

پیش‌بینی مؤلفه‌های زوال ستون‌های بتن مسلح با استفاده از روش‌های یادگیری ماشین

آزاده خشک‌رودی (دانشجوی دکتری)

حسین پروینی ثانی* (استادیار)

مجتبی اعجمی (استادیار)

گروه مهندسی عمران، واحد زنجان، دانشگاه آزاد اسلامی، زنجان، ایران

مهندسی عمران شریف (پهار ۲۰۲۰) (۱۴۰۲)
دردی ۲ - ۳۹، شماره ۱، ص. ۱۵-۲۲، پژوهشی

یکی از مؤلفه‌های کلیدی در تعیین عملکرد سازه، مؤلفه‌های زوال هستند. در نوشتار حاضر، به پیش‌بینی مؤلفه‌های زوال ستون‌های بتن مسلح توسط مدل‌های یادگیری ماشین پرداخته شده است. برای این منظور از ۲۵۵ داده‌ی آزمایشگاهی مربوط به ستون‌های بتن مسلح از سال ۱۹۷۳ تا ۲۰۰۲، برای پیش‌بینی با روش‌های مختلف یادگیری ماشین انتخاب شده‌اند، که دچار سه نوع شکست: خمشی، برشی و خمشی - برشی بوده‌اند. در ادامه، عملکرد روش‌های یادگیری ماشین، شامل: آداپوست، شبکه‌ی عصبی مصنوعی (ANN) و جنگل تصادفی (RF) با هم مقایسه شده‌اند. در این راستا، تحلیل‌های دقیق توسط نرم‌افزار پایتون بررسی شدند و نتایج به دست آمده نشان دادند که مدل جنگل تصادفی دارای دقتی برابر ۹۱٪ برای پیش‌بینی چرخش خمیری بعد از تسلیم (θ_p) ، ۸۱٪ برای چرخش خمیری از نقطه‌ی زوال مقاومت تا نقطه‌ی صفر مقاومت (θ_{pc}) و ۸۸٪ برای ظرفیت استهلاک انرژی نرمالایز شده (λ) نسبت به سایر الگوریتم‌ها بوده است. در ضمن، مدل جنگل تصادفی، نسبت به مدل‌های تحلیلی، بهبود پیش‌بینی قابل ملاحظه‌ی در تعیین مؤلفه‌های زوال داشته است.

واژگان کلیدی: مؤلفه‌های زوال، یادگیری ماشین، هوش مصنوعی، شبکه‌های عصبی مصنوعی، جنگل تصادفی.

۱. مقدمه

در سال‌های اخیر، مطالعات متعددی جهت استفاده از الگوریتم‌های مختلف جهت پیش‌بینی پارامترهای سازه‌ی انجام شده است. بیو^۱ و همکاران (۲۰۱۸)، مقاومت فشاری و کششی بتن با کارایی بالا را توسط الگوریتم ترکیبی به دست آوردند، که شامل: مدل شبکه‌ی عصبی مصنوعی (ANN)^۲ و الگوریتم کرم شب‌تاب اصلاح شده بوده است. نتایج به دست آمده نشان داده‌اند که سیستم ترکیبی، عملکرد بالایی نسبت به سایر الگوریتم‌ها داشته است.^[۱] نخاله‌های ساختمانی و پسماندهای کشاورزی، از جمله نگرانی‌های عمده‌ی زیست‌محیطی در جهان هستند. سالانه بیش از ۲۵۴/۵ میلیون تن پوسته‌ی برنج برای دفع، در دسترس است، که مقدار زیادی از آنها را می‌توان باز یافت و به عنوان سنگ‌دانه در بتن استفاده کرد. جتاهون^۳ و همکاران (۲۰۱۸)، برای پیش‌بینی مقاومت ۲۸ روزه‌ی بتن حاوی خاکستر پوست برنج، از

مدل شبکه‌ی عصبی مصنوعی (ANN) استفاده کرده‌اند.^[۱] سالانه ۲۰ میلیون تن، نخاله‌ی ساختمانی در تهران تولید می‌شود، که مقدار زیادی از آنها را می‌توان باز یافت و به عنوان بتن بازیافتی استفاده کرد. فخاریان و همکاران (۲۰۱۸)، به پیش‌بینی مقاومت فشاری بتن بازیافتی با استفاده از شبکه‌های عصبی مصنوعی (ANN) پرداخته‌اند.^[۲] اونیاری و آیکوتون^۴ (۲۰۱۸)، از مدل شبکه‌ی عصبی مصنوعی (ANN) برای پیش‌بینی مقاومت فشاری و خمشی ملات ساخته شده با افزودنی زئولیت اصلاح شده استفاده کرده‌اند.^[۳] پیش‌بینی ظرفیت باربری شمع‌های تحت بار جانبی، یکی از مسائل اساسی در مهندسی ژئوتکنیک بوده و تا کنون روش‌های متفاوتی برای ارزیابی آن ارائه شده است، اردکانی و کوهستانی (۲۰۱۷)، از روش ماشین بردار پشتیبان برای پیش‌بینی ظرفیت باربری جانبی شمع‌ها در خاک‌های رسی استفاده کرده‌اند.^[۴] از آن جایی که مصالح ساختمانی اغلب جرم سازه را تشکیل می‌دهند، برای بهره‌وری از مصالح و کاهش انتشار گازهای گلخانه‌ی، می‌توان از ارزیابی‌های زیست‌محیطی استفاده کرد. همچنین دامیکو^۵ و همکاران (۲۰۱۸)، از


* نویسنده مسئول

تاریخ: دریافت ۱۴۰۱/۴/۲۲، اصلاحیه ۱۴۰۱/۸/۷، پذیرش ۱۴۰۱/۹/۱۲.

DOI:10.24200/J30.2022.60697.3116

استناد به این مقاله:

خشک‌رودی، آزاده، پروینی ثانی، حسین و اعجمی، مجتبی (۱۴۰۲). «پیش‌بینی مؤلفه‌های زوال ستون‌های بتن مسلح با استفاده از روش‌های یادگیری ماشین»، مهندسی عمران شریف، ۲۲-۱۵، ص. ۲-۳۹، (۱)



شکل ۱. نمودار لنگر - دوران.

