

Predicting Properties of Self-Compacting Concrete using Integrated Models based on Metaheuristic Algorithms

Hadi pouryan¹, Ashkan KhodaBandehLou^{2*}, Peyman Hamidi³, Fedra ashrafzadeh⁴

1- Ph.D. Student, Department of Civil Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran

2- Associate Professor, Department of Civil Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran, Email: a.khodabandehlou@iaurmia.ac.ir

3- Assistant Professor, Department of Civil Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran

4- Assistant Professor, Department of Civil Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran

Received: 01 February 2024 Revised: 01 January 2025 Accepted: 05 January 2025

Research paper

Abstract

Concrete is one of the most fundamental and widely used materials in the construction industry. Development and innovation in this field have led to the introduction of self-compacting concrete (SCC), which has brought considerable technological developments. The mix design of SCC is one of the substantial issues, so the number of materials used in this concrete must be measured precisely. On the other hand, testing the compressive strength of concrete at certain ages causes high costs, concrete waste, and environmental damage. Modern artificial intelligence techniques that are capable of learning and modeling sophisticated problems have been increasingly used in concrete technology over the past years. Therefore, this study adopts various machine learning methods, including support vector machine (SVM), Multivariate Adaptive Regression Splines (MARS), and model tree (Mp5-MT) to predict the rheological behaviors and compressive strength of SCC. For this purpose, four parameters of slump flow's diameter, L-box ratio (L), funnel duration (V), and 28-day compressive strength of concrete were collected through authenticate resources. Input variables included Binder amount, Supplementary Cementitious Materials (SCMs), water binder ratio, amount of fine and dry materials, and Superplasticizers. As the MARS technique comprises some hyperparameters whose values highly affect the model accuracy, the optimization technique of the Gravitational Search Algorithm (GSA) has been used in this study to determine these values. The results of this study showed that the MARS model integrated with the optimization GSA technique can enhance the anticipation accuracy by up to 1.35%, 11.1%, 2.3%, and 1.07% rather than the MARS model. Also, the Mp5-MT model outperformed the MARS-GSA model in predicting results, so this is proposed as the selected model for predicting rheological behaviors and compressive strength of SCC.

Keywords: Self-Compacting Concrete, Rheological Properties, Compressive Strength, Machine Learning, Metaheuristic Optimization Algorithm

*Corresponding Author: Ashkan KhodaBandehLou

pouryan, H., KhodaBandehLou, A., Hamidi, P., ashrafzadeh, F. Predicting properties of self-compacting concrete using integrated models based on metaheuristic algorithms. *Journal of Concrete Structures and Materials*, 2024; 9(1): 1-29. <http://doi.org.10.30478/jcsm.2025.441113.1360>

2538-5828/ © 2025 The Authors. Published by Iranian Concrete Society

This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

پیش‌بینی خواص بتن خودتراکم با استفاده از مدل‌های تلفیقی بر پایه الگوریتم‌های فرا ابتکاری

هادی پوریان^۱، اشکان خدابنده‌لو^{۲*}، پیمان حمیدی^۳، فدرا اشرف زاده^۴

۱- دانشجوی دکتری، گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

۲- دانشیار، گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

۳- استادیار، گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

۴- استادیار، گروه مهندسی عمران، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

پست الکترونیکی نویسنده مسئول: a.khodabandehlou@iaurmia.ac.ir

تاریخ دریافت: ۱۳۹۲/۱۱/۱۴، تاریخ بازنگری: ۱۳۹۳/۱۰/۱۲، تاریخ پذیرش: ۱۳۹۳/۱۰/۱۶

نوع مقاله: پژوهشی

چکیده

بتن یکی از اساسی‌ترین و پرمصرفترین مصالح در صنعت ساخت و ساز می‌باشد. توسعه و نوآوری در این زمینه به معرفی بتن خودتراکم منجر شده که خود پیشرفت‌های عظیمی را به دنبال داشته‌است. طرح مخلوط بتن خودتراکم از مسائل بسیار با اهمیت بوده و لازم است تا مقادیر مصالح مصرفی در این بتن با دقت زیادی تعیین شود. از طرفی انجام آزمایش مقاومت فشاری بتن در سنین مقرر باعث، صرف هزینه زیاد، تولید پسماند بتن و آسیب به محیط زیست می‌شود. طی سالیان گذشته استفاده از روش‌های نوین هوش مصنوعی که توانایی یادگیری و مدل‌سازی مسائل پیچیده را دارند در حوزه تکنولوژی بتن افزایش یافته‌است. بنابراین تحقیق حاضر از روش‌های یادگیری ماشین مختلف، از جمله ماشین بردار پشتیبانی (SVM)، رگرسیون اسپلاین چند متغیره تطبیقی (MARS) و مدل درخت (Mp5-MT) برای پیش‌بینی رفتارهای رئولوژی به همراه مقاومت فشاری بتن خودتراکم استفاده می‌کند. بدین منظور چهار پارامتر قطر جریان اسلامپ، نسبت جعبه (L)، مدت زمان قیف (V) و مقاومت فشاری ۲۸ روزه بتن از مراجع موثق جمع‌آوری شده‌است. مقدار بایندر، درصد مواد جایگزین سیمان (SCMs)، نسبت آب به بایندر، مقدار مصالح ریز و مصالح خشک و مقدار سوپرپلاستیسیز به عنوان متغیرهای ورودی انتخاب شدند. با توجه به اینکه روش MARS دارای درونپارامترهایی (Hyper-parameter) بوده که مقدار آن‌ها بر دقت مدل بسیار تاثیرگذار است، در این تحقیق از تکنیک بهینه‌سازی الگوریتم جستجوی گرانش (Gravitational Search Algorithm, GSA) برای تعیین آن‌ها استفاده شده‌است. نتایج این تحقیق نشان داد که مدل MARS ترکیب شده با تکنیک بهینه‌سازی الگوریتم جستجوی گرانش می‌تواند دقت پیش‌بینی متغیرهای مد نظر را به ترتیب تا ۱/۳۵، ۱۱/۱، ۲/۳ و ۱/۰۷ درصد نسبت به مدل MARS افزایش دهد. همچنین مدل Mp5-MT توانایی بیشتری در پیش‌بینی نتایج در مقایسه با مدل MARS-GSA از خود نشان داد که به عنوان مدل منتخب برای پیش‌بینی رفتارهای رئولوژیکی و مقاومت فشاری بتن خودتراکم معرفی می‌گردد.

کلمات کلیدی: بتن خودتراکم، ویژگی‌های رئولوژی، استحکام فشاری، یادگیری ماشین، الگوریتم بهینه‌سازی فراابتکاری.

بتن یکی از اساسیترین و پرمصرفترین مصالح در صنعت ساخت و ساز است و الزام به توسعه آن روز به روز افزایش می‌یابد. معرفی بتن خودتراکم (Self compacting concrete)، پیشرفت‌های تکنولوژیکی عظیمی را به دنبال داشته‌است. به عنوان مثال، با استفاده از بتن خودتراکم می‌توان زمان ساخت، هزینه و میزان سر و صدا در کارگاه‌های ساختمانی را کاهش داد. بتن خودتراکم، بتنی است که بدون نیاز به ویبره و متراکمسازی، فقط به واسطه وزن خود می‌تواند در داخل قالب جریان یابد و در یک فرآیند طبیعی آن را پر و از میان میلگردها و دیگر موانع موجود عبور کند.

لازم به ذکر است که برای دستیابی به تراکم کافی و پر نمودن فضای بین آرماتورها، بتن تازه باید هر دو حالت سیالیت بالا و چسبندگی خوب را به صورت هم‌زمان داشته باشد. در حقیقت وقتی بتن از چسبندگی بالا برخوردار نباشد، زمانی که بتن در نزدیک یک مانع جریان می‌یابد، سنگدانه‌های درشت ممکن است توسط مانع متوقف شده و شروع به بریدن ملات بتن نماید و جریان بتن را متوقف می‌نماید [۱]. روانی بتن یک فاکتور مهم برای قابلیت مناسب اجراست که پس از فراگیر شدن استفاده از آرماتور در بتن از اوایل قرن بیستم و لزوم استفاده از بتن با کارایی بالا مد نظر قرار گرفت. در بتن خودتراکم، فوق روان‌کننده و مواد پودری برای حصول کارایی بالا و گرانروی مناسب و عدم جداشدگی مهم است [۲]. فوق روان‌کننده‌ها نسل جدیدی از روان‌کننده‌ها هستند که می‌توانند با یک نسبت آب به سیمان، به طور چشمگیری کارپذیری و روانی ملات‌ها و بتن‌ها را افزایش دهند و یا در یک کارپذیری ثابت، به مقدار قابل ملاحظه‌ای، نسبت آب به سیمان را کاهش دهند که موجب تولید بتن با مقاومت بالا و کم‌شدن خزش می‌شود [۳]. فوق روان‌کننده‌ها از لحاظ ترکیب شیمیایی مواد تغلیظ شده فرمالدهید ملامین می‌باشند که این مواد دارای خاصیت کندگیرکنندگی نیز می‌باشند. در یک نسبت آب به سیمان معین، این خاصیت فوق روان‌کننده خواهد بود اسلامپ را از ۷۵ میلی‌متر به ۲۰۰ میلی‌متر افزایش دهد، در حالیکه مخلوط چسبندگی خود را حفظ کند [۴]. محققین مشاهده کرده‌اند که مصرف هم‌زمان ملامین و یا نفتالین با درصد بالای مصالح ریزدانه می‌تواند در اصلاح لزجت و روانی مؤثر باشد [۵].

با توجه به اینکه مصرف زیاد سیمان و فوق روان‌کننده، هزینه‌های زیادی را در پی داشته، استفاده از مواد پودری مکمل سیمان مثل متاکائولن به عنوان جایگزین درصدی از سیمان مورد توجه قرار گرفته‌است. استفاده از متاکائولن، مقاومت و پایداری بتن را در برابر حمله‌های شیمیایی، سولفات‌ها و انبساط‌های ناشی از واکنش‌های کلیایی سیلیکاتی و سیکل‌های یخ‌زدن و آب‌شدن افزایش می‌دهد. متاکائولن همچنین در برخی از خواص مکانیکی بتن شامل مقاومت فشاری، خواص کوتاه مدت و مقاومت خمشی مؤثر است. براساس تحقیقات انجام شده، استفاده از متاکائولن، ریزساختار، تخلخل، نفوذپذیری، مقاومت فشاری، مقاومت در برابر حمله سولفات بتن و دیگر خصوصیات مکانیکی و پایایی بتن را بهبود می‌بخشد [۶].

علاوه بر این، برخی راهکارها برای نسبت اختلاط بهینه بتن خودتراکم از قبیل کاهش نسبت سنگدانه به مواد سیمانی، افزایش مقدار خمیر پایه سیمانی با نسبت آب به سیمان مشخص، کنترل بزرگترین اندازه سنگدانه درشت پیشنهاد شده‌است. طرح اختلاط بتن را می‌توان به عنوان فرآیندی در نظر گرفت که تلاش می‌کند بتن اقتصادی با کارایی، مقاومت و دوام کافی را با انتخاب مناسب مواد متشکله و تعیین مقادیر نسبی آن‌ها تولید کند. تحقیقات انجام شده نشان می‌دهد که دامنه طرح اختلاط و مواد ترکیبی در انواع بتن خودتراکم بسیار گسترده بوده و محدوده وسیعی از مخلوط‌های مناسب بتن خودتراکم برای کاربردهای مختلف ارائه شده‌است [۷]. براساس طرح اولیه اصلی اکامورا و ازوا در حالت کلی سه روش برای تولید بتن خودتراکم (روش پودری، استفاده از فوق روان‌کننده و اصلاح ویسکوزیته و روش ترکیبی) وجود دارد [۸].

