

پیش‌بینی مقاومت فشاری بتن با استفاده از الگوریتم‌های رگرسیونی یادگیری ماشین

نعیم روشن^۱، منصور قلعه‌نوی^۲، امیر خسروی^۳

۱- دانشجوی دکتری سازه، دانشگاه فردوسی مشهد

۲- دانشیار گروه مهندسی عمران، دانشگاه فردوسی مشهد*

۳- دانشجوی دکتری سازه، دانشگاه فردوسی مشهد

* ghalehnovi@um.ac.ir

خلاصه

در سال‌های اخیر استفاده از شیوه‌های هوشمند به منظور حل مساله‌های حجیم در حوزه علوم مهندسی گسترش یافته است. طرح اختلاط بتن نیز یکی از مسائلی است که در حوزه مهندسی عمران اهمیت فراوانی دارد. یافتن بهترین نسبت ترکیب مواد تشکیل دهنده بتن برای دستیابی به مقاومت فشاری مطلوب از جمله هدف‌های حل مساله طرح اختلاط بتن با استفاده از الگوریتم‌های یادگیری ماشین است. اساساً مساله‌های یادگیری ماشین به توجه به نوع خروجی مساله به دو دسته رگرسیون و کلاس‌بندی تقسیم‌بندی می‌شوند. الگوریتم‌های رگرسیونی به پیش‌بینی مقادیر کمی مانند قیمت، سن و غیره می‌پردازد در حالی که الگوریتم‌های کلاس‌بندی به منظور طبقه‌بندی مقادیر گسسته مورد استفاده قرار می‌گیرند. در این پژوهش به بررسی و مقایسه الگوریتم‌های رگرسیونی یادگیری ماشین پرداخته شده است. بر همین اساس از یک مجموعه داده ۱۰۰۰ تایی طرح اختلاط بتن استفاده شده است. پارامترهایی نظیر نسبت آب به مواسیمنی، میزان سیمان، مقدار فوق‌روان‌کننده و غیره بر طرح اختلاط بتن تأثیرگذار بوده است. با توجه به نتایج بدست آمده، استفاده از روش‌های مبتنی بر درخت تصمیم سرعت تحلیل را بهبود بخشیده و ضریب همبستگی بهتری را نسبت به روش‌های شبکه عصبی و بردار پشتیبان ارائه می‌کند.

کلمات کلیدی: مقاومت فشاری بتن، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، درخت تصمیم‌گیری

۱. مقدمه

روش‌های یادگیری ماشین (Machine Learning)، سیستم‌های مختلف را قادر می‌کنند که یاد بگیرند، بررسی کنند و پیشنهادها را کاربردی ارائه دهند. به طور کلی، این روش‌ها به سه دسته یادگیری نظارت‌شده، نظارت‌نشده و تقویتی تقسیم‌بندی می‌شوند. در مساله تخمین مقاومت فشاری بتن، به دلیل اینکه از برجسب گذاری بر روی داده‌ها استفاده می‌شود، با یک مساله یادگیری ماشین نظارت‌شده سر و کار داریم. الگوریتم‌های یادگیری نظارت‌شده گونه‌های متفاوتی دارند. از جمله می‌توان به روش‌های درخت تصمیم (Decision tree)، دسته‌بند بیز (Naïve Bays classifier)، رگرسیون لجستیک (Regression logistic)، ماشین بردار پشتیبان (Support vector machine) و غیره اشاره نمود. با توجه به اینکه مقاومت فشاری بتن ماهیتی کمی و عددی دارد، بیشتر به کمک روش‌های رگرسیونی حل می‌گردد.