آنها نشان دادند که مدهای شکست لرزه‌ی دیوارهای برشی بتن مسلح به پارامترهای مختلفی، مانند: نسبت ابعادی، نسبت طول به عرض دیوارهای برشی و شاخص المان‌های تقویتی مرزی بستگی دارد.^[۱۵] سانتوس^{۱۱} و همکاران (۲۰۱۷)، از مدل شبکه‌های عصبی مصنوعی برای تشخیص ناهنجاری در پل‌ها استفاده کرده‌اند.^[۱۶] منگالاسو و همکاران (۲۰۲۰)، از مدل‌های یادگیری ماشین جنگلی تصادفی (RF)^{۱۲} برای پیش‌بینی حالت شکست ستون‌های بتن مسلح و دیوارهای برشی و نیز از یک روش توضیحی افزایشی تطبیقی SHAP^{۱۳} برای رتبه‌بندی متغیرهای ورودی بابت شناسایی مدهای شکست استفاده کردند و نشان دادند که الگوریتم جنگل تصادفی دارای دقت تقریبی ۸۶٪ است. همچنین نتایج آنها نشان داد که متغیرهای هندسی و شاخص‌های پایداری، پارامترهای مهمی در تعیین مدهای شکست هستند.^[۱۷] در نوشتار حاضر، پیش‌بینی مؤلفه‌های زوال برای ستون‌های بتن مسلح توسط روش‌های یادگیری ماشین، که شامل روش‌های جنگل تصادفی (RF)، شبکه‌ی عصبی مصنوعی (ANN) و آداپوست^{۱۴} هستند، انجام شده است.

برای این منظور، نتایج ۲۵۵ نمونه‌ی آزمایشگاهی از ستون‌های بتن مسلح به دست آمده، که توسط پژوهشگران مختلف در بازه‌ی زمانی ۱۹۷۳ تا ۲۰۰۲ جمع‌آوری و انتخاب شده‌اند.^[۱۸] نتایج به دست آمده از روابط تحلیلی موجود و مدل‌های به دست آمده از چند روش یادگیری ماشین برای اعتبارسنجی مدل‌های پیشنهادی استفاده شده‌اند. برای درک و پیش‌بینی رفتار سازه‌ها، تحت بارهای لرزه‌ی، مدل‌هایی نیاز است که بتوانند رفتار اعضاء سازه را تشریح کنند. منحنی‌های بک - بُن^{۱۵} یا یک‌جهته، مدل‌های چندخطی هستند که شامل مؤلفه‌های زوال هستند، (شکل ۱). رویکرد تحلیلی، برای ایجاد مدل‌هایی برای تخمین مؤلفه‌های زوال ستون‌های بتن مسلح براساس نتایج آزمایشگاهی به دست آمده است. روابط مذکور براساس تعداد محدودی از پارامترها، به پیش‌بینی مؤلفه‌های زوال می‌پردازند. این مدل‌ها اغلب دقت پیش‌بینی محدود را نشان می‌دهند، بنابراین استفاده از چنین مدل‌هایی برای شبیه‌سازی رفتار ستون‌های بتن مسلح کافی نیست. هدف اصلی مطالعه‌ی حاضر، پیدا کردن مدلی از روش‌های یادگیری ماشین است، که بتواند بهترین پیش‌بینی را داشته باشد. مدل جنگل تصادفی (RF)، پیش‌بینی بهتری نسبت به روابط تحلیلی داشته است. در ادامه، عملکرد مدل‌های یادگیری ماشین با روابط تحلیلی مقایسه شده است.

۱.۱. روابط تحلیلی

برای درک و پیش‌بینی رفتار سازه‌ها تحت بارهای لرزه‌ی، مدل‌هایی نیاز است که بتوانند رفتار اعضاء سازه را تشریح کنند. منحنی‌های بک - بُن یا منحنی‌های یک‌جهته، مدل‌های چندخطی هستند که شامل مؤلفه‌های زوال هستند (شکل ۱).

روش هوش مصنوعی و یادگیری ماشین استفاده و روش‌ها، اطلاعات قوی و دقیقی از مصالح سازه‌ی و جزئیات ساخت و ساز را فراهم و در نتیجه، فرصت مناسبی برای برآورد قابل اطمینان از چرخه‌ی عمر گازه‌های گلخانه‌ی ایجاد کرده‌اند.^[۶] در مطالعات دیگری، طبقه‌بندی مدهای شکست در سازه‌های بتن مسلح با میانقاب بنایی از طریق الگوریتم‌های یادگیری ماشین توسط هوانگ و بارتون^۶ (۲۰۱۹) انجام شده است. نتایج به دست آمده نشان داده‌اند که بیشتر الگوریتم‌ها، دقتی بیش از ۸۰٪ دارند، که در این میان بالاترین دقت برای الگوریتم‌های ماشین بردار پشتیبان و تقویتی تطبیقی بوده است.^[۷] در این راستا، مانگالاتو و وژون^۷ (۲۰۱۸)، توانستند مدهای شکست قبل و بعد از تسلیم عضو، همچنین مقاومت‌های برشی اتصال‌ها در تیرها و ستون‌های بتن مسلح تحت بارهای لرزه‌ی را از طریق یادگیری ماشین به دست آورند.^[۸] سیام^۸ و همکاران (۲۰۱۸)، نیز برای طبقه‌بندی و پیش‌بینی عملکرد دیوارهای برشی آجری مسلح از روش‌های یادگیری ماشین استفاده کرده‌اند. ایشان ابتدا از یک الگوریتم بدون نظارت برای خوشه‌بندی دیوارها بر اساس مشخصات هندسی و مکانیکی استفاده کرده و سپس از طریق الگوریتم‌های تحت نظارت به طبقه‌بندی دیوارها و پیش‌بینی جابه‌جایی جانبی با توجه به مدهای شکست پرداخته‌اند.^[۹] کیانی و همکاران (۲۰۱۹)، پاسخ‌های لرزه‌ی و منحنی‌های شکنندگی را از طریق ابزارهای یادگیری ماشین به دست آورده‌اند. آنها از ۱۰ الگوریتم یادگیری ماشین استفاده کرده و دریافته‌اند که الگوریتم جنگل تصادفی (RF) و تحلیل‌های تشخیص خطی و درجه دوم، کارایی بالاتری در پیش‌بینی پاسخ‌های سازه‌ی دارند. علاوه بر این، ایشان از یک روش مبتنی بر طبقه‌بندی، برای استخراج منحنی‌های شکنندگی استفاده کرده‌اند، که نتایج به دست آمده حاکی از دقت و کارایی بالای روش مذکور است.^[۱۰] ژون^۹ و همکاران (۲۰۱۴)، مدل‌های آماری برای مقاومت برشی اتصال‌های تیر به ستون بتنی مسلح را براساس روش‌های یادگیری ماشین ارائه دادند و با استفاده از الگوریتم‌های رگرسیون خطی چندگانه‌ی معمولی و روش یادگیری ماشین پیشرفته‌ی ماریچ رگرسیون خطی سازگار چندگانه (MARS)، تأثیر پارامترهای مختلفی، مانند: خواص ماده، پارامترهای طراحی و پیکربندی اتصال (مقاومت برشی اتصال) را بررسی کردند و دریافته‌اند که روش MARS، دقت و پیش‌بینی بالایی دارد.^[۱۱] رفیعی و عادل^{۱۱} (۲۰۱۷)، از یک مدل جدید برای پایش سلامت سازه‌های بلندمرتبه از طریق ترکیب یادگیری ماشین بدون نظارت، ماشین بولترمن محدود و یک الگوریتم طبقه‌بندی تحت نظارت به نام طبقه‌بندی دینامیک عصبی استفاده کرده‌اند. ایشان نتایج به دست آمده را با سه الگوریتم طبقه‌بندی نظارت شده مقایسه کرده و دریافته‌اند که طبقه‌بندی دینامیکی عصبی، دقت بالاتری نسبت به سایر الگوریتم‌ها دارد.^[۱۲] فلاح و همکاران (۲۰۲۱)، از الگوریتم‌های یادگیری ماشین در پایش سلامت سازه‌ها استفاده کرده و نشان داده‌اند که یادگیری ماشین به طور مؤثری چندین تجزیه و تحلیل، مانند: خوشه‌بندی، رگرسیون و طبقه‌بندی آسیب در سازه‌های مختلف، از جمله: ساختمان‌ها، پل‌ها، سدها، تونل‌ها و غیره را انجام می‌دهد و از این طریق می‌تواند شکاف‌های دانش فعلی و نیازهای مطالعات آینده را مشخص کند.^[۱۳] چارالامپاکیس^{۱۰} و همکاران (۲۰۲۰)، دوره‌ی تناوب اصلی سازه‌های بتن‌آرمه‌ی مسلح میانقاب با مصالح بنایی را با استفاده از روش‌های یادگیری ماشین تخمین زدند و نشان دادند که دوره‌ی تناوب، که به ارتفاع سازه‌ها، طول دهانه‌ی بین ستون‌ها، نسبت بازشدگی دیوار و سختی دیواربنایی مربوط است، را می‌توان از طریق یادگیری ماشین به دست آورد و در نتیجه، با این کار سطح هزینه‌های محاسباتی بالا، کاهش می‌یابد.^[۱۴] منگالاسو و همکاران (۲۰۲۰)، مدهای شکست لرزه‌ی، دیوارهای برشی بتن مسلح را توسط ۸ الگوریتم یادگیری ماشین به دست آوردند، که از میان الگوریتم‌های انتخاب شده، الگوریتم جنگل تصادفی نسبت به سایر الگوریتم‌ها، دقت حدود ۸۶٪ داشته است.