روش‌های متفاوتی، از جمله آزمایش جریان اسلامپ [۹]، قیف ۷، جعبه L و آزمایش مقاومت فشاری [۱۰] برای تست بتن تازه

خود متراکم پیشنهاد شده است. متأسفانه هیچ کدام از آن‌ها به تنهایی یا ترکیبی از آن‌ها نتوانسته است به طور جامع سه خاصیت کلیدی (توانایی جاری شدن در قالب، توانایی گذشتن آزادانه از بین آرماتورها و مقاومت در برابر جدا شدن از هم) این نوع بتن را به درستی اندازه‌گیری نماید.

علاوه بر این، در سالیان اخیر از مدل‌های داده مبنا و ترکیب این روش‌ها با الگوریتم‌های فرا ابتکاری برای ارزیابی خواص بتن استفاده شده است. بلالیا دوما و همکاران^۱ از روش رگرسیون اسپلاین چند متغیره تطبیقی برای تخمین مقاومت فشاری بتن خودتراکم با استفاده از داده‌های حاوی خاکستر بادی استفاده کردند [۱۱]. عمادی و مدنی شبکه عصبی مصنوعی، انفیس و ماشین بردار پشتیبان را برای تخمین مقاومت فشاری بتن غلتکی از سن نمونه، شن، ماسه، سیمان، آب و خاکستر بادی به کار بردند. نتایج نشان داده که مدل شبکه عصبی مصنوعی توانایی بیشتری در پیش‌بینی مقاومت فشاری بتن غلتکی دارد [۵]. غنی زاده و همکاران، مقاومت فشاری بتن را با استفاده از روش سطح پاسخ پیش‌بینی کردند. نتایج اسن تحقیق نشان داد که برهمکنش میان سیمان و خرده آسفالت ریزدانه، برهمکنش میان درشتدانه طبیعی و زمان عملآوری، برهمکنش میان خرده آسفالت ریزدانه و زمان عملآوری و همچنین برهمکنش مجذور زمان عملآوری و مجذور دما نیز توانسته در پیش‌بینی مقادیر مقاومت فشاری تأثیرگذار است. علاوه بر این، مقاومت فشاری با افزایش مقدار سیمان افزایش خواهد یافت به طوری که با افزایش مقدار خرده آسفالت ریزدانه نرخ افزایش مقاومت کاهش می‌یابد. به علاوه کاهش مقدار خرده آسفالت ریزدانه یا افزایش زمان عملآوری در یک میزان درشتدانه طبیعی ثابت، افزایش مقاومت فشاری را در پی خواهد داشت. همچنین ملاحظه گردید که با افزایش درصد خرده آسفالت ریزدانه، تأثیر زمان عملآوری بر روی مقاومت فشاری کاهش می‌یابد [۱۲]. فتحی و همکاران در تحقیقی به پیش‌بینی مقاومت فشاری بتن حاوی پوزولان به کمک شبکه‌ی عصبی مصنوعی و تحلیل رگرسیون پرداختند. ۸۰ نمونه با مقاومت فشاری ۷ و ۲۸ روزه مورد تحلیل قرار گرفته است. نتایج نشان داد که شبکه‌ی عصبی با الگوریتم لوبنبرگ مارکوارت، بهترین دقت و تحلیل رگرسیون و کمترین دقت را برای تعیین مقاومت فشاری بتن دارند [۱۳]. اشرفیان و همکاران، در تحقیقی قابلیت ابزار هوش مصنوعی در مدل‌های داده مبنا را با استفاده از دو روش مدل درخت و مارس جهت تخمین جریان اسلامپ در بتن خودتراکم حاوی متاکائولن بررسی کردند. ایشان با استفاده از قابلیت فرموله کردن این روش‌ها مدل‌های خطی و غیر خطی جهت برآورد جریان اسلامپ ارائه نمودند [۱۴]. طاهری امیری و همکاران (۱۳۹۸) با استفاده از روش بیان ژن (Gene Expression Programming) خواص و مصالح بتن حاوی خاکستر پوسته برنج را مورد بررسی قرار دادند. نتایج این تحقیق نشان داد نتایج مدل‌سازی نشان داد که این روش قادر است با دقت ۹۰ درصد مقاومت فشاری را پیش‌بینی کند [۱۵].

گلوپسکی و اسزوستک^۲، یک مدل شبکه عصبی مصنوعی را برای ارزیابی طرح اختلاط بتن حاوی خرده آجر بازیافتی را با استفاده از معیار مقاومت فشاری ارائه دادند. در این مطالعه از پایگاه داده‌های شامل ۱۴۷ نتیجه برای آزمایش مقاومت فشاری برای مرحله آموزش و آزمون استفاده شده است [۱۶]. بهنود و همکاران، مقاومت فشاری بتن حاوی دوده سیلیس را با استفاده از شبکه عصبی مصنوعی تخمین زدند. در این راستا، در این مطالعه از روش بهینه‌سازی چندهدفی گرگ‌های خاکستری برای اجرای مرحله آموزش استفاده شده است [۱۷]. احسانی و همکاران، به ارزیابی مقاومت فشاری بتن حاوی خاکستر بادی و دوده سیلیسی با استفاده از الگوریتم کلونی زنبور عسل مصنوعی پرداختند. در این مطالعه از ۷ متغیر به عنوان پارامترهای ورودی برای ارزیابی و پیش‌بینی مقاومت فشاری استفاده شده است [۱۸]. سادووسکی و همکاران^۳، یک مدل کمی بهینه برای مقاومت فشاری بتن سازگار با محیط زیست حاوی کوارتز معدنی ارائه دادند.

¹ Belalia Douma et al.

² Golewski & Szostak

³ Sadowski et al.

در این مطالعه، مقاومت فشاری بر مبنای شبکه عصبی مصنوعی با ۴ متغیر ورودی و ۹ لایه مخفی توسعه یافته است [۱۹]. سان و همکاران^۴، با استفاده از الگوریتم فرا ابتکاری کلونی زنبور عسل جمع شده با روش‌های رگرسیونی به بهینه‌سازی و تخمین مقادیر مقاومت فشاری نمونه‌های بتنی حاوی دوده سیلیسی و خاکستر بادی پرداختند [۲۰]. آستریس و همکاران^۵، روش غیر خطی و غیر پارامتریک مارس و همچنین مدل درخت را برای پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی پوزولان متاکائولن به کار بردند. این مطالعه برای اولین بار اندازه بزرگ‌ترین سنگدانه را به عنوان ورودی در نظر گرفته و تحلیل کرده است [۲۱]. ده روسا و همکاران^۶، مقاومت فشاری ۱۰۰۰ نمونه بتن درجا را با استفاده از روش‌های هوشمند مختلف رگرسیونی درخت تصمیم، کرنلی و چندگانه مدل‌سازی کردند. متغیرهای بررسی شده در این تحقیق شامل سیمان، خاکستر بادی، شن، ماسه، آب، حجم هوا و افزودنی کاهنده آب می‌باشد [۲۲]. گل افشانی و همکاران، با به کارگیری پارامترهای طرح اختلاط، به پیش‌بینی مقاومت فشاری ۲۸ بتن بازیافتی و بتن پرتلند پرداختند. این تحقیق با ترکیب الگوریتم فراابتکاری گرگ خاکستری و روش‌های شبکه عصبی مصنوعی و انفیس مدل‌های بهینه‌شده رگرسیونی را ارائه می‌دهد [۲۳]. ستار و همکاران، مقاومت فشاری بتن ژئوپلیمر حاوی پوزولان‌های طبیعی را با استفاده از روش‌های شبکه عصبی مصنوعی و شبکه عصبی استنتاجی فازی مورد ارزیابی قرار دادند. نتایج این تحقیق نشان داد مدل توسعه داده شده روش عصبی استنتاجی فازی با میانگین خطای مطلق ۱/۶۵۵ مگاپاسکال عملکرد بهتری در مقایسه با شبکه عصبی با میانگین خطای مطلق ۱/۹۸۹ داشته است [۲۴]. جارادت و همکاران^۷، با استفاده از چند روش هوشمند مصنوعی رایج نظیر رگرسیون خطی، جنگل تصادفی، درخت تصمیم و ماشین بردار پشتیبان به مدل‌سازی مقاومت فشاری بتن خودتراکم پرداختند. آن‌ها در مطالعه خود، ابتدا با استفاده از طرح‌های اختلاط منتخب، تحلیل آزمایشگاهی از خواص مکانیکی این بتن نظیر تست اولتراسونیک و مقاومت فشاری در سنین ۱، ۷ و ۲۸ روزه انجام دادند. سپس طرح‌های اختلاط این مطالعه جهت مدل‌سازی وارد هر یک از مدل‌ها شدند و مدل برتر با توجه به مقادیر شاخص آماری خطا تعیین گردید [۲۵].

به صورت خلاصه می‌توان نتیجه گرفت که هنوز هیچ استاندارد جهانی برای طراحی اختلاط بتن خودتراکم وجود ندارد و بسیاری از مراکز علمی و شرکتهای ساخت بتن، از روش‌های ابتکاری خود در این زمینه استفاده می‌کنند. علاوه بر این، گستردگی مواد و مصالح مورد استفاده در این نوع بتن و پیچیدگی طرح اختلاط و متاثر بودن طرح اختلاط آن از پارامترهای مختلف و نیز یافتن روابط بین پارامترهای مختلف طرح اختلاط آن، باعث شده است تا ارائه مدلی برای طرح اختلاط بتن خودتراکم، امری ضروری به نظر برسد. بنابراین، در تحقیق حاضر، خواص بتن خودتراکم حاوی پوزولان با استفاده از روش‌های نوین با قابلیت فرموله کردن و ارائه روابط بهینه شامل ماشین بردار پشتیبانی (SVM)، رگرسیون اسپلاین چندمتغیره تطبیقی (MARS)، مدل درختی (MT) مدل‌سازی شده و مورد تجزیه و تحلیل قرار می‌گیرد.

۲- روش‌های هوش مصنوعی

در این بخش تلاش می‌شود روش‌های هوش مصنوعی مورد استفاده در این تحقیق به صورت خلاصه تشریح شوند.

⁴ Sun et al.

⁵ Asteris et al.

⁶ DeRousseau et al.

⁷ Jaradat et al.