۲. پیش‌بینی مقاومت فشاری بتن

با توجه به تعداد پارامترهای نسبتاً زیاد موثر بر رفتار مقاومت فشاری بتن، استفاده از روش‌ها و الگوریتم‌های مبتنی بر داده‌های حجیم می‌تواند سرعت و دقت بیشتری را به دست دهد. از جمله پارامترهای بسیار مهم تأثیرگذار بر مقاومت فشاری بتن می‌توان به مقدار و نوع سیمان مصرفی، نسبت آب به مواسیمنی، میزان درشت‌دانه و ریزدانه و دانه‌بندی آن، مقدار مواد جایگزین سیمان، نوع و میزان فوق‌روان‌کننده و همچنین سن نمونه بتنی اشاره کرد. در همین راستا، محققان در تلاش برای تخمین مقاومت فشاری بتن با استفاده از شیوه‌های نوین مبتنی بر یادگیری ماشین، تحقیقاتی را انجام داده‌اند. در سال ۱۳۹۱، رضانیان‌پور و همکاران با استفاده از شبکه عصبی مصنوعی مقاومت فشاری نمونه بتنی را تخمین زدند. در این پژوهش که بر روی ۷۶ طرح اختلاط بتن صورت گرفت، از سیمان تیپ ۱، پوزلان‌های طبیعی (توف و بومیس) و همچنین سایر پوزلان‌ها مانند خاکستر پوسته برنج، متاکاولین و دوده سیسیلیس به عنوان مواد جایگزین سیمان استفاده شد. پس از تست مقاومت فشاری در زمان مشخص و ثبت داده‌ها از الگوریتم شبکه عصبی

مصنوعی در نرم‌افزار متلب و جعبه‌ابزار مربوطه برای یادگیری ماشین استفاده شد. به منظور آموزش شبکه عصبی، ۹۰ درصد داده‌ها برای آموزش و ۱۰ درصد باقیمانده برای آزمایش شبکه به کار رفتند. با استفاده از فرایند آزمون و خطا، تعداد نورون‌های بهینه در دو لایه مشخص گردید و ضریب همبستگی ۰/۹۶۸ برای این بررسی گزارش شد [1]. در یک بررسی دیگر، ترکان و نادری دهکردی با استفاده از الگوریتم رگرسیون ماشین بردار پشتیبان مقاومت فشاری ۲۸ روزه بتن را پیش‌بینی نمودند. در واقع یک مدل ترکیبی با استفاده از الگوریتم بهینه‌ساز ازدحام ذره (PSO) برای ارائه‌ی پارامترهای یادگیری مدل مورد استفاده این محققان قرار گرفت. در مجموع ۴۲۶ داده آزمایشگاهی با استفاده از این شیوه مورد آموزش و سپس آزمایش قرار گرفت. با توجه به اینکه الگوریتم ماشین بردار پشتیبان به شدت به ابرپارامترهایی نظیر فاکتور جریمه (C) و انحراف کرنل (γ) وابسته است، استفاده از یک شیوه فراابتکاری مانند الگوریتم ازدحام ذره می‌تواند تا حدود زیادی به عملکرد آن کمک کند. نتایج نشان داد که بهره‌گیری از این شیوه ترکیبی تاثیر به‌سزایی در بالا بردن عملکرد الگوریتم رگرسیون ماشین بردار پشتیبان برای پیش‌بینی مقاومت فشاری ۲۸ روزه بتن داشته است [2]. داوودی نیز در سال ۱۳۹۵، با بکارگیری الگوریتم درخت تصمیم‌گیری اثر فوق‌روان‌کننده را بر مقاومت فشاری بتن مورد سنجش قرار داد. در این بررسی از الگوریتم معروف درخت تصمیم J48 استفاده شد. درخت تصمیم در الگوریتم J48 با استفاده از آنتروپی اطلاعات روی مجموعه‌ای از داده‌های آموزشی ساخته می‌شوند. در این بررسی از مجموعه ۹۳۶ تایی داده‌ها با ۵ متغیر استفاده شد. در این بررسی نمونه‌ها با توجه به میزان مقاومت فشاری به ۵ کلاس تقسیم‌بندی شدند سپس از الگوریتم درخت تصمیم برای ساخت مدل درخت تصمیم استفاده شد. به عنوان یک نتیجه مخلوط بتن سه روزه با کمتر از ۲۸ روز سن حتی با وجود فوق‌روان‌کننده هم نمی‌تواند به مقاومت فشاری لازم دست پیدا کند [3].