$$\theta_{p, simplified} = 0.13(1 + 0.55a_{sl})(0.13)^v(0.02 + 40\rho_{sh})^{0.65} (0.57)^{0.1} units f'_c \quad (2)$$

$$\theta_{pc} = (0.76)(0.31)^v(0.02 + 40\rho_{sh})^{1.2} \quad (3)$$

$$\lambda = (127.2)(0.19)^v(0.595)^{\frac{v_p}{v_n}}(4.25)^{\rho_{sh, eff}} \quad (4)$$

۲. مروری بر روش‌های یادگیری ماشین

در نوشتار حاضر، الگوریتم‌های یادگیری ماشین و اثر کلی مدل‌های یادگیری که در پیش‌بینی مؤلفه‌های زوال اعضاء بتنی به کار می‌روند، بررسی شده‌اند. در مدل‌سازی الگوریتم‌های یادگیری ماشین از نرم‌افزار Python ۳/۸ استفاده شده است. در یادگیری ماشین، داده‌ها به دو قسمت آموزشی و آزمایشی تقسیم می‌شوند، که بخش راستی آزمایشی مدل‌های یادگیری ماشین توسط داده‌های آزمایشی انجام می‌شود. در واقع، داده‌های آزمایشی به عنوان معیاری برای مقایسه‌ی عملکرد مدل‌های پیش‌بینی هستند. ۹۰٪ از داده‌ها برای آموزش و ۱۰٪ برای آزمایش به صورت تصادفی در نظر گرفته شده‌اند. سپس روش‌های یادگیری ماشین اعمال شده است. نتایج به دست آمده از مدل‌های یادگیری ماشین با داده‌های آزمایشگاهی مقایسه و توسط معیارهای ارزیابی میزان دقت و صحت نتایج بیان شده‌اند، که در ادامه، به طور خلاصه معرفی شده‌اند:

۲.۱. شبکه‌ی عصبی مصنوعی (ANN)

شبکه‌ی عصبی، مجموعه‌ی از نورون‌هاست که با قرار گرفتن در لایه‌های مختلف، معماری خاصی را بر مبنای ارتباطات بین نورون‌ها در لایه‌های مختلف تشکیل می‌دهند. نورون می‌تواند یک تابع ریاضی غیرخطی باشد؛ در نتیجه، یک شبکه‌ی عصبی که از اجتماع نورون‌های مذکور تشکیل می‌شود، نیز می‌تواند یک سامانه‌ی کاملاً پیچیده و غیرخطی باشد. شبکه‌ی عصبی هر نورون مستقلاً عمل می‌کند و رفتار کلی شبکه، برآیند رفتار نورون‌های متعدد است. به عبارت دیگر، نورون‌ها در یک روند همکاری، یکدیگر را تصحیح می‌کنند. شبکه‌ی عصبی مصنوعی (ANN)، برگرفته از شبکه‌ی عصبی انسان است. در مبحث شبکه‌های عصبی مصنوعی، مدل‌های ریاضی و نرم‌افزاری متعددی با الهام گرفتن از مغز انسان پیشنهاد شده‌اند، که برای حل گسترده‌ی وسیعی از مسائل علمی، مهندسی و کاربردی در حوزه‌های مختلف کاربرد دارند.

شبکه‌های عصبی، لایه‌های مختلفی دارند. شبکه‌های عصبی، اطلاعات را دریافت می‌کنند و در لایه‌های مخفی به تحلیل آنها می‌پردازند، که شامل: تصاویر، نوشته‌ها، صداها و غیره هستند و باید به بردارها و اطلاعات قابل درک برای ماشین تبدیل شوند. اطلاعات مذکور با تنظیم پارامترهای مختلف شبکه و ویژگی‌های موجود طبقه‌بندی می‌شوند و در نهایت یک خروجی را ایجاد می‌کنند. پارامترهای شبکه‌های عصبی، شامل: وزن‌ها، تابع فعال‌سازی، لایه‌های ورودی، لایه‌ی پنهان و لایه‌ی خروجی هستند. لایه‌های شبکه‌های عصبی تا جایی تغییر می‌کنند که الگوریتم مذکور قادر به ارائه‌ی جواب تصادفی نباشد.^[۱۹]

۲.۲. جنگل تصادفی (RF)

الگوریتم جنگل تصادفی (RF)، یک الگوریتم محبوب یادگیری ماشین از زیرمجموعه‌ی هوش مصنوعی است، که به روش یادگیری نظارت شده تعلق دارد و می‌تواند برای

جدول ۱. ۱۴ پارامتر ورودی و ۳ پارامتر خروجی.