۱-۲- رگرسیون اسپلاین چند متغیره تطبیقی (MARS)

رگرسیون اسپلاین چندمتغیره تطبیقی یا مارس، روش رگرسیونی غیر خطی و ناپارامتریک است که اولین بار توسط فریدمن معرفی شد. مارس، پاسخ‌های غیرخطی را بین ورودی‌ها و خروجی یک سیستم به وسیله مجموعه‌ای از قطعه‌های خطی تکه‌ای (کثیرالجزءه‌های چند قطعه‌ای) با گرادین‌های متفاوت مدل‌سازی می‌کند. فرضی ثابت درباره رابطه تابعی اساسی بین متغیرهای ورودی و خروجی لازم نیست. نقاط انتهایی این قطعه‌ها، گره نامیده می‌شوند. گره، انتهای یک ناحیه از داده‌ها و ابتدای ناحیه‌ای دیگر از داده‌ها را مشخص می‌کند. منحنی‌های قطعه‌ای منتج (شناخته شده به عنوان توابع پایه)، انعطاف‌پذیری بیشتری را به مدل می‌دهند و نیز انحناها، آستانه‌ها و دیگر انحراف‌های حاصل از توابع خطی را در نظر می‌گیرند [۲۶]. روش مارس، توابع پایه را با جستجو به روش مرحله‌ای ایجاد می‌کند. الگوریتم رگرسیون انطباقی، برای انتخاب موقعیت‌های گره به کار می‌رود. مدل‌های مارس، به روش دو مرحله‌ای ایجاد می‌شوند. مرحله اول، توابع را جمع می‌بندند و گره‌های احتمالی را برای بهبود عملکرد می‌یابد، که به مدلی با برازش کامل می‌انجامد (مرحله مقدم). مرحله دوم، دربرگیرنده حذف کمترین جمله‌های حقیقی است (مرحله موخر). کدهای مورد استفاده در این روش از کد جکابسنز [۲۶] برای انجام تحلیل‌های ارائه شده در این پژوهش استفاده شد.

فرض کنیم y خروجی تعیین شده و $X = (X_1, \dots, X_p)$ ماتریس متغیرهای ورودی P باشد. پس فرض می‌شود که داده‌ها از مدل «حقیقی» مجهول به وجود می‌آیند. در مورد پاسخ پیوسته داریم:

$$y = f(X_1, \dots, X_p) + e = f(x) + e \quad (1)$$

که در آن e توزیع خطا است. مارس تابع f را با کاربرد توابع پایه (BFs) تقریب می‌زند. توابع پایه، کثیرالجزءه‌های چند قطعه‌ای (چندجمله‌ای‌های نرم)، شامل توابع خطی چندقطعه‌ای و توابع مکعبی چندقطعه‌ای هستند. با توجه به اینکه در این تحقیق، از توابع خطی چندقطعه‌ای استفاده شده‌است، در ادامه به توضیح این توابع پرداخته خواهد شد.

توابع خطی چند قطعه‌ای از نوع $\max(0, x - t)$ با یک گره واقع در مقدار t هستند. معادله $\max(\cdot)$ به معنای آن است که تنها بخش مثبت (\cdot) مورد استفاده قرار می‌گیرد، در غیر این صورت، مقدار آن صفر می‌شود.

$$\max(0, x - t) \begin{cases} x - t & \text{if } x \geq t \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

$m\lambda$ مدل مارس، به عنوان ترکیب خطی BF ها و روابط متقابل آن‌ها ایجاد، و به صورت زیر بیان می‌شود:

$$f(x) = \beta_0 + \sum_{m=1}^M \beta_m \lambda_m(x) \quad (3)$$

، پارامتر هموارسازی نامیده می‌شود. هر $\lambda(x)$ تابعی پایه است و می‌تواند تابع کثیرالجزءه‌ای چندقطعه‌ای، یا حاصل ضرب دو تابع کثیرالجزءه‌ای چندقطعه‌ای یا بیشتر که پیش از این در مدل جا داشت، باشد (مرتبه‌های بالاتر می‌تواند مورد β استفاده قرار گیرد، هنگامی که داده‌ها آن را ایجاب کنند؛ برای سادگی، در این تحقیق حداکثر در مرتبه دوم فرض می‌شود). ضرایب ثابت هستند، و با استفاده از روش کوچکترین مربعات برآورد می‌شوند.

۲-۲- ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یک نوع الگوریتم داده‌کاوی است که تاکنون در زمینه‌های گوناگونی نظیر تشخیص چهره، بیو انفورماتیک، طبقه‌بندی متون و... مورد استفاده قرار گرفته‌است. مهم‌ترین کاربرد ماشین‌های بردار پشتیبان در طبقه‌بندی و خطی‌سازی داده‌ها است. این الگوریتم، برای اولین بار در مطالعه‌ی Cortes and Vapnik (۱۹۹۵) مطرح شد و سپس به‌طور قابل توجهی مورد توجه سایر محققین قرار گرفت [۲۷].

روش ماشین بردار پشتیبان از پرکاربردترین روش‌های یادگیری ماشینی است. اساس این روش تئوری یادگیری آماری وپنیک در دهه‌ی ۹۵ میلادی می‌باشد که توسط Cortes and Vapnik (۱۹۹۵) ارائه گردید [۲۷]. برای کمینه‌نمودن خطای پیش‌بینی در SVM از اصول کاهش ریسک ساختاری استفاده می‌شود. این در حالی است که روش‌هایی مانند انواع شبکه‌های عصبی مصنوعی از اصول کمینه سازی ریسک تجربی استفاده می‌کنند.

مشابه سایر روش‌های هوش مصنوعی، فرآیند ایجاد مدل ماشین بردار پشتیبان نیز شامل دو مرحله آموزش و آزمایش می‌باشد که پس از خاتمه‌ی فاز آموزش قابلیت تعمیم‌یابی مدل آموزش داده شده بر اساس داده‌های آزمایش مورد ارزیابی قرار می‌گیرد. مبنای این روش بر انتقال متغیرهای مستقل به یک فضای فرضی چندبعدی با استفاده از توابع کرنل (kernel function) است. توابع خطی (Linear)، چند جمله‌ای (Polynomial)، گوس (Gaussian)، و تانژانت هایپربولیک (Tangent hyperbolic) از جمله بهترین کرنل‌های مورد استفاده در ساختار SVM است. در فضای چند بعدی می‌توان از یک رابطه خطی برای مرتبط کردن متغیر وابسته به متغیرهای مستقل استفاده کرد.

۳-۲- مدل درخت (MP5-MT)

درخت تصمیم یکی از ابزارهای قوی و متداول برای دستهبندی است که دارای یک ساختار شبیه به درخت است. درخت‌های تصمیم روشی برای نمایش یک سری از قوانین هستند که منتهی به یک رده یا مقدار می‌شوند. درخت‌های تصمیم به کمک جداسازی متوالی داده‌ها به یک سری گروه مجزا تشکیل شده و سعی می‌شود در فرآیند جداسازی، فاصله بین گروه‌ها افزایش یابد. ساختار یک مدل درختی شامل ریشه، گره‌های داخلی و برگ می‌باشد. از مدل‌های درخت تصمیم در حل بسیاری از مسائل طبقه‌بندی و رگرسیونی استفاده شده است [۲۸].

الگوریتم M5 رایجترین طبقه‌بندی استفاده شده در خانواده مدل تصمیم‌گیری درختی است که توسط دکا^۸ برای پیش‌بینی داده‌های پیوسته ارائه شد. مدل درختی M5 یک الگوریتم پیش‌بینی عددی است و گره‌های درخت با خواص بیشینه خطاهای مورد انتظاری که به عنوان تابعی از انحراف استاندارد پارامترهای خروجی می‌باشد، انتخاب می‌شوند. مدل M5 یک مدل درختی برای پیش‌بینی صفات عددی پیوسته است که در آن، توابع رگرسیونی خطی در برگ‌های این درخت ظاهر می‌گردند [۲۹]. این روش، یک مدل خطی چندمتغیره را برای داده‌ها در هر گره از مدل درختی می‌سازد. تشکیل ساختار مدل‌های درخت تصمیم‌گیری شامل مراحل ایجاد درخت و هرس کردن آن است که در مرحله تشکیل درخت، از یک الگوریتم استنتاجی یا معیار تقسیم (انشعاب) برای تولید یک درخت تصمیم استفاده می‌شود. معیار تقسیم برای الگوریتم مدل M5، انحراف معیار مقادیر هر کلاسی است که به عنوان کمیتی از خطا به یک گره می‌رسد و کاهش مورد انتظار در این خطا را به عنوان نتیجه آزمون هر صفت در آن گره محاسبه می‌نماید.

کاهش معیار (SDR) از معادلات (۴) و (۵) به دست می‌آید [۳۰].

$$SDR = sd(T) - \sum_i \frac{T_i}{|T|} \times sd(T_i) \quad (4)$$

$$sd(E) = \sqrt{\frac{1}{N} \left(\sum_{i=1}^N y_i^2 - \frac{1}{N} \left(\sum_{i=1}^N y_i \right)^2 \right)} \quad (5)$$

که در آن E بیانگر مجموعه‌ای از نمونه‌هاست که به گره می‌رسند، Sd بیانگر انحراف معیار، y_i مقدار عددی ویژگی هدف نمونه i ، N شماره داده‌ها و E_i بیانگر زیرمجموعه‌ای از نمونه‌هاست که i امین نتیجه تست پتانسیلی را دارند، می‌باشد. به دلیل فرآیند انشعاب، داده‌های قرار گرفته در گره‌های فرزند، انحراف معیار کمتری نسبت به گره مادر داشته و بنابراین خالص‌تر هستند. پس از حداکثرسازی

⁸ Deka

تمامی انشعابهای ممکن، M5 صفتی را انتخاب می‌کند که کاهش مورد انتظار را بیشینه نماید. این تقسیم بیشتر ساختار شبه درختی بزرگی را تشکیل می‌دهد که باعث بیشبرازش می‌گردد. برای غلبه بر مساله بیشبرازش، درخت تشکیل شده باید هرس شود. این کار با جایگزینی یک درخت فرعی با یک برگ انجام می‌شود. بنابراین، مرحله دوم در طراحی مدل درختی شامل هرس نمودن درخت رشد یافته و جایگزینی درختان فرعی با توابع رگرسیونی خطی است.

این تکنیک تولید مدل درختی، فضای پارامترهای ورودی را به نواحی یا زیر فضاهای کوچکتر تقسیم نموده و در هر کدام از آنها، یک مدل رگرسیونی خطی برازش می‌دهد. بعد از اینکه مدل خطی به دست آمد، برای کمینه کردن خطای تخمین با حذف کردن پارامترها، ساده‌سازی مدل انجام می‌شود. در مدل M5 از یک جستجوی حریصانه برای حذف متغیرهایی که مشارکت کمی در مدل دارند، استفاده می‌شود. البته گاهی اوقات همه متغیرها حذف شده و فقط یک مقدار ثابت باقی میماند. به عنوان مثال اگر $X_1 > 2.5$ و $X_2 > 2$ باشند، آنگاه مدل سوم به فرم $Y = a_0 + a_1 X_1 + a_2 X_2$ مورد استفاده قرار می‌گیرد.