۳. شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی شامل یک سری عملگرهای محاسباتی هستند که نحوه کار آنها مشابه سیستم‌های عصبی بیولوژیکی است. اجزای شبکه عصبی شامل یک سری ورودی، تعدادی لایه پنهان و یک لایه خروجی است [4]. هر لایه از تعدادی نرون تشکیل شده است. نرون‌های هر لایه با تمام نرون‌های لایه‌های دیگر در ارتباط اند ولی با سایر نرون‌ها در همان لایه ارتباط ندارند. داده‌های ورودی شبکه عصبی به دو زیرمجموعه آموزشی (train set) و آزمایشی (test set) تقسیم‌بندی می‌شوند. از زیرمجموعه آموزشی برای آموزش شبکه و از زیرمجموعه آزمایشی برای سنجش مقادیر بدست‌آمده از شبکه با مقادیر واقعی استفاده می‌شود [5].

الگوریتم آموزش در شبکه عصبی به دنبال حداقل شدن اختلاف بردار خروجی صحیح و بردار خروجی حاصله است. بدین منظور شبکه دارای دو فاز پیش‌رونده (forward feed) و پس‌رونده (backward propagation) است. عملیات بهینه‌سازی در فاز پس‌رونده بر روی ضرایب وزنی انجام می‌شود [4]. در این مقاله برای پیش‌بینی مقاومت فشاری بتن از شبکه عصبی مصنوعی پرسپترون چندلایه استفاده شده است. تابع سیگموئید به عنوان تابع فعالیت در هر لایه در نظر گرفته شده است.

۴. ماشین بردار پشتیبان

این روش از جمله برترین روش‌ها در بین روش‌های یادگیری ماشین محسوب می‌شود که در سال ۱۹۹۵ توسط Vapnik توسعه داده شد. ماشین بردار پشتیبان به عنوان یک روش خطی در تحلیل داده‌ها برای مسأله‌های طبقه‌بندی و رگرسیون قابل استفاده است [6]. در این روش یادگیری نظارت‌شده، به دنبال به حداکثر رساندن فاصله ابرصفحه جداکننده تا نزدیک‌ترین نقطه آموزش (بردار پشتیبان) از هر کلاس به منظور دستیابی به عملکرد مطلوب داده‌های آموزشی هستیم. هنگامی که امکان جداسازی خطی داده‌ها فراهم نباشد معمولاً از یک نگاشت به فضای بالاتر که این امکان جداسازی خطی را فراهم می‌کند استفاده می‌شود. این نگاشت توسط تابعی تحت عنوان "کرنل" انجام می‌شود. این تابع امکان تعیین یک مرز تصمیم غیرخطی را ایجاد می‌کند که در فضای با ابعاد بالاتر خطی است [2].



شکل ۱- تاثیرگذاری داده‌ها در الگوریتم ماشین بردار پشتیبان

در مساله‌های مربوط به پیش‌بینی و رگرسیون هدف این روش یافتن تخمینی $f(x)$ به گونه‌ای است که برای همه نمونه‌های آموزشی x_i حداکثر فاصله آن از مقدار خروجی y_i برابر ε باشد. به عبارت دیگر خطاها تا زمانی که مقداری کمتر از ε داشته باشند، برای ما اهمیت نخواهند داشت. بدین ترتیب مساله رگرسیون بردار پشتیبان را می‌توان به صورت یک مساله خطی مانند زیر فرمول‌بندی کرد.

$$f(x) = w \cdot \phi(x) + b$$

که در آن w و b به ترتیب نشان‌دهنده وزن‌ها و بایاس‌هاست. تابع ϕ نیز داده‌های نگاشت‌شده در فضای بالاتر با امکان جداسازی خطی را نشان می‌دهد. برای پیدا کردن w بهینه از یک مساله بهینه‌سازی به صورت زیر بهره می‌بریم [7]:

$$\begin{aligned} & \text{Minimize} && \frac{1}{2} w^T w \\ & \text{subject to} && \begin{cases} y_i - w^T x_i - b \leq \varepsilon \\ w^T x_i + b - y_i \leq \varepsilon \end{cases} \end{aligned}$$