واحد	پارامتر	توصیف پارامتر
mm	b	عرض ستون
mm	h	عمق ستون
	$\frac{L_c}{H}$	نسبت ابعادی ستون
	v	نسبت نیروی محوری
	$\frac{P_h}{P}$	نسبت نیروی محوری به نیروی محوری متعادل شده
Mpa	f'_c	تنش فشاری بتن
Mpa	f_y	تنش تسلیم فولاد
	ρ	نسبت مساحت میلگرد طولی به مساحت کل
mm	d_b	قطر میلگرد طولی
mm	s	فاصله‌ی میلگردهای عرضی
	s_n	ضریب کمانش میلگرد
	ρ_{sh}	نسبت مساحت میلگرد عرضی به مساحت کل
	$\rho_{sh, eff}$	نسبت مساحت مؤثر میلگرد عرضی به مساحت کل
	a_sl	شاخص متغیر پیوستگی لغزشی
rad	θ_p	چرخش خمیری بعد از تسلیم
rad	θ_{pc}	چرخش خمیری از نقطه‌ی زوال تا نقطه‌ی صفر مقاومت
	λ	ظرفیت استهلاک انرژی نرمالیز شده

در مطالعه‌ی حاضر، داده‌های مربوط به ۲۵۵ مؤلفه‌ی زوال مربوط به ستون‌های بتن مسلح و همچنین روابط تجربی به دست آمده، توسط هسلتون^{۱۶} و همکاران (۲۰۰۸)^[۱۸] استفاده شده است. معادله‌ی ۱، چرخش خمیری بعد از تسلیم θ_p ، معادله‌ی ۲، چرخش خمیری بعد از تسلیم ساده شده θ_p ؛ معادله‌ی ۳، چرخش خمیری از نقطه‌ی زوال تا نقطه‌ی صفر مقاومت θ_{pc} و معادله‌ی ۴، ظرفیت استهلاک انرژی نرمالیز شده λ هستند.^[۱۸] در مجموعه‌ی داده‌ها، ۱۴ ویژگی به عنوان ورودی الگوریتم هستند، که شامل: b عرض ستون، h عمق ستون، $\frac{L_c}{H}$ نسبت ابعادی ستون، v نسبت نیروی محوری، $\frac{P_h}{P}$ نسبت نیروی محوری بالانس شده به نیروی محوری، f'_c تنش فشاری بتن، f_y تنش تسلیم میلگرد، ρ نسبت مساحت میلگرد طولی به مساحت کل، d_b قطر میلگرد طولی، s فاصله‌ی میلگردهای عرضی، s_n ضریب کمانش میلگرد، ρ_{sh} نسبت مساحت میلگردهای عرضی به مساحت کل، شاخص متغیر پیوستگی لغزشی (اگر لغزش وجود داشته باشد، مقدار آن برابر یک و در غیر این صورت، برابر ۰ خواهد بود) هستند. همچنین سه خروجی، شامل: چرخش خمیری بعد از تسلیم θ_p ؛ چرخش خمیری از نقطه‌ی زوال تا نقطه‌ی صفر مقاومت θ_{pc} و ظرفیت استهلاک انرژی نرمالیز شده λ هستند، که در جدول ۱ ارائه شده‌اند. ستون‌ها نیز بعد از انهدام، دچار سه نوع شکست: خمشی، برشی، خمشی - برشی می‌شوند، که شکست خمشی با عدد ۱، شکست برشی با عدد ۲ و شکست خمشی - برشی با عدد ۳ و نمونه‌های گزارش نشده با (not reported) نمایش داده شده‌اند. تابع توزیع داده‌ها به صورت گاوسی در نظر گرفته شده است.

۲.۱. روابط تحلیلی موجود

$$\theta_p = 0.12(1 + 0.55a_{sl})(0.16)^v(0.02 + 40\rho_{sh})^{0.72} (0.54)^{0.1} units f'_c (0.66)^{0.1} s_n (2.27)^{1.0} \rho \quad (1)$$

مشکلات طبقه‌بندی و رگرسیون (پیش‌بینی و بیان تغییرات یک متغیر بر اساس اطلاعات متغیر دیگر) در یادگیری ماشین استفاده شود. روش RF، مبتنی بر مفهوم یادگیری گروه است، که یک فرایند ترکیب چند طبقه‌بندی‌کننده برای حل یک مسئله‌ی پیچیده و بهبود عملکرد مدل است. جنگل تصادفی (RF)، اساساً مانند کیسه‌بی است که شامل n درخت تصمیم‌گیری است، که مجموعه‌بی متفاوت دارد و در زیرمجموعه‌های مختلف داده‌ها آموزش داده می‌شوند. یکی از بزرگ‌ترین مزایای جنگل تصادفی (RF)، تطبیق پذیری آن برای کارهای رگرسیون و طبقه‌بندی است. همچنین در مورد مشاهده‌ی اهمیت نسبی، که به ویژگی‌های ورودی اختصاص می‌یابد، جنگل تصادفی یک الگوریتم بسیار مفید است؛ زیرا ابرپارامترهای پیش‌فرضی که از مشاهدات و ویژگی‌ها استفاده می‌کنند، اغلب نتیجه‌ی پیش‌بینی خوبی ایجاد می‌کنند. ابرپارامترهای جنگل تصادفی اعدادی هستند که باید به طور صحیح انتخاب شوند. روش خاصی در انتخاب ابرپارامترها وجود ندارد. پارامترهای مذکور تا جایی تغییر می‌کنند، که دیگر الگوریتم RF، قادر به ارائه‌ی جواب تصادفی نباشد.^[۲۰]

۳.۲. آدابوست

آدابوست (AdaBoost) مخفف برجسب‌زنی تطبیقی^[۱۷]، یک الگوریتم طبقه‌بندی آماری و یادگیری ماشین است. آدابوست، روش یادگیری ترکیبی و شناخته شده‌ترین روش از خانواده‌ی برجسب‌زنی است. در الگوریتم آدابوست، مدل‌ها به طور پی‌درپی یاد گرفته می‌شوند، به طوری که در هر نوبت، یک مدل آموزش داده می‌شود. در پایان هر نوبت، نمونه‌هایی که اشتباه طبقه‌بندی شده‌اند، شناسایی می‌شوند و تأکید روی آنها در یک مجموعه‌ی آموزشی جدید، افزایش می‌یابد. پس مجموعه‌ی آموزشی ذکر شده‌ی جدید، برای نوبت بعدی آموزش استفاده و یک مدل جدید آموزش داده می‌شود. ایده این است که مدل‌های جدید باید قادر به جبران خطاهای ایجاد شده توسط مدل‌های قبلی باشند. در واقع، آدابوست یک متالگوریتم است، که به منظور ارتقاء عملکرد و رفع مشکل رده‌های نامتوازن همراه دیگر الگوریتم‌های یادگیری ماشین استفاده می‌شود. الگوریتم آدابوست نسبت به داده‌های نویز و پرت حساس است، ولی نسبت به مشکل پیش‌پردازش، از بیشتر الگوریتم‌های یادگیری برتری دارد.^[۲۱]