۴-۲- الگوریتم جستجوی گرانش (GSA)

در الگوریتم جستجوی گرانشی، با شبیه‌سازی قوانینی شبیه به قانون گرانش و قوانین حرکت نیوتن در محیطی با زمان گسسته در فضای جستجو، بهینه‌یابی انجام می‌شود. طبق قانون گرانش، هر جرم، محل و وضعیت سایر اجرام را از طریق قانون جاذبه گرانشی درک میکند. بنابراین میتوان از این نیرو به عنوان ابزاری برای تبادل اطلاعات استفاده کرد. از بهینه‌یاب طراحی شده برای حل هر مسئله بهینه‌سازی که در آن هر جواب مسئله به صورت یک موقعیت در فضا قابل تعریف و میزان شباهت آن با سایر جواب‌های مسئله به صورت یک فاصله قابل بیان باشد، می‌توان استفاده کرد. میزان اجرام با توجه به تابع هدف تعیین می‌شوند. در قدم اول فضای سیستم مشخص می‌شود. محیط شامل یک دستگاه مختصات چند بعدی در فضای تعریف مسئله است که هر نقطه از فضا یک جواب مسئله است. عامل‌های جستجو کننده مجموعه‌ای از اجرام می‌باشند. هر جرم چهار مشخصه دارد: الف: موقعیت جرم، ب: جرم گرانشی فعال، ج: جرم گرانشی غیرفعال و د: جرم اینرسی. موقعیت جرم، نقطه‌ای در فضا است که جوابی از مسئله است. مقدار اجرام گرانشی و اینرسی، با توجه به برازندگی هر جرم تعیین می‌شوند. پس از تشکیل سیستم، قوانین حاکم بر آن مشخص می‌شوند. فرض می‌شود تنها قانون گرانش و قوانین حرکت حاکم می‌باشند.

۴-۲-۵- معیارهای ارزیابی خطا برای مقایسه عملکرد مدل‌های هوشمند

برای مقایسه عملکرد مدل‌های ارائه شده در مراحل آموزش و تست، شاخصه‌ای آماری ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE)، میانگین خطای مطلق (MAE)، ضریب نش (NSE) و LMI استفاده می‌شود.

$$R = \frac{\sum_{i=1}^N (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2 \sum_{i=1}^N (P_i - \bar{P})^2}} \quad (6)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (7)$$

$$MAE = \frac{\sum_{i=1}^N |P_i - O_i|}{N} \quad (8)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (Pi - Oi)^2}{\sum_{i=1}^N (Oi - \bar{O})^2} \quad (9)$$

$$LMI = 1 - \left[\frac{\sqrt{\sum_{i=1}^N |Pi - \bar{Pi}|}}{\sqrt{\sum_{i=1}^N |Oi - \bar{O}|}} \right] \quad (10)$$

که O_i مقدارهای مشاهده‌های، P_i مقدارهای پیش‌بینی، \bar{O} میانگین داده‌های مشاهده‌ای، \bar{P} میانگین داده‌های پیش‌بینی و N تعداد داده‌ها می‌باشد.

۳- نتایج و بحث

در این قسمت، ابتدا داده‌های جمع‌آوری شده آزمایشگاهی شامل پارامترهای ورودی و خروجی مدل، نحوه پراکندگی و محدوده هر یک از طرح اختلاط و نتایج خواص تازه و سخت شده بتن خودتراکم تفسیر می‌شود. سپس، نحوه توسعه هر یک از مدل‌های مستقل SVM، Mp5-MT، MARS و مدل تلفیقی MARS-GSA برای پیش‌بینی خواص تازه و سخت شده بتن خودتراکم حاوی پوزولان‌های معدنی پرداخته می‌شود. در نهایت عملکرد مدل‌ها بوسیله شاخص‌های آماری مختلف و آزمون‌های اعتبارسنجی مورد ارزیابی قرار می‌گیرد.

۳-۱- جمع‌آوری و تحلیل داده‌های آزمایشگاهی

محققان مختلفی خواص تازه و سخت‌شده بتن خودتراکم حاوی پوزولان‌های معدنی را اندازه‌گیری و در منابع علمی گزارش کرده‌اند. تحقیق حاضر این‌گونه داده‌ها را جمع‌آوری کرده و برای مدل‌سازی و پیش‌بینی متغیرهای مد نظر با استفاده از روش‌های هوش مصنوعی بکار می‌برد. ۲۰۶ سری داده آزمایشگاهی جهت مدل‌سازی از مقالات معتبر [۳۱-۵۲] جمع‌آوری شده که از کل داده‌ها به ترتیب ۷۵٪ و ۲۵٪ برای اجرای مراحل آموزش و تست در نظر گرفته می‌شود.

جدول (۱) مراجع مورد استفاده، سال انتشار و تعداد داده مورد استفاده از هر کدام را گزارش می‌کند. ذکر این نکته حائز اهمیت است تمامی داده‌های واقعی که از مراجع معتبر علمی جمع‌آوری شده‌اند برای اعتبارسنجی مدل‌ها مورد استفاده قرار می‌گیرند (Dhiyaneshwaran et al. [42]; Bingöl & Tohumcu, [43]; Ranjbar et al. [44]; Krishnapal et al. [45]; Nepomuceno et al. [46]; Vivek & Dhinakaran, [47]; Tang et al. [48]; Gholhaki et al. [49]; De Belie et al. [50]; Hani et al. [51]; Nuruzzaman et al. [52])

جدول ۱. منابع داده‌های مورد استفاده برای توسعه مدل‌های پیشنهادی

ردیف	نویسنده	سال انتشار	تعداد داده	ردیف	نویسنده	سال انتشار	تعداد داده
۱	Gettu et al	۲۰۰۲	۲	۱۲	Dhiyaneshwaran et al.	۲۰۱۳	۶
۲	Patel	۲۰۰۳	۱۷	۱۳	Bingöl & Tohumcu	۲۰۱۳	۴
۳	Felekouglu et al.	۲۰۰۷	۵	۱۴	Ranjbar et al.	۲۰۱۷	۱۰
۴	Sahmaran et al.	۲۰۰۹	۹	۱۵	Krishnapal et al.	۲۰۱۳	۸
۵	Güneyisi & Gesoğlu	۲۰۰۹	۸	۱۶	Nepomuceno et al.	۲۰۱۴	۱۹
۶	Mahalingam & Nagamani	۲۰۱۱	۹	۱۷	Vivek & Dhinakaran	۲۰۱۷	۱۴
۷	Siddique et al.	۲۰۱۱	۵	۱۸	Tang et al.	۲۰۱۸	۴
۸	Uysal et al.	۲۰۱۱	۴	۱۹	Gholhaki et al.	۲۰۱۸	۱۰
۹	Siddique et al.	۲۰۱۲	۲۰	۲۰	De Belie et al.	۲۰۱۸	۱۳
۱۰	Muthupriya et al.	۲۰۱۲	۳	۲۱	Hani et al.	۲۰۱۸	۱۲
۱۱	Madandoust & Mousavi	۲۰۱۲	۱۴	۲۲	Nuruzzaman et al.	۲۰۲۰	۱۰

۲-۳- نحوه انتخاب پارامترهای بهینه برای توسعه مدل‌های هوشمند مصنوعی

انتخاب متغیرهای ورودی مناسب برای مدل‌های هوشمند مصنوعی و روش‌های داده‌کاوی تاثیر زیادی در عملکرد آن‌ها دارد. از این رو، بر اساس مشاهدات تجربی و مطالعات سایر محققان از جمله متغیرهای ورودی موثر در پیش‌بینی خواص تازه و سخت شده بتن خودتراکم می‌توان به پارامترهای اثرگذار در طرح اختلاط نظیر سنگدانه، سیمان، آب و... اشاره کرد. جدای از این متغیرها، پارامترهای بدون بعد مانند نسبت آب به سیمان و یا نسبت درشتدانه به ریزدانه نیز می‌توانند بسته به طرح اختلاط و نوع بتن مورد مطالعه، اثرگذاری قابل توجهی داشته‌باشد.

هر چند روش‌های مختلفی برای انتخاب ویژگی وجود دارد، در تحقیق حاضر از روش ضریب مالو برای انتخاب ویژگی و کاهش ابعاد پارامترهای ورودی اثرگذار بر خروجی مسئله یعنی خواص تازه و سخت شده استفاده خواهد شد. این روش عملکرد موفقی در انتخاب تعداد کمتر از متغیرهای پیش‌بینی‌کننده برای کالیبره کردن مدل برتر، داشته‌است. مقدار ضریب مالو کم نشان‌دهنده یک انتخاب خوب از زیرمجموعه‌های پیش‌بینی‌کننده و همچنین یک مدل پیش‌بینی‌کننده قوی است.

برای انتخاب حالت ورودی بهینه برای توسعه مدل‌های هوش مصنوعی ۷ سناریو با چینش متفاوت حالات ورودی در نظر گرفته شد. در ادامه با استفاده از مقایسه آماره CP مالو و ضریب تبیین (R^2) در نرم‌افزار مینی تب ۲۰۱۷، نتایج بررسی و حالت ورودی بهینه برای آموزش مدل برگزیده شد (جدول). ذکر این نکته مهم است که یک مدل مبهم مدلی است که پیش‌بینی‌های مهمی را از داده و ضرایب رگرسیون متمایل به خطا و پیش‌بینی‌های آن را پاسخ می‌دهد. در یک کلام، آماره Cp Mallow اندازه این تمایل را برآورد می‌کند و پاسخ‌های پیش‌بینی شده را برای داشتن یک مدل مبهم نشان می‌دهد.

جدول ۲. سناریوهای پیش‌بینی‌شده برای انتخاب بهترین حالت ورودی برای توسعه مدل‌ها

شماره سناریو	تعداد ورودی	شرح سناریوها
سناریو اول	۴ ورودی	درشت دانه، ریزدانه، آب، چسباننده
سناریو دوم	۵ ورودی	درشت دانه، ریزدانه، آب، چسباننده، فوق روان کننده
سناریو سوم	۵ ورودی	سیمان، درشت دانه، ریزدانه، آب، فوق روان کننده
سناریو چهارم	۶ ورودی	پوزولان، نسبت آب به چسباننده، ریزدانه، درشتدانه، فوق روان کننده، چسباننده
سناریو پنجم	۷ ورودی	سیمان، آب، نسبت آب به چسباننده، ریزدانه، درشتدانه، فوق روان کننده، چسباننده
سناریو ششم	۴ ورودی	نسبت آب به سیمان، نسبت آب به چسباننده، نسبت درشتدانه به ریزدانه، فوق روان کننده
سناریو هفتم	۶ ورودی	سیمان، نسبت درشت دانه به ریزدانه، نسبت آب به سیمان، نسبت آب به چسباننده، فوق روان کننده، چسباننده

در (جدول) مقادیر آماره Cp Mallow و ضریب تبیین سناریوهای مختلف گزارش شده است. این مقادیر که به کمک نرم‌افزار مینی‌تب محاسبه شده‌اند برای انتخاب بهترین حالت ورودی قابل استناد هستند.