۵. درخت تصمیم‌گیری

یکی از روش‌های یادگیری ماشین که یادگیری استقرایی مغز را شبیه‌سازی می‌کند، درخت تصمیم‌گیری است. این روش در مقایسه با سایر روش‌های محاسبه نرم تقریباً جدید محسوب می‌شود. در این روش، نگاشتی از فضای مشاهده‌شده در مورد یک پدیده به استنتاج‌هایی در مورد فضای هدف ایجاد می‌شود. به سخن دیگر، درخت تصمیم‌گیری را با جستجو در فضای نمادی مشاهدات مجموعه آموزشی انجام می‌دهد و نتیجه را به صورت گزاره‌های منطقی، قاعده‌ها و یا طبقه‌بندی ممکن ذخیره می‌کند. با توجه به وجود فضای نمادی در شیوه‌ی درخت تصمیم‌گیری، لزومی بر عددی بودن داده‌های ورودی وجود ندارد. در صورتی که شبکه‌های عصبی فقط در فضای عددی قابل استفاده هستند و بر اساس وزن‌دهی به یک سری از پارامترها آموزش می‌بینند. برعکس شبکه‌های عصبی، درخت تصمیم به تولید قانون می‌پردازد. مدل MSP از جمله مدل‌های درخت تصمیم است که در مقایسه با سایر مدل‌های درخت رگرسیونی از دقت بیشتری برخوردار است و همزمان قاعده‌های ایجاد شده توسط آن نسبت به نتایج بدست‌آمده از شبکه عصبی قابل فهم‌تر است [8]. با این وجود عملکرد درخت تصمیم در برخی موارد ضعیف‌ترین از سایر الگوریتم‌های یادگیری ماشین است. دو دلیل عمده در این رابطه ذکر شده‌است: اول اینکه درخت تصمیم به راحتی تحت تاثیر داده‌های اریب (دارای نویز) قرار می‌گیرد و دوم ویژگی‌های اضافی هستند که کارایی درخت تصمیم را کاهش می‌دهند [9].

روند ایجاد درخت، شامل تقسیم فضای ورودی به چند ناحیه با استفاده از مدل رگرسیون خطی چند متغیره است. در این فرایند، هر داده جدید در یکی از برگ‌های درخت قرار می‌گیرد. این روند با توجه به شرایط تقسیم‌بندی بدست‌آمده از مرحله قبل صورت می‌پذیرد. در نهایت، خروجی پیش‌بینی شده در برگ درختی که هر داده در آن قرار گرفته، محاسبه می‌گردد [8]. در مدل MSP ابتدا یک درخت رگرسیون با توجه به تقسیم‌بندی فضای نمونه ایجاد می‌شود. این کار برای حداقل کردن تغییرات درون داده‌های هر زیرمجموعه، از ریشه تا گره و در طول شاخه‌ها انجام می‌شود. در MSP، مقدار تغییرات با استفاده از محاسبه انحراف‌معیار داده‌ها مشخص می‌گردد. به سخن دیگر، ویژگی‌های با بیش‌ترین مقدار کاهش خطا انتخاب می‌گردند. شاخص کاهش انحراف‌معیار داده‌ها توسط رابطه زیر محاسبه می‌شود:

$$SDR = sd(I) - \sum_i \frac{|I_i|}{|I|} \times sd(I_i)$$

که در آن پارامترهای I و sd به ترتیب نشان‌دهنده مجموعه داده‌ها قرار گرفته در هر گره و انحراف‌معیار داده‌ها می‌باشد. I_i نیز داده‌هایی را نشان می‌دهد که در نتیجه تقسیم‌بندی گره با توجه به پارامترهای انتخاب‌شده برای تقسیم‌بندی فضای داده‌ها، تعیین شده‌اند. پس از ایجاد شاخه‌های درخت، یک مدل رگرسیون خطی چندمتغیره برای هر گره داخلی ساخته می‌شود.

در سال ۲۰۰۱ برایم الگوریتم جنگل تصادفی (RF) را به عنوان یک روش توسعه‌یافته از الگوریتم‌های درخت تصمیم معرفی نمود. این روش پیش‌بینی چندین الگوریتم منفرد را با هم و با استفاده از قوانین مبتنی بر درخت تصمیم ترکیب می‌کند [10]. فرض اساسی این روش بر این پایه استوار است که تکنیک‌های بکارگرفته‌شده در آموزش گروهی از دیگر الگوریتم‌های آموزشی بالاتر است، زیرا ترکیب چند مدل پیش‌بینی دقیق‌تر از یک مدل خواهد بود. رگرسیون جنگل تصادفی مجموعه‌ای از شرایط یا محدودیت‌ها را بیان می‌کند که به صورت سلسله مراتبی شکل گرفته‌اند و به صورت پشت‌سرهم به سمت پایین رشد می‌کند. برای این کار از جزءبندی بازگشتی و رگرسیون‌های چندگانه استفاده می‌شود. توضیحات کامل‌تری در این زمینه در مرجع [11] موجود است.