۳. عملکرد مدل‌های یادگیری ماشین

برای تعیین بهترین عملکرد در میان سه الگوریتم استفاده شده در مطالعه‌ی حاضر، از ۲۵۵ داده‌ی آزمایشگاهی به دست آمده برای مؤلفه‌های زوال ستون‌های بتن مسلح استفاده شده است. داده‌ها به صورت تصادفی به ۹۰٪ برای آموزش و ۱۰٪ برای آزمایش تقسیم‌بندی شده‌اند. تقسیم‌بندی بر اساس روش Kennard-Stone Algorithm بوده است. سه الگوریتم: شبکه‌ی عصبی مصنوعی (ANN)، جنگل تصادفی (RF) و آدابوست برای پیش‌بینی استفاده و عملکرد آنها ارزیابی شده‌اند. سه پارامتر ارزیابی، عملکرد شامل این موارد هستند:

الف) ریشه‌ی میانگین مربع خطا (RMSE)^[۱۸]

$$RMSE = \sqrt{\frac{1}{N_t} \sum_{i=1}^{N_i} (Y_{test}^{\wedge} - Y_{testi})^2} \quad (5)$$

ب) ضریب تعیین (R^2)^[۱۹]

$$R^2 = 1 - \frac{\sum_{i=1}^{N_i} (Y_{test}^{\wedge} - Y_{testi})^2}{\sum_{i=1}^{N_i} (Y_{test} - Y_{testi})^2} \quad (6)$$

ج) خطای مطلق میانگین (MAE)^[۲۰]

$$MAE = \frac{1}{N_t} \sum_{i=1}^{N_i} |Y_{test}^{\wedge} - Y_{testi}| \quad (7)$$

پارامترهای اخیر، برای داده‌های آموزشی و آزمایشی برای ۳ الگوریتم محاسبه شده‌اند، که در جدول‌های ۲ الی ۴ ارائه شده‌اند. در معادله‌های ۵ الی ۷،

جدول ۲. مقایسه‌ی عملکرد مدل‌های یادگیری ماشین مجموعه‌ی داده‌های آزمایشی و آموزشی در θ_p .

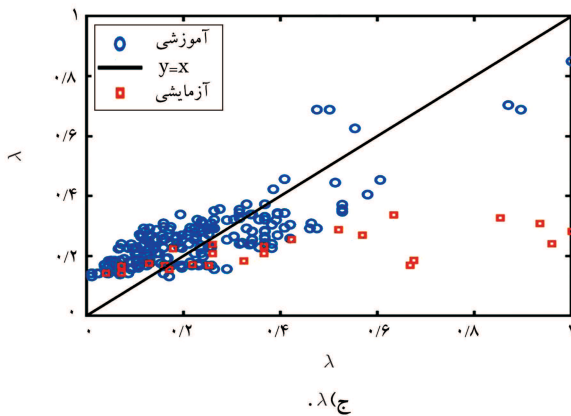
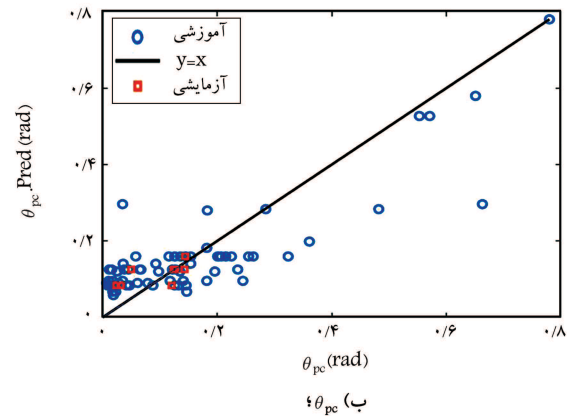
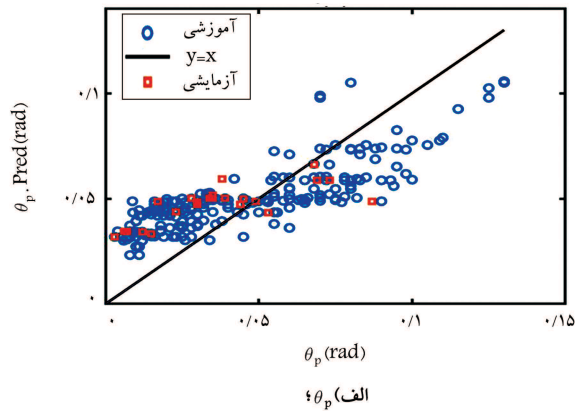
مجموعه‌ها	روش‌ها	R^2	RMSE	MAE
آدابوست		۰/۵۷	۰/۰۱۹۸	۰/۰۱۷۴
نتایج آزمایشی	شبکه‌ی عصبی مصنوعی	۰/۶۶	۰/۰۱۲۸	۰/۰۰۸۴
	جنگل تصادفی	۰/۶۷	۰/۱۲۶	۰/۰۰۸
	آدابوست	۰/۶۶	۰/۰۱۹	۰/۰۱۷
نتایج آموزشی	شبکه‌ی عصبی مصنوعی	۰/۷۷	۰/۰۱۴۳	۰/۰۰۹۴
	جنگل تصادفی	۰/۹۱	۰/۰۰۹۸	۰/۰۰۷۲

جدول ۳. مقایسه‌ی عملکرد مدل‌های یادگیری ماشین مجموعه‌ی داده‌های آزمایشی و آموزشی در θ_{pc} .

مجموعه‌ها	روش‌ها	R^2	RMSE	MAE
نتایج آزمایشی	شبکه‌ی عصبی مصنوعی	۰/۳۲	۰/۰۸۹	۰/۰۸۳
	آدابوست	۰/۴	۰/۰۴۱	۰/۰۳۲
	جنگل تصادفی	۰/۴۰۴	۰/۰۴۲	۰/۰۳۴
	شبکه‌ی عصبی مصنوعی	۰/۴۲	۰/۱۲۶	۰/۰۹
نتایج آموزشی	آدابوست	۰/۷۲	۰/۰۸۹	۰/۰۶۷
	جنگل تصادفی	۰/۸۱	۰/۰۷۲	۰/۰۵

جدول ۴. مقایسه‌ی عملکرد مدل‌های یادگیری ماشین مجموعه‌ی داده‌های آزمایشی و آموزشی در λ .

مجموعه‌ها	روش‌ها	R^2	RMSE	MAE
آدابوست		۰/۵۲	۰/۳۲	۰/۲۵
نتایج آزمایشی	شبکه‌ی عصبی مصنوعی	۰/۷۴	۰/۱۶	۰/۱۲
	جنگل تصادفی	۰/۸۵	۰/۳۲	۰/۲۵
	آدابوست	۰/۶۶	۰/۰۸۹	۰/۰۸۶
نتایج آموزشی	شبکه‌ی عصبی مصنوعی	۰/۷۵	۰/۰۹۳	۰/۰۷
	جنگل تصادفی	۰/۸۸	۰/۰۵۷	۰/۰۳۹



شکل ۲. الگوریتم آداپوست.