جدول ۳. نتایج بررسی سناریوها برای انتخاب بهترین حالت ورودی در نرم افزار مینی تب

شماره سناریو	۱	۲	۳	۴	۵	۶	۷
C _p mallow	۵۲/۱۸	۲۴/۱۲	۱۱/۸۲	۸/۶۳	۱۰/۲۲	۱۹/۴	۱۵/۴۲
R ²	۶۳/۱۰	۶۴/۱۲	۵۹/۵۰	۸۰/۸۵	۶۷/۴۹	۵۸/۶۶	۶۱/۳۱

این جدول نشان می‌دهد که سناریو شماره ۴ بهترین نتایج را براساس تحلیل آماری ارائه نموده است. با توجه به این بررسی خواص مکانیکی تازه و سخت شده بتن خودتراکم بر اساس رابطه (۱۱) به عنوان تابعی از متغیرهای پیش‌بین در سناریو ۴ مدل‌سازی می‌شود.

$$\text{Target} = f(B, \text{SCM}, W/B, CA, FA, SP) \quad (11)$$

۳-۳- تحلیل و بررسی داده‌های آزمایشگاهی جمع‌آوری شده

هدف اصلی در این پژوهش توسعه و تحلیل چهار مدل هوشمند مصنوعی مستقل و ترکیبی شامل، SVM، Mp5-MT، MARS و MARS-GSA در پیش‌بینی خواص مکانیکی تازه و سخت شده بتن خودتراکم حاوی پوزولان‌های معدنی می‌باشد. در اکثر مطالعات صورت گرفته، داده‌های آزمایشگاهی محدود به جغرافیای آن منطقه بوده اما مجموعه داده‌های جمع‌آوری شده در این مطالعه از کشورهای مختلف و جغرافیای وسیع‌تر می‌باشد. از این رو، به منظور ارزیابی داده‌های آزمایشگاهی مورد استفاده در پیش‌بینی خواص مکانیکی تازه و سخت شده بتن خودتراکم حاوی پوزولان‌های معدنی، محدوده، میانگین و انحراف معیار داده جمع‌آوری شده در (جدول) ارائه شده است.

جدول ۴. ارزیابی آماری پارامترهای مورد استفاده در پیش‌بینی خواص تازه و سخت شده بتن خودتراکم

ورودی	واحد	انحراف معیار	میانگین	ماکزیمم	مینیمم
پوزولان (SCM)	Kg	40.54	34.33	272	0
چسباننده (B)	Kg	88.68	505.01	748	350
نسبت آب به چسباننده (W/B)	Kg	0.061	0.382	0.5	0.22
ریزدانه (FA)	Kg	97.06	864.94	1085	645
درشتدانه (CA)	Kg	137.19	768.07	1159	562
فوق روان کننده (SP)	mm	4.66	6.921	21.84	0.74
خروجی					
جریان اسلامپ (D)	mm	65.74	664.6	885	361
قیف (V-funnel) v	Sec	11.88	2.685	95.8	0.35
جعبه (L-box) L	-	5.662	9.586	47.9	2
مقاومت فشاری ۲۸ روزه (CS)	MPa	15.15	45.63	86.8	17

۳-۴- نتایج مدل‌سازی جهت پیش‌بینی خواص تازه و سخت شده بتن خودتراکم

در این بخش نحوه آموزش و توسعه مدل‌های SVM، Mp5-MT، MARS و MARS-GSA پرداخته شده و عملکرد آن‌ها با شاخصه‌ای آماری مختلف مورد ارزیابی قرار می‌گیرد.

۳-۴-۱- توسعه مدل ماشین بردار پشتیبان (SVM)

با توجه به اینکه مطالعات مربوط به استفاده از SVM نشان داده که کرنل گوسی در مقایسه با سایر کرنل‌ها برای مدل‌سازی پدیده‌های پیچیده عملکرد بهتری دارد (Keshtegar et al. 2020). از این رو در این تحقیق نیز از کرنل گوسی $k(x, x') = \exp\left(-\frac{1}{2\sigma^2} \|x - x'\|^2\right)$ بهره برده می‌شود. که X و X' به ترتیب داده‌ها و میانگین داده‌ها می‌باشند. همچنین σ پارامتر کرنل یا به عبارتی σ^2 واریانس داده می‌باشد. علاوه بر پارامترهای کرنل، ثابت C و \mathcal{E} نیز بایستی به درستی تنظیم شوند تا مدل بتواند در مرحله‌ی آزمایش به خروجی مطلوب برسد. مشابه تحقیقات گذشته، مطالعه حاضر نیز این پارامترها بر اساس سعی و خطا تعیین می‌کند.

نتایج بدست آمده از سعی و خطا در (جدول) و (جدول) ارائه شده‌است. در این پژوهش با توجه به مطالعه تحقیقات پیشین، مقدار اثرگذاری پارامتر \mathcal{E} کم بوده و مقدار آن برای تمامی متغیرهای هدف برابر $0/0001$ در نظر گرفته شده‌است. برای انتخاب C و σ بهینه ابتدا σ ثابت و برابر $0/1$ و پارامتر C با 7 مقدار در بازه 10 الی 700 مقداردهی شد تا بهترین مقدار آن پس از آزمون سعی و خطا بدست آید. سپس این کار را بالعکس برای انجام می‌دهیم.

جدول ۵. تعیین پارامتر C مدل SVM با آزمون و خطا برای مدل‌سازی خواص تازه و سخت شده بتن خودتراکم

پارامتر C								شاخص خطا	متغیر هدف
۷۰۰	۶۰۰	۵۰۰	۴۰۰	۳۰۰	۲۰۰	۱۰۰	۱۰		
۰/۴۲	۰/۴۸	۰/۵۱	۰/۵۲	۰/۴۲	۰/۳۴	۰/۲۵	۰/۱۱	R	جریان اسلامپ
۱۷۶/۵۴	۱۹۳/۰۲	۱۴۶/۴۲	۱۲۱/۳۴	۱۸۲/۹۲	۲۳۶/۲۱	۴۲۱/۲۴	۶۱۸/۷۵	RMSE	
۲۱۵/۴۲	۱۵۷/۱۱	۱۰۵/۲۲	۷۹/۲۸	۲۱۸/۷۸	۲۳۵/۶۵	۳۴۶/۱۸	۴۸۶/۴۲۱	MAE	
۰/۱۸	۰/۲۸	۰/۲۴	۰/۲۷	۰/۳۴	۰/۴۵	۰/۲۸	۰/۲۳	R	جعبه L
۳/۴۱۷	۱/۵۸۴	۲/۶۲۵	۱/۷۵۸	۱/۰۵۸	۰/۵۶۲	۱/۸۶۲	۲/۳۱۵	RMSE	
۲/۵۱۵	۱/۰۵۷	۲/۳۱۲	۱/۳۱۹	۰/۵۶۸	۰/۳۹۱	۱/۳۱۴	۲/۱۱۷	MAE	
۰/۱۴	۰/۲۲	۰/۲۲	۰/۲۷	۰/۲۵	۰/۲۸	۰/۱۵	۰/۰۵	R	قیف V
۱۲/۳۱۵	۹/۶۲۷	۱۰/۶۲۱	۷/۳۱۲	۹/۶۲۱	۶/۶۲۴	۱۱/۶۲۴	۱۹/۲۷۸	RMSE	
۱۱/۱۰۵	۸/۶۵۶	۸/۷۹۲	۶/۳۱۳	۷/۶۵۱	۵/۲۴۴	۱۰/۶۲۸	۱۷/۲۱۷	MAE	
۰/۳۲	۰/۴۴	۰/۵۳	۰/۴۸	۰/۳۸	۰/۴۶	۰/۳۸	۰/۳۴	R	مقاومت فشاری
۱۳/۶۲۴	۱۱/۵۲۱	۹/۸۲۱	۹/۹۲۵	۱۱/۵۸۷	۱۰/۱۶۲	۱۰/۹۲۸	۱۲/۰۵۸	RMSE	
۱۲/۹۶۸	۹/۲۵۸	۸/۱۱۴	۹/۰۲۵	۱۰/۱۲۵	۹/۶۲۸	۱۰/۶۲۱	۱۱/۶۲۱	MAE	

جدول ۶. تعیین پارامتر σ مدل SVM با آزمون و خطا برای مدل‌سازی خواص تازه و سخت شده بتن خودتراکم

پارامتر σ							شاخص خطا	متغیر هدف
7/0	6/0	5/0	4/0	3/0	2/0	1/0		
63/0	65/0	71/0	67/0	59/0	15/0	11/0	R	جریان اسلامپ
27/92	62/86	29/49	56/61	42/108	62/158	19/218	RMSE	
32/89	11/48	65/42	44/53	37/89	64/116	92/156	MAE	
39/0	42/0	58/0	61/0	62/0	59/0	56/0	R	جعبه L
628/0	268/0	121/0	092/0	077/0	114/0	189/0	RMSE	
462/0	158/0	92/0	076/0	064/0	105/0	125/0	MAE	
29/0	26/0	32/0	39/0	39/0	35/0	24/0	R	قیف V
824/6	625/6	632/5	925/3	521/3	248/4	258/6	RMSE	
338/5	625/5	225/4	259/2	924/2	117/4	358/5	MAE	
76/0	88/0	73/0	58/0	51/0	62/0	42/0	R	مقاومت فشاری
634/8	611/7	592/9	625/12	55/13	358/11	462/15	RMSE	
22/7	219/6	928/8	175/11	257/11	528/10	624/12	MAE	

مقادیر بهینه پارامترهای مدل SVM با کرنل 'گوسی' برای پیش‌بینی متغیرهای هدف مختلف در (جدول) ارائه شده‌است.

جدول ۷. مقادیر بهینه پارامترهای کرنل گوسی، ثوابت c و مربوط به مدل SVM

متغیر هدف	σ	ϵ	c
جریان اسلامپ	5/0	0001/0	400
جعبه L	3/0	0001/0	200
قیف V	3/0	0001/0	200
مقاومت فشاری	6/0	0001/0	500

۳-۴-۲- توسعه مدل درخت پشتیبان (Mp5-MT)

معیارهای مختلفی می‌توانند در فاز پیش‌بینی بر فرآیند مدل‌سازی خواص تازه و سخت شده بتن خودتراکم با استفاده از مدل درخت تصمیم Mp5-MT تاثیرگذار باشند، یکی از عوامل مهم و اثرگذاری که در این بخش باید مورد بررسی قرار گیرد، تعیین پارامترهای درون شبکه این روش هوشمند پایه درختی می‌باشد. ابتدا باید داده‌های آزمایشگاهی جمع‌آوری شده به دو گروه آموزش و تست در درصدهای هر یک به ترتیب ۷۵ و ۲۵ درصد می‌باشد، تقسیم شده و پارامترهای درون شبکه را مانند روش SVM با آزمون سعی و خطا تعیین نمود. برای پیاده‌سازی این درخت تصمیم می‌توان از نرم‌افزارهای مانند WEKA، MATLAB، و Rapidminer استفاده نمود. پارامترهای درون شبکه روش Mp5-MT شامل اندازه دسته، کمترین تعداد نمونه‌ها در هر برگ، تعداد موقعیت‌ها و وضعیت هرس کردن میباشند که با ایجاد تغییرات در این پارامترها، ممکن است مقادیر پیش‌بینی و دقت مدل‌سازی‌ها افزایش و یا کاهش یابند. در این پژوهش، (جدول) نشان‌دهنده مقادیر هر یک از پارامترها می‌باشد که برای هر ۴ متغیر هدف یعنی خواص تازه و سخت‌شده بتن خودتراکم یکسان در نظر گرفته شده‌است.