۶. مجموعه داده

داده‌های آزمایشگاهی از ۱۷ منبع متفاوت توسط yeh در سال ۱۹۹۸ جمع‌آوری گردید [12]. این داده‌ها برای بتن‌های حاوی سیمان به علاوه سایر مواد افزودنی نظیر خاکستر بادی، سرباره و فوق‌روان‌کننده گردآوری شد. داده‌هی مربوط، مشخصات نزدیک به ۱۰۰۰ طرح اختلاط بتن را شامل می‌شود. از این مقدار حدود ۷۰۰ نمونه با استفاده از سیمان پرتلند ساخته و در شرایط طبیعی عمل‌آوری شده‌اند. نمونه‌ها با ابعاد متفاوتی در بین این داده‌ها دیده می‌شود که همگی بر اساس آیین‌نامه‌های موجود به نمونه استوانه‌ای ۱۵ سانتی‌متری تبدیل شدند. در برخی موارد کلاس (نوع) خاکستر بادی و یا سازنده فوق‌روان‌کننده مورد استفاده در داده‌ها ذکر نشده است که خود می‌تواند سبب بروز خطاهای احتمالی باشد. با این توصیف، مشخصات طرح اختلاط بتن حاوی مواد افزودنی شامل سیمان، نسبت آب به سیمان، سرباره کوره، خاکستر بادی، درشت‌دانه، ریزدانه، سن نمونه و مقدار فوق‌روان‌کننده بر حسب کیلوگرم در مترمکعب در جدول ۱ ذکر شده است.

جدول ۱ - مشخصات آماری داده‌های طرح اختلاط مورد استفاده در این پژوهش

بیشینه (min)	کمینه (max)	میانگین (Mean)	انحراف معیار (StdDV)	
۱۰۲	۵۴۰	۲۸۱/۱۷	۱۰۴/۵	سیمان
۰	۳۵۹/۴	۷۳/۹	۸۶/۲۸	سرباره کوره
۰	۲۰۰/۱	۵۴/۲	۶۴	خاکستر بادی
۱۲۱/۸	۲۴۷	۱۸۱/۵۷	۲۱/۳۵	آب
۰	۳۲/۲	۶/۲	۵/۹۷	فوق‌روان‌کننده
۸۰۱	۱۱۴۵	۹۷۲/۹۲	۷۷/۷۵	درشت‌دانه
۵۹۴	۹۹۲/۶	۷۷۳/۶	۸۰/۱۸	ریزدانه
۱	۳۶۵	۴۵/۶۶	۶۳/۱۷	سن
۲/۳۳	۸۲/۶	۳۵/۸۲	۱۶/۷	مقاومت فشاری (MPa)

۷. معیارهای مقایسه

نتایج بررسی قابلیت پیش‌بینی الگوریتم‌های متفاوت یادگیری ماشین بر روی مجموعه داده ۱۰۰۰ تایی طرح اختلاط بتن توسط سه معیار ضریب همبستگی، میانگین خطای مطلق و خطای جذر میانگین مربع‌ها مقایسه می‌شوند.

ضریب همبستگی (Correlation Coefficient) ابزاری آماری برای تعیین نوع و درجه رابطه یک متغیر کمی با دیگری است. ضریب همبستگی یکی از معیارهای مورد استفاده در تعیین همبستگی دو متغیر است. این ضریب شدت رابطه و همچنین نوع رابطه (مستقیم یا معکوس) را نشان می‌دهد و بین ۱ و -۱ متغیر است. ضریب همبستگی در صورت عدم وجود رابطه بین دو متغیر برابر صفر خواهد بود و همچنین از فرمول زیر محاسبه می‌گردد:

$$\text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y}$$

میانگین خطای مطلق (Mean Absolute Error) نشان‌دهنده قدرمطلق متوسط خطای بین مقدار پیش‌بینی شده برای داده جدید و مقدار واقعی آن را نشان می‌دهد و از رابطه زیر محاسبه می‌شود:

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_i - Y_i|$$

خطای جذر میانگین مربعی () تفاوت میان مقدار پیش‌بینی شده توسط الگوریتم ماشین با مقدار واقعی را آشکار می‌سازد. این مقدار از رابطه زیر بدست می‌آید:

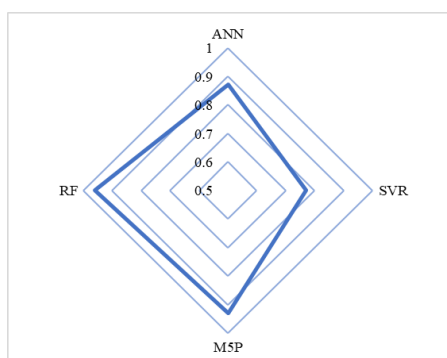
$$RMSE = \sqrt{MSE} = \sqrt{E((X_i - Y_i)^2)}$$

۸. بحث بر روی نتایج

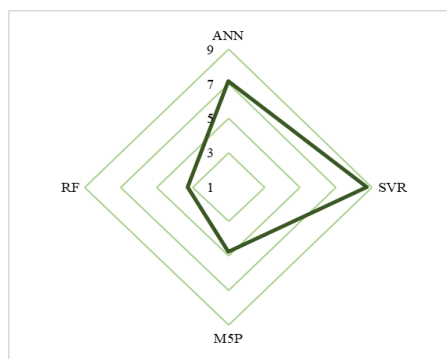
با توجه به شکل‌های ۲ تا ۴ مشخص می‌شود که روش‌های مبتنی بر درخت تصمیم پاسخ بهتری را نسبت به دو روش شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان نتیجه می‌دهند. برای این مقایسه از سه معیار ضریب همبستگی، میانگین خطای مطلق و خطای جذر میانگین مربعی استفاده شد. همانگونه که در شکل ۲ مشخص است ضریب همبستگی داده‌های پیش‌بینی شده و داده‌های واقعی در روش‌های مبتنی بر درخت تصمیم (MP5 و RF) مقدار بیشتری را دارد. این مقدار در روش‌های شبکه عصبی و بردار پشتیبان به ترتیب برابر با ۰/۸۷ و ۰/۷۷ گزارش شده است و می‌توان نتیجه گرفت که روش شبکه عصبی عملکرد بهتری را نسبت به رگرسیون بردار پشتیبان داشته است.

در مقایسه چهار الگوریتم یادگیری ماشین با استفاده از معیار میانگین خطای مطلق که نتایج آن در شکل ۳ آمده است، دو روش MP5 و RF خطای کمتری را گزارش کردند در حالی که میانگین خطای مطلق در روش‌های SVR و ANN به ترتیب برابر با ۸/۶۹ و ۷/۱۳ است. این مطلب حاکی از آن است که استفاده از الگوریتم‌های مبتنی بر درخت تصمیم‌گیری به منظور پیش‌بینی مقاومت فشاری بتن عملکرد قابل قبولی را داشته‌اند.


به عنوان آخرین و مهم‌ترین معیار، مقایسه بر اساس خطای جذر میانگین مربعی انجام شد (شکل ۴). این معیار خطا برای روش RF عددی برابر با ۴/۷۴ بدست آمده است که در مقایسه با سایر الگوریتم‌ها مقدار کمتری دارد. بیش‌ترین خطای جذر میانگین مربعی مربوط به الگوریتم رگرسیون بردار پشتیبان است که برابر با ۱۰/۸۲ گزارش شده است.