جدول ۸. مقایسه‌ی عملکرد مدل جنگل تصادفی برحسب مدل تحلیلی برای θ_p .

MAE	RMSE	R^2	روش‌ها
۰/۰۰۷۲	۰/۰۰۹۸	۰/۹۱	جنگل تصادفی
۰/۰۲	۰/۰۲۷	۰/۱۹	معادله‌ی ۱
۰/۰۲۱	۰/۰۲۷	۰/۱۸	معادله‌ی ۲
۶۴	۶۳/۷	۷۹	بهبود نسبت به معادله‌ی ۱ (%)
۶۵/۷	۶۳/۷	۸۰/۲	بهبود نسبت به معادله‌ی ۲ (%)

تحلیلی مشاهده می‌شوند. مدل جنگل تصادفی در مقایسه با دیگر مدل‌های تحلیلی، پارامترهای MAE ، $RMSE$ ، R^2 را به میزان قابل ملاحظه‌ی بهبود بخشیده است. در ضمن، خلاصه‌ی نتایج در جدول‌های ۸ الی ۱۰ ارائه شده است.

جدول ۵. مقایسه‌ی عملکرد الگوریتم‌ها و روابط تحلیلی برای θ_p .

MAE	RMSE	R^2	روش‌ها	مجموعه‌ها
۰/۰۱۷	۰/۰۱۹	۰/۶۶	آداپوست	نتایج آموزشی
۰/۰۰۹۴	۰/۰۱۴۳	۰/۷۷	شبکه‌ی عصبی مصنوعی	
۰/۰۰۷۲	۰/۰۰۹۸	۰/۹۱	جنگل تصادفی	
۰/۰۲	۰/۰۲۷	۰/۱۹	معادله‌ی ۱	
۰/۰۲۱	۰/۰۲۷	۰/۱۸	معادله‌ی ۲	

جدول ۶. مقایسه‌ی عملکرد الگوریتم‌ها و روابط تحلیلی برای θ_{pc} .

MAE	RMSE	R^2	روش‌ها	مجموعه‌ها
۰/۰۹	۰/۱۲۶	۰/۴۲	شبکه‌ی عصبی مصنوعی	نتایج آموزشی
۰/۰۶۷	۰/۰۸۹	۰/۷۲	آداپوست	
۰/۰۵	۰/۰۷۲	۰/۸۱	جنگل تصادفی	نتایج آموزشی
۰/۰۹۶	۰/۱۴	۰/۲	معادله‌ی ۳	

جدول ۷. مقایسه‌ی عملکرد الگوریتم‌ها و روابط تحلیلی برای λ .



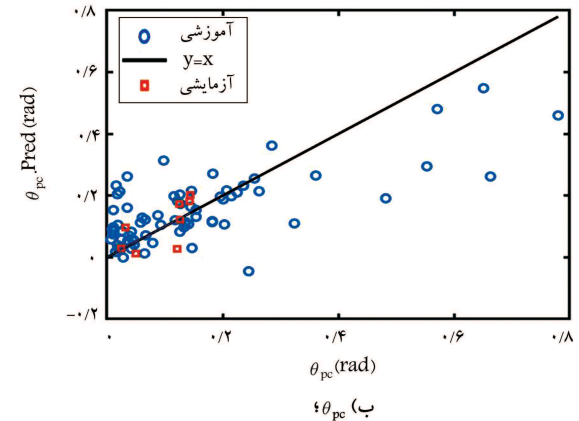
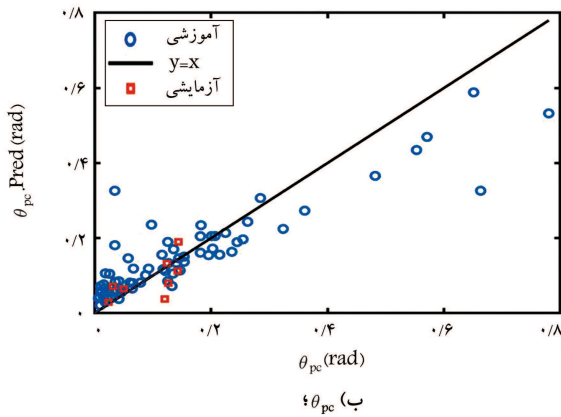
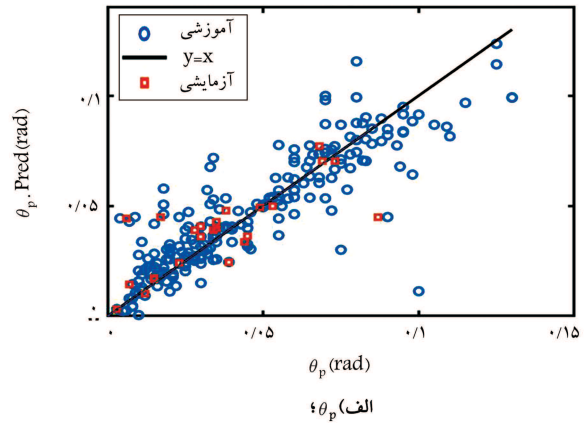
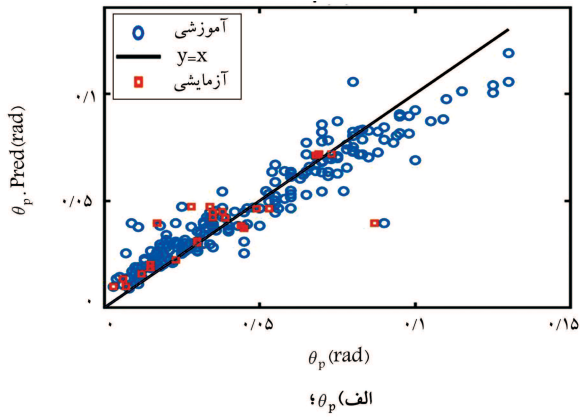
MAE	RMSE	R^2	روش‌ها	مجموعه‌ها
۰/۰۸۶	۰/۰۹۸	۰/۶۶	آداپوست	نتایج آموزشی
۰/۰۷	۰/۰۹۳	۰/۷۵	شبکه‌ی عصبی مصنوعی	
۰/۰۳۹	۰/۰۵۷	۰/۸۸	جنگل تصادفی	نتایج آموزشی
۰/۳۷	۰/۴۳	۰/۴۷	معادله‌ی ۴	

$Y_{test,i}^{\wedge}$ مقادیر پیش‌بینی شده در i آمین مشاهده در داده‌های آزمایشی و $Y_{test,i}$ مقادیر واقعی برای i آمین مشاهده در داده‌های آزمایشی هستند، که توسط الگوریتم یادگیری ماشین به دست آمده‌اند، N_t تعداد داده‌های نهایی در مجموعه‌ی آزمایشی Y_{-test} مقدار متوسط داده در مجموعه‌ی آزمایشی هستند. جدول‌های ۲ الی ۴ به طور واضح نشان می‌دهند که الگوریتم جنگل تصادفی (RF)، عملکرد بهتری نسبت به دو الگوریتم دیگر داشته است. در شکل‌های ۲ الی ۴، پیش‌بینی مؤلفه‌های زوال برای ۳ الگوریتم ذکر شده مشاهده می‌شود.