جدول ۸. قادر اختصاص داده شده به پارامترهای درون شبکه مدل درخت تصمیم

پارامترهای مدل	اندازه دسته	کمترین تعداد نمونه‌ها در هر برگ	تعداد موقعیت‌ها	وضعیت هرس کردن
مقادیر	۱۰۰	۲	۴	بله

۳-۴-۳- رگرسیون اسپلاین چند متغیره تطبیقی (MARS)

(جدول) جزییات تحلیلی روش مارس شامل نوع تابع پایه مورد استفاده، تعداد آن‌ها و بیشترین مقدار عکس‌العمل هر تابع را با استفاده از تکنیک سعی و خطا بررسی کرده‌است. برازش در هر تابع پایه بصورت جداگانه صورت پذیرفته و مدل مربوط به این برازش برای هر یک از خواص تازه و سخت شده بتن خودتراکم ارائه شده‌است. مارس به لحاظ محاسباتی، در پیدا کردن مدل بهینه کارآمدتر است، چرا که در اصل با برازش رگرسیون‌های خطی، مدل‌های قابل انعطاف می‌سازد و مدل را با تقسیم به شیب‌های جداگانه در فاصله‌های مشخص متغیرهای ورودی تقریب می‌زند. متغیرها و محل‌های گره برای هر متغیر، از طریق روش جست‌وجوی سریع اما متمرکز تعیین می‌شوند. همچنین انتخاب مقدم و روش حذفی موخر، به عنوان تضمین‌کننده مدل بهینه تشخیص داده می‌شود. صرف‌نظر از توانایی کمک به برآورد متغیرهای ورودی، مزیت دیگر مارس سرعت همگرایی آن است که در زمان پردازش آن مشهود است.

جدول ۹. جزئیات روش مارس برای پیش‌بینی خواص تازه و سخت‌شده بتن خودتراکم

خروجی مدل	D	L-Box	V-funnel	CS
نوع توابع پایه	چند تکه‌ای خطی	چند تکه‌ای خطی	چند تکه‌ای خطی	چند تکه‌ای خطی
تعداد توابع پایه	۱۵	۲۴	۱۸	۲۰
بیشترین مقدار عکس‌العمل	۳	۳	۳	۳
پارامتر جریمه	۱	۱	۱	۱
GCV	۱۸۲۰/۱	۰/۰۰۳	۶/۹۷	۲۳/۷۴

۴-۴-۳- توسعه مدل MARS بهبود یافته با الگوریتم GSA

در این مطالعه از الگوریتم فراابتکاری GSA برای تعیین مقادیر بهینه پارامترهای درون مدل مارس و بهبود عملکرد آن استفاده شده‌است. در این تحقیق، سه متغیر تصمیم‌گیر مدل مارس شامل تعداد توابع پایه، بیشترین مقدار عکس‌العمل و پارامتر جریمه که با استفاده از روش کمترین مربعات خطا در مارس برآورد می‌شود، با پیاده‌سازی الگوریتم‌های پیشنهادی و کمینه‌کردن خطاها بدست آمده است.

در این مطالعه تعداد تکرار (max iteration) ۱۰-۱۰۰۰ و تعداد جواب تولید شده (n population) ۱۰-۱۰۰ مورد بررسی قرار گرفته‌است. در (جدول) مقادیر پارامترهای بهینه الگوریتم پیشنهادی GSA برای بهبود عملکرد مدل مارس ارائه شده‌است. (جدول) روند و گام‌های یافتن مقادیر بهینه پارامترهای درون شبکه مدل مارس را با استفاده از الگوریتم GSA برای مدل‌سازی و پیش‌بینی هر یک از خواص تازه و سخت‌شده بتن خودتراکم را در این مطالعه نمایش داده‌است.

جدول ۱۰. شبه کد الگوریتم جستجوی گرانشی

۱. مقداردهی اولیه به متغیرها
۲. مقداردهی اولیه به عامل‌ها بصورت تصادفی
۳. تا زمانی که شرایط نهایی برآورده نشده است مراحل زیر انجام شود
۴. ارزیابی شایستگی عامل‌ها
۵. محاسبه M برای هر عامل
۶. به روزرسانی عامل‌های K, G, K_{best}
۷. محاسبه شتاب وارده به هر عامل
۸. محاسبه سرعت هر عامل
۹. به روزرسانی موقعیت هر عامل
۱۰. برگرداندن بهترین راه حل پیدا شده

جدول ۱۱. مقادیر پارامترهای بهینه الگوریتم جستجوی گرانش

پارامتر	مقدار
متغییر تصمیم گیری	3
تعداد جواب تولید شده	30
جرم اینرسی	20
ثابت گرانش	100
تعداد تکرار	1000

(جدول) جزییات تحلیلی مدل MARS-GSA را بررسی و روابط مربوط به هر برازش را به صورت جداگانه ارائه نموده‌است.

جدول ۱۲. جزییات روش مارس توسعه یافته برای پیش‌بینی خواص تازه و سخت‌شده بتن خودتراکم

خروجی مدل	D	L-Box	V-funnel	CS
نوع توابع پایه	چند تکه‌ای خطی	چند تکه‌ای خطی	چند تکه‌ای خطی	چند تکه‌ای خطی
تعداد توابع پایه	21	22	15	22
بیشترین مقدار عکس العمل	4	2	3	3
پارامتر جریمه	2	4	1	2
GCV	1/1820	003/0	97/6	74/23

۵-۳- مقایسه مدل‌های پیش‌بین برای تخمین خواص تازه و سخت شده بتن خودتراکم

در این بخش عملکرد مدل‌های هوش مصنوعی پیشنهادی (ماشینهای بردار پشتیبان، مدل درخت تصمیم، مارس و همچنین مدل مارس بر پایه الگوریتم جستجوی گرانش) در پیش‌بینی خواص تازه و سخت‌شده بتن خودتراکم (جریان اسلامپ، جعبه L، کیف V و مقاومت فشاری) با استفاده شاخصه‌های آماری خطا، نمودارهای پراکندگی و دیگر نمودارهای بصری مقایسه می‌شود



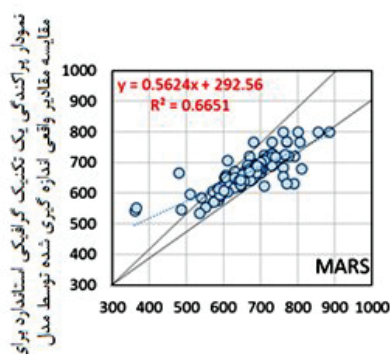

۵-۳-۱- نتایج مدل‌های پیش‌بین برای جریان اسلامپ (D)

نتایج بدست آمده از مدل‌سازی و پیش‌بینی جریان اسلامپ بتن خودتراکم با استفاده از روش‌های هوش مصنوعی مختلف در (جدول) آورده شده‌است. در این جدول، مقادیر هر یک از شاخصه‌های آماری خطا در مراحل آموزش و تست آورده شده‌است. مطابق جدول زیر، ضریب همبستگی (R) در مرحله آموزش برای مدل ماشینهای بردار پشتیبان، مدل درخت و رگرسیون اسپلاین چند متغیره تطبیقی به ترتیب ۰/۶۸، ۰/۹۷ و ۰/۸۲ می‌باشد. همچنین مقدار شاخص آماری RMSE برای مدل پیشنهادی، SVM، Mp5-MT و MARS در این مرحله به ترتیب ۰/۷۰/۵۴، ۲۰/۵۱ و ۴۲/۱۳ حاصل گردیده‌است. زمانی که پارامترهای مدل مارس با استفاده از الگوریتم بهینه‌سازی جستجوی گرانش ترکیب شد دقت مدل ترکیبی نسبت به مدل مارس مستقل در ترم R و NSE به میزان ۷/۳ و ۸/۱ درصد افزایش یافت.


جدول ۱۳. ارزیابی عملکرد مدل‌های پیشنهادی برای پیش‌بینی جریان اسلامپ

مدل‌ها	مرحله آموزش				
	R	NSE	RMSE	MAE	LMI
SVM	0.68	0.02	70.54	57.00	0.16
MARS	0.82	0.65	42.13	21.20	0.57
Mp5-MT	0.97	0.92	20.51	12.13	0.75
MARS-GSA	0.88	0.70	34.91	20.28	0.68
مدل‌ها	مرحله آزمایش				
	R	NSE	RMSE	MAE	LMI
SVM	0.71	0.17	49.29	42.65	0.11
MARS	0.74	0.53	31.35	22.89	0.40
Mp5-MT	0.78	0.61	28.61	20.88	0.46
MARS-GSA	0.75	0.54	30.16	20.39	0.42

شکل به ترتیب مقادیر جریان اسلامپ بتن خودتراکم واقعی و پیش‌بینی شده نظیر آن در مرحله آموزش و درصد خطای مطلق توسط مدل پیشنهادی SVM، Mp5-MT، MARS و MARS-GSA را نشان می‌دهد. در یک مقایسه‌ی کیفی، بیشتر جریان اسلامپ در روش مدل درخت شکل (۱) بر روی خط نیمساز متمرکز هستند و فقط تعداد اندکی از این نقاط خارج از منطقه تمرکز می‌باشند اما در روش‌های دیگر پراکندگی داده‌ها از خط نیمساز مشخصتر می‌باشد. علت این پراکندگی در روش مدل درخت به ساختار دسته‌بندی این روش در پیش‌بینی جریان اسلامپ بتن خودتراکم می‌باشد. همچنین، بهکارگیری الگوریتم GSA باعث تقویت مدل مارس مستقل شده و در شکل (۲) به وضوح قابل مشاهده است که درصد خطای مطلق این روش ترکیبی نسبت به روش مارس مستقل کاهش داشته‌است.



شکل ۱. نمودار پراکندگی مقادیر جریان اسلامپ در مرحله آموزش برای مدل‌های پیشنهادی



شکل ۲. نمودار درصد خطای مطلق مدل‌های مستقل و ترکیبی در پیش‌بینی جریان اسلامپ بتن خودتراکم

۲-۵-۳- نتایج مدل‌های پیش‌بین برای جعبه L (L-box)

عملکرد هر یک از مدل‌های هوشمند MARS، Mp5-MT، SVM و MARS-GSA جهت تخمین مشخصه جعبه L بتن خودتراکم در (جدول ۱۴) ارائه شده است. بر این اساس، اگرچه مدل درخت در مرحله آموزش دارای عملکرد بهتری از معیارهای دقت و خطا داشته است، اما این روش مARS بر پایه الگوریتم جستجوی گرانش بوده است که توانسته است در مرحله آزمایش (تست) نتیجه و عملکرد بهتری نسبت به روش مدل درخت و دیگر روش‌های هوشمند مصنوعی داشته باشد.

جدول ۱۴. ارزیابی عملکرد مدل‌های پیشنهادی برای مدل‌سازی جعبه L

مدل‌ها	مرحله آموزش				
	R	NSE	RMSE	MAE	LMI
SVM	0.64	0.17	0.08	0.06	0.07
MARS	0.73	0.51	0.06	0.03	0.57
Mp5-MT	0.96	0.89	0.03	0.02	0.69
MARS-GSA	0.82	0.68	0.05	0.04	0.42
مدل‌ها	مرحله آزمایش				
	R	NSE	RMSE	MAE	LMI
SVM	0.63	0.18	0.08	0.06	0.01
MARS	0.72	0.47	0.06	0.05	0.15
Mp5-MT	0.79	0.59	0.05	0.04	0.35
MARS-GSA	0.80	0.64	0.05	0.04	0.36

بر اساس جدول (۱۴)، شاخصه‌های خطای RMSE و MAE در مرحله آموزش برای مدل MARS-GSA نسبت به روش MARS به ترتیب ۱۴ و ۲۱ درصد در پیش‌بینی خواص رئولوژی، جعبه L، بتن خودتراکم کاهش داشته است. همچنین شاخص LMI که نشان‌دهنده میزان دقت مطلق بدون در نظر گرفتن مقادیر پرت می‌باشد برای این روش ۰/۳۶ بدست آمده است که نسبت به دیگر روش‌های هوشمند نظیر MARS، SVM (01/0) و Mp5-MT (35/0) بیشتر و نشانگر دقت به نسبت بالای این روش است.