شکل ۲- مقایسه ضریب همبستگی (Corr) الگوریتم‌های مختلف یادگیری ماشین



شکل ۳- مقایسه میانگین خطای مطلق (MAE) الگوریتم‌های مختلف یادگیری ماشین



شکل ۴- مقایسه خطای جذر میانگین مربع های (RMSE) الگوریتم های مختلف یادگیری ماشین

۹. نتیجه گیری

با توجه به اینکه محاسبه مقاومت فشاری بتن از جمله مهم ترین مساله های مطرح شده در زمینه مهندسی عمران است و از طرفی مجموعه داده های فراوانی نیز در این زمینه موجود است، الگوریتم های یادگیری ماشین می توانند به عنوان ابزاری دقیق و کارا برای حل این مساله بکار روند. در این مقاله چهار الگوی الگوریتم ماشین برای حل مساله رگرسیون مقاومت فشاری بتن مورد بررسی و مقایسه قرار گرفت. برای این کار از یک مجموعه ۱۰۰۰ تایی طرح اختلاط بتن با ۸ متغیر مستقل استفاده شد. شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان، درخت تصمیم MP5 و جنگل تصادفی چهار الگوریتم یادگیری ماشین استفاده شده در این تحقیق بودند. به منظور مقایسه این الگوریتم ها از سه معیار ضریب همبستگی، میانگین خطای مطلق و جذر خطای میانگین مربع ها استفاده شد. در انتها الگوریتم جنگل تصادفی با کمترین مقدار خطای و بیشترین میزان ضریب همبستگی به عنوان الگوی برتر برای تخمین مقاومت فشاری بتن برگزیده شد.

۱۰. مراجع

- [1] رمضانپور، ع. ا.، پیلوار، ا. ر. و سبحانی، ج. (۱۳۹۱)، "تخمین مقاومت فشاری بتن با استفاده از شبکه عصبی مصنوعی"، چهارمین کنفرانس ملی سالیانه بتن ایران، تهران، ایران.
- [2] ترکان، م. و نادری دهکردی، م. (۱۳۹۵)، "بهینه سازی مدل رگرسیون بردار پشتیبان () با استفاده از الگوریتم ازدحام ذره () به منظور پیش بینی مقاومت فشاری ۲۸ روزه بتن"، اولین کنفرانس بین المللی علوم کامپیوتر و مهندسی، دانشگاه آزاد اسلامی واحد نجف آباد، ایران.
- [3] داوودی، ه. (۱۳۹۵)، "ارزیابی تاثیر فوق روان کننده بر مقاومت فشاری بتن با استفاده از الگوریتم طبقه بندی درخت تصمیم"، چهارمین همایش ملی مصالح ساختمانی و فناوری های نوین در عمران، معماری و شهرسازی، دانشگاه آزاد اسلامی واحد میبد، ایران.
- [4] برنجیان، فروهر، نویدرضا و قاسمی، (۲۰۱۴)، "پیش بینی مشخصات سخت شده بتن خودتراکم الیافی به کمک شبکه های عصبی مصنوعی". پژوهش های تجربی در مهندسی عمران، ۱ (پاییز و زمستان ۹۳)، ۸۹-۹۹.
- [5] یوسفی، م. م. و مظلوم، م. (۲۰۱۴). "روش های ترکیب شبکه عصبی در پیش بینی نتایج آزمایشات روانی و مقاومتی بتن خودتراکم". مدل سازی در مهندسی، ۱۲ (۳۷)، ۳۹-۴۹.
- [6] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- [7] Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14(3), 199-222.
- [8] گودرزیان، ع.، نیکو، م. ر.، حسن زاده، ی. و نصیریور، م. (۱۳۹۱)، "کاربرد الگوریتم MP5 جهت پیش بینی عمق و سرعت جریان بر روی پرتاب-کننده جامی سدها: مطالعه موردی، سد جره"، یازدهمین کنفرانس هیدرولیک ایران، دانشگاه ارومیه، ایران.



دوازدهمین کنگره ملی مهندسی عمران

۸ و ۷ خرداد ۱۳۹۹

دانشگاه صنعتی سهند، تبریز، ایران



[9] Erdal, H. I. (2013). Two-level and hybrid ensembles of decision trees for high performance concrete compressive strength prediction. *Engineering Applications of Artificial Intelligence*, 26(7), 1689-1697.

[10] Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.

[11] نوروزی، ح.، ندیری، ع.، اصغری مقدم، ا. و قره خانی، م.، (۱۳۹۵). "پیش‌بینی قابلیت انتقال آبخوان دشت ملکان با استفاده از روش جنگل تصادفی". دانش آب و خاک، ۲۷(۲)، ۶۱-۷۵.

[12] Yeh, I. C. (1998). Modeling of strength of high-performance concrete using artificial neural networks. *Cement and Concrete research*, 28(12), 1797-1808.