۴. مقایسه‌ی عملکرد مدل‌های یادگیری ماشین با

معادله‌های تجربی مؤلفه‌های زوال

در بخش حاضر، عملکرد مدل‌های پیش‌بینی‌کننده در مقایسه با مدل‌های تحلیلی در جدول‌های ۵ الی ۷ خلاصه شده است. مدل جنگل تصادفی (RF)، نسبت به سایر الگوریتم‌ها عملکرد بهتری داشته و پیش‌بینی‌ها برای مؤلفه‌های زوال بر اساس ۱۴ پارامتر اشاره شده انجام شده است. نتایج به دست آمده برای ارزیابی الگوریتم‌ها نشان می‌دهند که مدل جنگل تصادفی با $R^2 = ۰/۹۱$ ، $RMSE = ۰/۰۰۹۸$ و $MAE = ۰/۰۰۷۲$ برای θ_p ؛ با $R^2 = ۰/۸۱$ ، $RMSE = ۰/۰۷۲$ و $MAE = ۰/۰۵$ برای θ_{pc} ؛ و همچنین $R^2 = ۰/۸۸$ ، $RMSE = ۰/۰۵۷$ و $MAE = ۰/۰۳۹$ برای λ ، نسبت به دیگر مدل‌های تحلیلی ذکر شده، به طور قابل ملاحظه‌ی، عملکرد بهتری داشته است. تقریباً همه‌ی مدل‌های پیش‌بینی شده در محدوده‌ی $y=x$ قرار گرفته‌اند. در شکل ۵، نمودارهای مربوط به مدل‌های



شکل ۴. الگوریتم جنگل تصادفی.

شکل ۳. الگوریتم شبکه‌ی عصبی مصنوعی.

جدول ۹. مقایسه‌ی عملکرد مدل جنگل تصادفی برحسب مدل تحلیلی برای θ_{pc} .

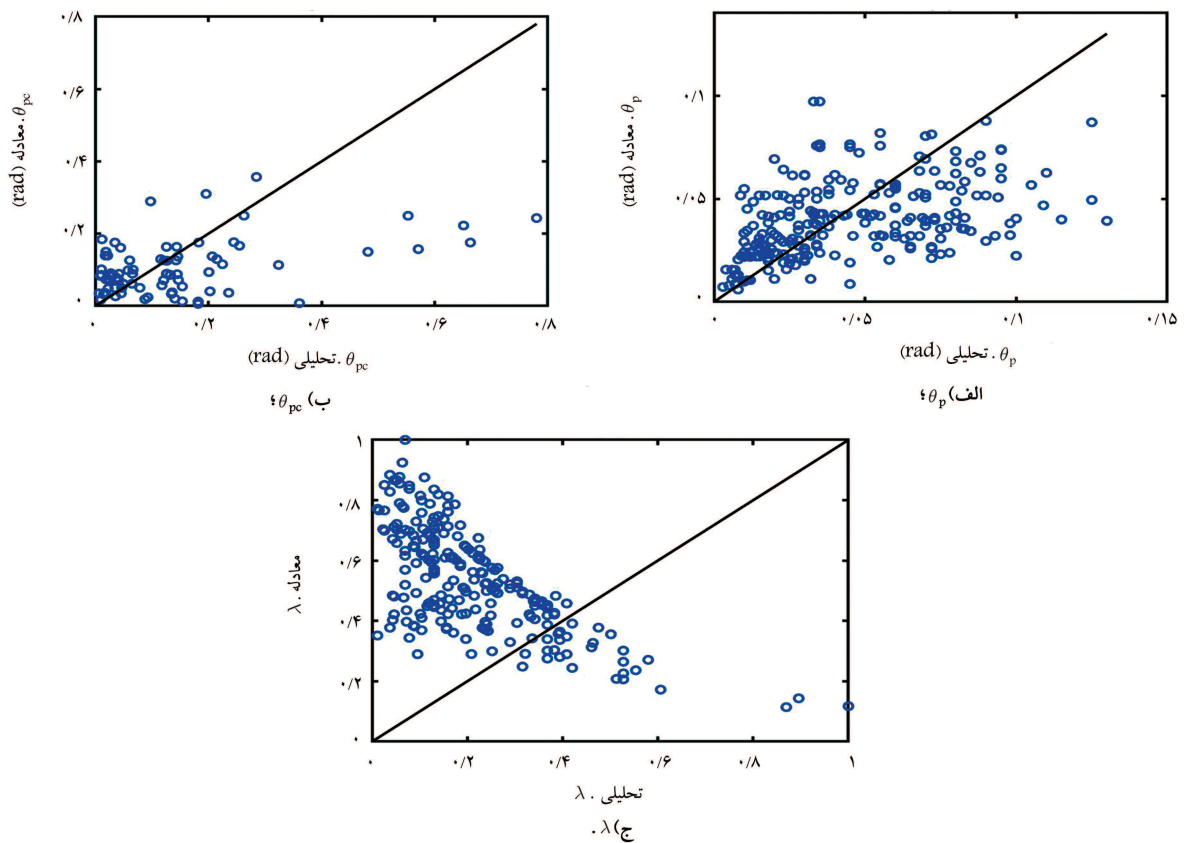
روش‌ها	R^2	RMSE	MAE
جنگل تصادفی	۰/۸۱	۰/۰۷۲	۰/۰۵
معادله‌ی ۳	۰/۲	۰/۰۱۴	۰/۰۰۹۶
بهبود نسبت به معادله‌ی ۳ (%)	۷۵/۳	۴۸/۵	۹۲

جدول ۱۰. مقایسه‌ی عملکرد مدل جنگل تصادفی برحسب مدل تحلیلی برای λ .

روش‌ها	R^2	RMSE	MAE
جنگل تصادفی	۰/۸۸	۰/۰۵۷	۰/۰۳۹
معادله‌ی ۴	۰/۴۷	۰/۴۳	۰/۳۷
بهبود نسبت به معادله‌ی ۴ (%)	۴۶/۵	۸۶/۷	۸۹/۴

۵. نتیجه‌گیری

رویکرد تحلیلی، برای ایجاد مدل‌هایی به منظور تخمین مؤلفه‌های زوال ستون‌های بتن مسلح بر اساس نتایج آزمایشگاهی به دست آمده است. روابط مذکور بر اساس تعداد محدودی از پارامترها، به پیش‌بینی مؤلفه‌های زوال می‌پردازند. این مدل‌ها اغلب دقت پیش‌بینی محدود را نشان می‌دهند. بنابراین، استفاده از چنین مدل‌هایی برای شبیه‌سازی رفتار ستون‌های بتن مسلح کافی نیست. برای افزایش دادن دقت، مدل‌های یادگیری ماشین می‌توانند با پارامترهای بیشتری، پیش‌بینی‌های لازم را انجام دهند. نتایج به دست آمده از روابط تحلیلی و مدل‌های یادگیری ماشین با هم مقایسه و بهبود عملکرد آنها نسبت به مدل‌های تحلیلی بررسی شده است. در مطالعه‌ی



شکل ۵. پیش‌بینی انجام شده توسط روابط تحلیلی.