نمودارهای پراکندگی هر یک از مدل‌های هوشمند MARS، Mp5-MT، SVM و MARS-GSA نیز در (شکل ۳) نشان


بتن مورد استفاده قرار می‌گیرد، با استفاده از روش‌های هوشمند مصنوعی مستقل مانند ماشین‌های بردار پشتیبان، مدل درخت تصمیم، مارس و همچنین مدل مارس بر پایه الگوریتم جستجوی گرانس در (جدول ۱۵) آورده شده‌است. در این جدول، مقادیر هر یک از شاخص‌های آماری خطا در مراحل آموزش و تست آورده شده‌است.

بر اساس این جدول، در مرحله تست، دقت مدل MARS-GSA نسبت به مدل MARS مستقل که پارامترهای درون شبکه آن با سعی و خطا بدست آمده‌است، در شاخص‌های دقت NSE و LMI به ترتیب با مقادیر ۱۰ و ۲۹ درصد افزایش داشته و مقادیر شاخص خطای این مدل در پیش‌بینی پارامتر قیف V بتن خودتراکم در ترم RMSE و MAE به ترتیب ۱/۴۹ و ۱/۲۵ بدست آمده‌است. همچنان نقطه قوت روش Mp5-MT دقت بالای مدل در پیش‌بینی متغیر هدف و ضعف این مدل، افت عملکرد در مرحله آزمایش و یا تست می‌باشد که در پیش‌بینی پارامتر قیف V دوباره تکرار شده‌است.


جدول ۱۵. ارزیابی عملکرد مدل‌های پیشنهادی برای مدل‌سازی قیف V

مدل‌ها	مرحله آموزش				
	R	NSE	RMSE	MAE	LMI
SVM	0.80	0.50	4.40	3.21	0.18
MARS	0.93	0.84	2.47	1.13	0.71
Mp5-MT	0.98	0.94	1.47	0.84	0.79
MARS-GSA	0.92	0.84	2.48	1.85	0.53
مدل‌ها	مرحله آزمایش				
R	NSE	RMSE	MAE	LMI	
SVM	0.39	-0.18	3.52	2.92	-0.09
MARS	0.84	0.71	1.75	1.32	0.51
Mp5-MT	0.86	0.73	1.61	1.28	0.52
MARS-GSA	0.89	0.78	1.49	1.25	0.66

نمودارهای پراکندگی (شکل ۵) و درصد خطای مطلق (شکل ۶) نیز همانند بخش قبلی، قدرت مدل‌سازی روش Mp5-MT در مرحله آموزش و ضعف روش SVM با در نظر گرفتن پراکندگی قابل توجه این مدل در پیش‌بینی پارامتر قیف V بتن خودتراکم می‌باشد.



شکل ۵. نمودار پراکندگی مقادیر قیف V در مرحله آموزش برای مدل‌های پیشنهادی



شکل ۶. نمودار درصد خطای مطلق مدل‌های مستقل و ترکیبی در پیش‌بینی قیف V بتن خودتراکم

۴-۵-۳- نتایج مدل‌های پیش‌بین برای مقاومت فشاری (CS)

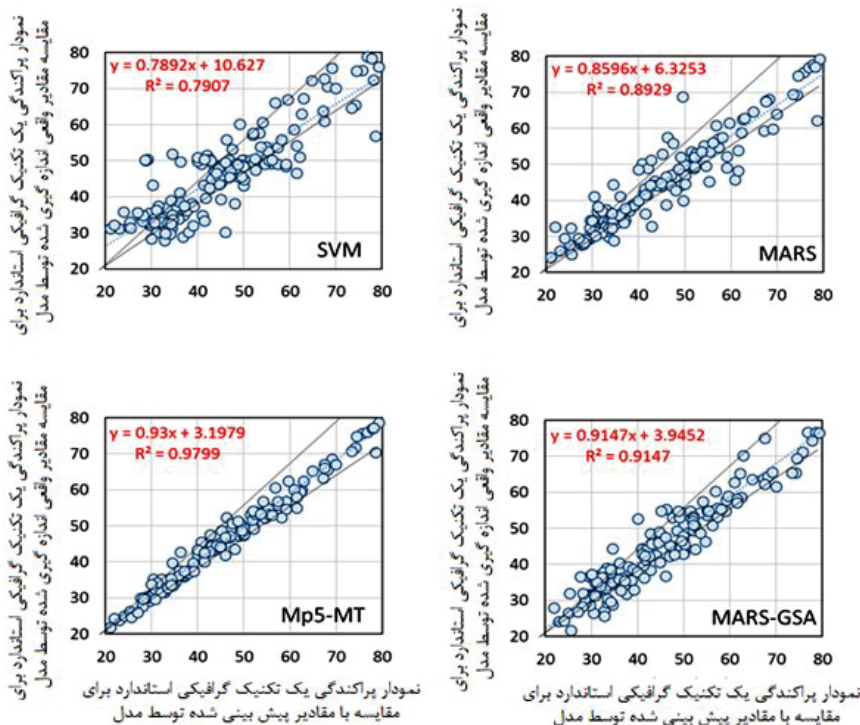
نتایج بدست آمده از مدل‌سازی و پیش‌بینی مقاومت فشاری بتن خودتراکم با استفاده از مدل‌های هوشمند SVM، Mp5-MT، MARS و MARS-GSA (جدول ل ۱۶) آورده شده‌است. در این جدول، مقادیر هر یک از شاخص‌های آماری خطا نظیر R، RMSE، NSE، MAE، LMI در مراحل آموزش و تست آورده شده‌است. در این تحقیق شاخص آماری R برای مدل‌های هوشمند SVM، Mp5-MT، MARS و MARS-GSA در مرحله تست به ترتیب ۰/۸۹، ۰/۹۳، ۰/۹۳ و ۰/۹۳ و پارامتر خطای NSE برای مدل‌های مذکور به ترتیب ۰/۷۸، ۰/۸۶، ۰/۸۶ و ۰/۸۶ تعیین گردید. پس با داشتن تنها شاخص‌های آماری خطا با معیار دقت به نوعی نمی‌توان مدل برتر را تعیین نمود. پس در این تحقیق با استفاده از شاخص‌های آماری نظیر RMSE و MAE می‌توان مدل برتر در پیش‌بینی مقاومت فشاری بتن خودتراکم را تعیین نمود. به این ترتیب، روش MARS-GSA در مرحله تست با داشتن مقادیر کمتر خطا در ترم RMSE و MAE، از عملکرد بهتری نسبت به سایر روش‌های پیشنهادی بوده‌است.

جدول ۱۶. ارزیابی عملکرد مدل‌های پیشنهادی برای مدل‌سازی مقاومت فشاری


مدل‌ها	مرحله آموزش				
	R	NSE	RMSE	MAE	LMI
SVM	0.89	0.79	6.82	5.15	0.57
MARS	0.94	0.89	4.85	2.90	0.76
Mp5-MT	0.99	0.98	2.22	1.61	0.87
MARS-GSA	0.96	0.91	4.31	3.52	0.71
مدل‌ها	مرحله آزمایش				
	R	NSE	RMSE	MAE	LMI
SVM	0.89	0.78	7.61	6.22	0.53
MARS	0.93	0.86	6.08	4.69	0.64
Mp5-MT	0.93	0.86	6.07	4.62	0.65
MARS-GSA	0.93	0.86	6.02	4.51	0.69

در یک مقایسه کیفی، بیشتر مقادیر مقاومت فشاری در روش ماشین‌های بردار پشتیبان در (شکل ۷) خارج از خط نیمساز متمرکز هستند و فقط تعداد اندکی از این نقاط بر روی این منطقه تمرکز می‌باشند اما در دو روش Mp5-MT و MARS-GSA تمرکز

داده‌ها بر روی خط نیمساز مشخص می‌باشد که نشان دهنده دقت هر یک از این مدل‌ها در پیش‌بینی و آموزش شبکه‌ها می‌باشد. در بخش تست، با توجه به نتایج بدست آمده از مقدار خطای مطلق در (شکل ۸) شکل، این‌طور برآورد می‌شود که روش MARS-GSA دارای خطای کمتری در هر یک از پیش‌بینی‌ها از مقاومت فشاری بتن خودتراکم بوده‌است که دلیل اصلی و عمده این موضوع استفاده از الگوریتم جستجوی گرانش می‌باشد که کمک‌کننده مشهودی در پیدا کردن مقادیر بهینه پارامترهای درون شبکه مدل مارس داشته‌است.



شکل ۷. نمودار پراکندگی مقادیر مقاومت فشاری در مرحله آموزش برای مدل‌های پیشنهادی



شکل ۸. نمودار درصد خطای مطلق مدل‌های مستقل و ترکیبی در پیش‌بینی مقاومت فشاری بتن خودتراکم

مدل‌های هوش مصنوعی پیشنهادی با تعداد زیادی داده واقعی که در مراجع برای خواص بتن خودتراکم واقعی گزارش شده است (Dhiyaneshwaran et al. [42]; Bingöl & Tohumcu, [43]; Ranjbar et al. [44]; Krishnapal et al. [45]; Nepomuceno et al. [46]; Vivek & Dhinakaran, [47]; Tang et al. [48]; Gholhaki et al. [49]; De Belie et al. [50]; Hani et al. [51]; Nuruzzaman et al. [52]) مورد ارزیابی قرار گرفته است و با دقت قابل قبولی آن‌ها را پیش‌بینی می‌کند بنابراین اعتبار مدل مورد تایید است.

۴- نتیجه گیری

در تحقیق حاضر برای مدل سازی خواص رئولوژی بتن خودتراکم نظیر کارایی، تعیین قابلیت پرکنندگی، قابلیت عبور بتن به ترتیب از آزمایش های جریان اسلامپ، قیف V و جعبه L و همچنین خواص مکانیکی سخت شده این نوع بتن نظیر مقاومت فشاری از روش های SVM، MARS، Mp5-MT به همراه مدل ترکیبی MARS-GSA استفاده شده است. داده های مورد نیاز برای مدل سازی از تحقیقات پیشین جمع آوری و به نسبت ۷۵/۲۵ در مرحله آموزش و تست استفاده شده اند. نتایج این تحقیق را می توان بصورت زیر ارائه داد:

۱. تکنیک ضریب مالو استفاده از ۷ پارامتر ورودی (مواد جایگزین سیمان، فوق روان کننده، درشت دانه، ریزدانه، متاکائولن، نسبت آب به چسباننده و چسباننده) برای توسعه مدل های هوش مصنوعی را پیشنهاد داد.

