the International Conference on Composites in Infrastructure*, Tucson, AZ, USA (1996).
37. Rochette, P. and Labossiere, P. "Axial testing of rectangular column models confined with composites", *J. Compos. Constr.*, **4**(3), pp. 129-136 (2000).
38. Rousakis, T. and Tepfers, R. "Experimental investigation of concrete cylinders confined by carbon FRP sheets, under monotonic and cyclic axial compressive load", *Chalmers University of Technology*, Goteborg, Sweden (2001).
39. Shahawy, M., Mirmiran, A. and Beitelman, T. "Tests and modeling of carbon-wrapped concrete columns", *Compos., Part B Eng.*, **31**(6-7), pp. 471-480 (2000).
40. Watanabe, K., Nakamura, H., Honda, Y. and et al. "Confinement effect of FRP sheet on strength and ductility of concrete cylinders under uniaxial compression", *In Proceedings of the 3rd International Symposium (FRPRCS-3) on Non-Metallic (FRP) Reinforcement for Concrete Structures*, Sapporo, Japan, pp. 233-240 (1997).
41. State Planning Organization and Management, "Design guidelines and customer agreement executive improvement of existing concrete structures using reinforced materials FRP (Publication 345)", (2006).
42. Raza, A., Khan, Q.U.Z. and Ahmad, A. "Prediction of axial compressive strength for FRP confined concrete compression members", *KSCE J. Civ. Eng.*, **24**(7), pp. 2099-2109 (2020).
43. Pour, A.F., Ozbakkaloglu, T. and Vincent, T. "Simplified design-oriented axial stress-strain model for FRP-confined normal-and high-strength concrete", *Eng. Struct.*, **175**, pp. 501-516 (2018).
44. Keshtegar, B., Sadeghian, P. Gholampour, A. and et al. "Nonlinear modeling of ultimate strength and strain of FRP-confined concrete using chaos control method", *Compos. Struct.*, **163**, pp. 423-431 (2017).
45. Sadeghian, P. and Fam, A. "Improved design-oriented confinement models for FRP wrapped concrete cylinders based on statistical analyses", *Eng. Struct.*, **87**, pp. 162-182 (2015).
46. Pham, T.M. and Hadi, M.N. "Confinement model for FRP confined normal-and highstrength concrete circular columns", *Constr. Build. Mater.*, **69**, pp. 83-90 (2014).
47. Realfonzo, R. and Napoli, A. "Concrete confined by FRP systems: confinement efficiency and design strength models", *Compos. B Eng.*, **42**(4), pp. 736-755 (2011).
48. Naderpour, H., Kheyroddin, A. and Amir, G.G. "Prediction of FRP-confined compressive strength of concrete using artificial neural networks", *Compos. Struct.*, **92**(12), pp. 2817-2829 (2010).
49. Vintzileou, E. and Panagiotidou, E. "An empirical model for predicting the mechanical properties of FRP-confined concrete", *Constr. Build. Mater.*, **22**(5), pp. 841-854 (2008).
50. Friedman, J.H. "Multivariate adaptive regression splines", *Ann. Stat.*, **19**, pp. 1-141 (1991).
51. Jekabsons, G. "Vari Reg: A software tool for regression modelling using various modeling methods", *Riga Technical University* (2010).
52. Huang, G.B., Zhou, H., Ding, X. and et al. "Extreme learning machine for regression and multiclass classification", *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, **42**(2), pp. 513-529 (2011).
53. Clerc, M. "Particle swarm optimization", *Hoboken, New Jersey, John Wiley & Sons* (2010).

54. Lazinica, A. "Particle swarm optimization", *Rijeka: Intech* (2009).
55. Zhou, C., Gao, H.B., Gao, L. and et al. "Particle swarm optimization (PSO) algorithm [J]", *Application Research of Computers*, **12**, pp. 7-11 (2003).
56. Deng, W., Yao, R., Zhao, H. and et al. "A novel intelligent diagnosis method using optimal LS-SVM with improved PSO algorithm", *Soft. Computing*, **23**(7), pp. 2445-2462 (2019).
57. Akbari, M. and Henteh, M. "Comparison of genetic algorithm (GA) and particle swarm optimization algorithm (PSO) for discrete and continuous size optimization of 2D truss structures", *Journal of Soft Computing in Civil Engineering*, **3**(2), pp. 76-97 (2019).
58. Zhu, S.L., Heddham, S., Nyarko, E.K. and et al. "Modeling daily water temperature for rivers: comparison between adaptive neuro-fuzzy inference systems and artificial neural networks models", *Environ. Sci. Pollut. Res.*, **26**, pp. 402-420 (2019).
59. Chai, T. and Draxler, R.R. "Root mean square error (RMSE) or mean absolute error (MAE)", *Geoscientific Model Development Discussions*, **7**(1), pp. 1525-1534 (2014).
60. Ashrafiyan, A., Taheri Amiri, M. and Haghghi, F. "Modeling the slump flow of self-compacting concrete incorporating metakaolin using soft computing techniques", *Journal of Structural and Construction Engineering*, **6**(2), pp. 5-20 (2019).
61. Taheri Amiri, M.J., Ashrafiyan, A., Haghghi, F.R. and et al. "Prediction of the compressive strength of self-compacting concrete containing rice husk ash using data driven models", *IJBQ*, **19**(1) pp. 209-221 (2019).
62. Shariati, K.B., Mafipour, M.S., Mehrabi, M.S. and et al. "Application of a hybrid artificial neural network-particle swarm optimization (ANN-PSO) model in behavior prediction of channel shear connectors embedded in normal and high-strength concrete", *Applied Sciences*, **9**(24), 5534 (2019).
63. Hanteh, R., Hanteh, M., Kheyroddin, A. and et al. "Determination of strength parameters in roller compacted concrete (RCC) dams using laboratory results and forecasting based on artificial neural networks", *Modares Civil Engineering Journal*, **20**(2), pp. 55-70 (2020).