بر اساس داده‌های آموزشی، برای θ_p برابر ۹۱٪، برای θ_{pc} برابر ۸۱٪ برای λ برابر ۸۸٪ بوده و لذا، بهترین پیش‌بینی را داشته است. همچنین روش RF برای داده‌های آزمایشی دارای دقت: ۶۷٪ برای θ_p ، ۴۰٪ برای θ_{pc} و ۵۲٪ بوده است. میزان بهبودی که مدل جنگل تصادفی نسبت به روابط تحلیلی داشته است، در R^2 برابر ۴۶/۵٪، در RMSE، ۸۶/۷٪ و در MAE ۸۹/۴٪ بوده است.

حاضر، از ۲۵۵ داده‌ی آزمایشگاهی استفاده شده است، که به صورت تصادفی به دو قسمت آموزشی و آزمایشی تقسیم‌بندی شده‌اند (۹۰٪ داده‌ها آموزشی و ۱۰٪ آزمایشی بوده‌اند). از سه مدل یادگیری ماشین و جهت بررسی عملکرد از سه معیار ارزیابی در نوشتار حاضر استفاده شده است. نتایج به دست آمده نشان داد که مدل جنگل تصادفی نسبت به دو مدل دیگر دقت بالاتری داشته است. دقت مدل RF

پانویس‌ها

1. Bui
2. Artificial Neural Network
3. Getahun
4. Onyari & Ikotun
5. D'Amico
6. Huang, H. and Burton
7. Mangalathu & Jeon
8. Siam
9. Jeon
10. Charalampakis
11. Santos
12. Random Forest
13. Shapley Additive Explanations
14. AdaBoost

15. Back-Bone
16. Haselton
17. Adaptive Boosting
18. Root Mean Square Error
19. Coefficient of Determination
20. Mean Absolute Error

منابع (References)

1. Bui, D.K., Nguyen, T., Chou, J.-Sh. and et al. "A modified firefly algorithm-artificial neural network expert system for predicting compressive and tensile strength of high-performance concrete", *Construction and Building Materials*, **180**, pp. 320-333 (2018).

2. Getahun, M.A., Shitote, S.M. and Gariy, Z.C.A. "Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes", *Construction and Building Materials*, **190**, pp. 517-525 (2018).
3. Naderpour, H., Rafean, A.H. and Fakharian, P. "Compressive strength prediction of environmentally friendly concrete using artificial neural networks", *Journal of Building Engineering*, **16**, pp. 213-219 (2018).
4. Onyari, E. and Ikotun, B. "Prediction of compressive and flexural strengths of a modified zeolite additive mortar using artificial neural network", *Construction and Building Materials*, **187**, pp. 1232-1241 (2018).
5. Ardakani, A.R. and Kohestani, V.R. "Prediction of lateral bearing capacity of piles of in clay soils using support vector machine", *Journal of Civil Engineering and Environment*, **47**(2), pp. 1-10, (In Persian) (1395/2017).
6. D'Amico, B., Myers, R.J., Voss, E. and et al. "Machine learning for sustainable structures: A call for data", *Structures*, **19**, pp. 1-4 (2019).
7. Huang, H. and Burton, H.V. "Classification of in-plane failure modes for reinforced concrete frames with infills using machine learning", *Journal of Building Engineering*, **25**, p. 100767 (2019).
8. Mangalathu, S. and Jeon, J.-S. "Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using machine learning techniques", *Engineering Structures*, **160**, pp. 85-94 (2018).
9. Siam, A., Ezzeldin, M. and El-Dakhakhni, W. "Machine learning algorithms for structural performance classifications and predictions: Application to reinforced masonry shear walls", *Structures*, **22**, pp. 252-265 (2019).
10. Kiani, J., Camp, C. and Pezeshk, S. "On the application of machine learning techniques to derive seismic fragility curves", *Computers & Structures*, **218**, pp. 108-122 (2019).
11. Jeon, J.S., Shafieezadeh, A. and DesRoches, R. "Statistical models for shear strength of RC beam-column joints using machine-learning techniques", *Earthquake Engineering & Structural Dynamics*, **43**(14), pp. 2075-2095 (2014).
12. Rafiei, M.H. and Adeli, H. "A novel machine learning-based algorithm to detect damage in high-rise building structures", *The Structural Design of Tall and Special Buildings*, **26**(18), p. e1400 (2017).
13. Flah, M., Nunez, I., Chaabene, W.B. and et al. "Machine learning algorithms in civil structural health monitoring: a systematic review", *Archives of Computational Methods in Engineering*, **28**(4), pp. 2621-2643 (2021).
14. Charalampakis, A.E., Tsiatas, G.C. and Kotsiantis, S.B. "Machine learning and nonlinear models for the estimation of fundamental period of vibration of masonry infilled RC frame structures", *Engineering Structures*, **216**, p. 110765 (2020).
15. Mangalathu, S., Jang, H., Hwang, S.-H. and et al. "Data-driven machine-learning-based seismic failure mode identification of reinforced concrete shear walls Engineering", *Structures*, **208**, p. 110331 (2020).
16. Santos, A., Figueiredo, E., Silva, M. and et al. "Genetic-based EM algorithm to improve the robustness of gaussian mixture models for damage detection in bridges structural", *Control and Health Monitoring*, **24**(3), p. e1886 (2017).
17. Mangalathu, S., Hwang, S.H. and Jeon, J.S. "Failure mode and effects analysis of RC members based on machine-learning-based shapley additive explanations (SHAP) approach", *Engineering Structures*, **219**, p. 110927 (2020).
18. Haselton, C.B., Liel, A.B., Lange, S.T. and et al. "Beam-column element model calibrated for predicting flexural response leading to global collapse of RC frame buildings", *PEER Report 2007/03, Pacific Earthquake Engineering Research Center College of Engineering, University of California, Berkeley*, pp. 86-99 (2008).
19. Mhatre, M.S., Siddiqui, F., Dongre, M. and et al. "A review paper on artificial neural network: a prediction technique", *International Journal of Scientific & Engineering Research*, **6**(12), pp. 161-163 (2015).
20. Breiman, L. "Bagging predictors", *Machine learning*, **24**(2), pp. 123-140 (1996).
21. Freund, Y. and Schapire, R.E. "Experiments with a new boosting algorithm", *Proceedings of the 13th International Conference* (1996).