۲. روش رگرسیون اسپلاین چند متغیره تطبیقی بر پایه الگوریتم GSA می تواند جریان اسلامپ را با دقت بهتری ($R=0/88$) و ($RMSE=34/91$) نسبت به روش رگرسیون اسپلاین چند متغیره تطبیقی ($R=0/82$ و $RMSE=42/13$) پیش بینی کند. همچنین مقدار شاخص آماری RMSE برای مدل پیشنهادی SVM، Mp5-MT و MARS در این مرحله به ترتیب ۰/۷۰/۵۴، ۲۰/۵۱ و ۴۲/۱۳ است.

۳. اگرچه مدل درخت عملکرد بهتری برای پیش بینی داده های آموزش پارامتر جعبه L دارد، اما روش MARS-GSA در مرحله تست عملکرد بهتری نسبت به روش مدل درخت و دیگر روش های هوشمند مصنوعی دارد. شاخص های خطای RMSE و MAE در مرحله آموزش برای مدل MARS-GSA نسبت به روش MARS به ترتیب ۱۴ و ۲۱ درصد در پیش بینی خواص رئولوژی، جعبه L و بتن خودتراکم کاهش داشته است. همچنین شاخص LMI که نشان دهنده میزان دقت مطلق بدون در نظر گرفتن مقادیر پرت می باشد برای این روش ۰/۳۶ بدست آمده است که نسبت به دیگر روش های هوشمند نظیر MARS (01/0)، SVM (0/۱۵) و Mp5-MT (0/۳۵) بیشتر و نشانگر دقت به نسبت بالای این روش است.

۴. نتایج مدل سازی پارامتر قیف V نشانگر عملکرد قابل قبول و کارایی الگوریتم GSA برای بهینه یابی مقادیر پارامترهای درون شبکه مدل ماریس می باشد. نتایج نشان داد که دقت مدل MARS-GSA در مرحله تست نسبت به مدل MARS، در شاخص های دقت NSE و LMI به ترتیب با مقادیر ۱۰ و ۲۹ درصد افزایش داشته است.

۵. روش MARS-GSA دارای خطای کمتری در هر یک از پیش بینی ها از مقاومت فشاری بتن خودتراکم است. همچنین، مقادیر ضریب همبستگی برای مدل های هوشمند MARS، Mp5-MT، SVM و MARS-GSA در مرحله تست به ترتیب ۰/۸۹، ۰/۹۳، ۰/۹۳ و پارامتر خطای NSE برای مدل های مذکور به ترتیب ۰/۷۸، ۰/۸۶، ۰/۸۶ و ۰/۸۶ تعیین گردید. روش MARS-GSA در مرحله تست دارای مقادیر خطای کمتر (MAE و RMSE) نسبت به سایر روش های پیشنهادی است.

منابع

- [1] Taheri Amiri, M. J., Ashraffian, A., Berenjian, J. (2019). Prediction of Compressive Strength of Self-Compacting Concrete Containing Fly Ash Using Multivariate Adaptive Regression Splines (MARS). *Concrete Research*, 12(2): 113-125. doi: 10.22124/jcr.2020.5966.1139
- [2] Siddique, R. (2011). Properties of self-compacting concrete containing class F fly ash. *Materials & Design*, 32(3), 1501-1507.
- [3] Sonebi, M., & Cevik, A. (2009). Genetic programming based formulation for fresh and hardened properties of self-compacting concrete containing pulverised fuel ash. *Construction and*

Building Materials, 23(7), 2614-2622.

[4] Dey, S., Kumar, V. P., Goud, K. R., & Basha, S. K. J. (2021). State of art review on self compacting concrete using mineral admixtures. *Journal of Building Pathology and Rehabilitation*, 6(1), 18.

[5] Emadi, M., Madani, S. H. (2017). Modeling Compressive Strength of Roller Compacted Concrete Pavement Using Artificial Neural Network, ANFIS and Support Vector Machine. *Journal of Transportation Infrastructure Engineering*, 3(3): 55-78. doi: 10.22075/jtie.2017.1823.1176

[6] Huseien, G. F., & Shah, K. W. (2020). Durability and life cycle evaluation of self-compacting concrete containing fly ash as GBFS replacement with alkali activation. *Construction and Building Materials*, 235, 117458.

[7] Witten I.H, Frank E. (2005). *Data mining: practical machine learning tools and techniques with Java implementations*, Morgan Kaufmann: San Francisco.

[8] Yeh, I. C. (2007). Modeling slump flow of concrete using second-order regressions and artificial neural networks. *Cement and concrete composites*, 29(6), 474-480.

[9] Kina, C., Turk, K., Atalay, E., Donmez, I., & Tanyildizi, H. (2021). Comparison of extreme learning machine and deep learning model in the estimation of the fresh properties of hybrid fiber-reinforced SCC. *Neural Computing and Applications*, 33, 11641-11659.

[10] Pham, A. D., Hoang, N. D., & Nguyen, Q. T. (2016). Predicting compressive strength of high-performance concrete using metaheuristic-optimized least squares support vector regression. *Journal of Computing in Civil Engineering*, 30(3), 06015002.

[11] Belalia Douma, O., Boukhatem, B., Ghrici, M., & Tagnit-Hamou, A. (2017). Prediction of properties of self-compacting concrete containing fly ash using artificial neural network. *Neural Computing and Applications*, 28, 707-718.

[12] Ghanizadeh, A. R., Karimi Goghari, M., & Tavana Amlashi, A. (2018). Modeling of compressive strength of roller-compacted concrete containing reclaimed asphalt pavement using response surface methodology (RSM). *Concrete Research*, 11(2), 67-79.

[13] Fathi, M., Roštami, S., & Khorami, M. S. (2018). Prediction of compressive strength concrete by artificial neural networks, fuzzy logic and multiple regression. *Sharif Journal of Civil Engineering*, 34(3.2), 83-92.

[14] Taheri Amiri, M. J., Ashrafiyan, A., Haghighi, F. R., & Javaheri Barforooshi, M. (2019). Prediction of the compressive strength of self-compacting concrete containing rice husk ash using data driven models. *Modares Civil Engineering journal*, 19(1), 209-221.

[15] Taheri Amiri, M. J., Ashrafiyan, A., & Berenjian, J. (2019). Prediction of Compressive Strength of Self-Compacting Concrete Containing Fly Ash Using Multivariate Adaptive Regression Splines (MARS). *Concrete Research*, 12(2), 113-125. doi: 10.22124/jcr.2020.5966.1139

[16] Golewski, G. L., & Szostak, B. (2022). Strength and microstructure of composites with cement matrixes modified by fly ash and active seeds of CSH phase. *Structural Engineering and Mechanics, An Int'l Journal*, 82(4), 543-556.

[17] Behnood, A., Behnood, V., Gharehveran, M. M., & Alyamac, K. E. (2017). Prediction of the compressive strength of normal and high-performance concretes using M5P model tree algorithm. *Construction and Building Materials*, 142, 199-207.

[18] Ehsani, M., Naseri, H., Saeedi Nezhad, R., Etebari Ghasbeh, M., & Moghadas Nejad, F.

- hardened properties of self-compacting concrete. *Building and environment*, 42(4), 1795-1802.
- [33] Şahmaran, M., Yaman, İ. Ö., & Tokyay, M. (2009). Transport and mechanical properties of self consolidating concrete with high volume fly ash. *Cement and concrete composites*, 31(2), 99-106.
- [34] Güneyisi, E., & Gesoğlu, M. (2008). Properties of self-compacting mortars with binary and ternary cementitious blends of fly ash and metakaolin. *Materials and Structures*, 41, 1519-1531.
- Mahalingam, B., & Nagamani, K. (2011). Effect of processed fly ash on fresh and hardened properties of self compacting concrete. *Int J Earth Sci Eng*, 4(5), 930-940.
- [35] Siddique, R., Aggarwal, P., & Aggarwal, Y. (2012). Influence of water/powder ratio on strength properties of self-compacting concrete containing coal fly ash and bottom ash. *Construction and Building Materials*, 29, 73-81.
- [36] Uysal, M., Yilmaz, K., & Ipek, M. (2012). The effect of mineral admixtures on mechanical properties, chloride ion permeability and impermeability of self-compacting concrete. *Construction and Building Materials*, 27(1), 263-270.
- [37] Siddique, R., Aggarwal, P., & Aggarwal, Y. (2012). Influence of water/powder ratio on strength properties of self-compacting concrete containing coal fly ash and bottom ash. *Construction and Building Materials*, 29, 73-81.
- [38] Muthupriya, P., Sri, P. N., Ramanathan, M. P., & Venkatasubramani, R. (2012). Strength and workability character of self compacting concrete with GGBFS, FA and SF. *Int J Emerg Trends Eng Dev*, 2(2), 424-434.
- [39] Madandoust, R., & Mousavi, S. Y. (2012). Fresh and hardened properties of self-compacting concrete containing metakaolin. *Construction and building materials*, 35, 752-760.
- [40] Dhiyaneshwaran, S., Ramanathan, P., Baskar, I., & Venkatasubramani, R. (2013). Study on durability characteristics of self-compacting concrete with fly ash. *Jordan journal of civil engineering*, 7(3), 342-353.
- [41] Bingöl, A. F., & Tohumcu, İ. (2013). Effects of different curing regimes on the compressive strength properties of self compacting concrete incorporating fly ash and silica fume. *Materials & Design*, 51, 12-18.
- [42] Ranjbar, M. (2017). Durability characteristics of self-compacting concrete incorporating pumice and metakaolin. *J. Mater. Civ. Eng.*, 29(11), 89-94.
- [43] Krishnapal, P., Yadav, R. K., & Rajeev, C. (2013). Strength characteristics of self compacting concrete containing fly ash. *Res J Eng Sci ISSN*, 2278, 9472.
- [44] Nepomuceno, M. C., Pereira-de-Oliveira, L. A., & Lopes, S. M. R. (2014). Methodology for the mix design of self-compacting concrete using different mineral additions in binary blends of powders. *Construction and Building Materials*, 64, 82-94.
- [45] Vivek, S. S., & Dhinakaran, G. (2017). Fresh and hardened properties of binary blend high strength self compacting concrete. *Engineering science and technology, an international journal*, 20(3), 1173-1179.
- [46] Tang, W. C., Wang, Z., Liu, Y., & Cui, H. Z. (2018). Influence of red mud on fresh and hardened properties of self-compacting concrete. *Construction and Building Materials*, 178, 288-300.
- [47] Gholhaki, M., Hajforoush, M., & Kazemi, M. (2018). An investigation on the fresh and hardened properties of self-compacting concrete incorporating magnetic water with various pozzolan-

ic materials. *Construction and Building Materials*, 158, 173-180.

[48] De Belie, N., Soutsos, M., & Gruyaert, E. (2018). *Properties of fresh and hardened concrete containing supplementary cementitious materials (Vol. 25)*. Cham, Switzerland: Springer.

[49] Hani, N., Nawawy, O., Ragab, K. S., & Kohail, M. (2018). *The effect of different water/binder ratio and nano-silica dosage on the fresh and hardened properties of self-compacting concrete*. *Construction and Building Materials*, 165, 504-513.

[50] Nuruzzaman, M. D., Casimiro, J. O. C., & Sarker, P. K. (2020). *Fresh and hardened properties of high strength self-compacting concrete using by-product ferronickel slag fine aggregate*. *Journal of Building Engineering*, 32, 101686.