

پیش بینی مقاومت فشاری بتن خودتراکم حاوی خاکستر بادی با استفاده از روش اسپلین رگرسیونی چندمتغیره تطبیقی (مارس)

محمد جواد ظاهری امیری

دانشجوی دکترای عمران-مهندسی و مدیریت ساخت، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران.

علی اشرفیان *

کارشناسی ارشد عمران-مهندسی و مدیریت ساخت، موسسه آموزش عالی طبری بابل، بابل، ایران.

جواد برنجیان

استادیار گروه عمران، موسسه آموزش عالی طبری بابل، بابل، ایران.

امید لطفی عمران

دانشجوی دکترای عمران-سازه، دانشگاه گیلان، گیلان، ایران.

چکیده

استفاده از بتن خودتراکم علاوه بر کاهش زمان ساخت، به کاهش هزینه نیز می‌انجامد، از اینرو استفاده از روش‌های نوین هوشمند مصنوعی جهت تخمین مقادیر خواص بتن خودتراکم ضروری به نظر می‌رسد. هدف اصلی در این مقاله، امکان استفاده از روش اسپلین رگرسیونی چندمتغیره (مارس) برای پیش‌بینی مقاومت فشاری ۲۸ روزه بتن خودتراکم می‌باشد. در این مطالعه، ۱۰۹ داده آزمایشگاهی مورد بررسی قرار گرفته است. همچنین برای مقایسه عملکرد روش مارس، داده‌های مذکور با روش شبکه عصبی مصنوعی نیز بررسی شد. روش مارس در مرحله آموزش مدل ($RMSE=4/250$) نسبت به شبکه عصبی ($RMSE=4/626$) عملکرد بهتری را نشان داد. نتایج بدست آمده از شاخص‌های خطا در مرحله آزمون روش‌های مارس و شبکه عصبی به ترتیب با ($RMSE=3/007$) و ($RMSE=4/049$) عملکرد مطلوبی در پیش‌بینی مقاومت فشاری از خود نشان دادند. همچنین تحلیل حساسیت انجام شده در این مطالعه نشان داد سیمان و پودر خاکستر بادی بیشترین تاثیر را در توسعه مدل پیشنهادی مارس داشته‌اند. ارزیابی مدل‌های پیشنهادی با استفاده از شاخص‌های آماری خطا سرعت و دقت مدل مارس را در پیش‌بینی خواص بتن مشخص کرده است.

واژه‌های کلیدی: بتن خودتراکم، مقاومت فشاری، پودر خاکستر بادی، مدل مارس، شبکه عصبی مصنوعی.

۱- مقدمه

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 شده‌اند تا ارائه مدلی برای طرح اختلاط بتن خودتراکم امری ضروری به نظر برسد. تجربه و مطالعه‌ی محققان نشان می‌دهد علاوه بر پژوهش‌های آزمایشگاهی گوناگون، روش‌های مختلف هوش مصنوعی در بررسی و پیش‌بینی خواص تازه و سخت شده بتن خودتراکم در دنیا در حال انجام است. راگو^۲ و همکاران به پیش‌بینی مقاومت فشاری بیست و هشت روزه بتن خودتراکم و بتن مقاومت بالا حاوی خاکستر بادی با استفاده از روش شبکه عصبی مصنوعی پرداختند. دوازده نمونه از هر کدام از بتن‌ها مورد بررسی مدلی قرار گرفت و نتایج مقاومت فشاری طراحی، واقعی و محاسباتی عملکرد مطلوب روش را در پیش‌بینی خروجی مدل نشان داده است [۸]. آریاز و همکاران^۳، دو شاخص مقاومت فشاری و سرعت پالس اولتراسونیک را به عنوان معیاری از تشخیص کیفیت بتن حاوی افزودنی‌های طبیعی با استفاده از روش‌های هوش مصنوعی مطالعه نمودند. در این مطالعه از الگوریتم‌های روش مدل درخت برای پیش‌بینی این دو مولفه بهره گرفته شد. برای این منظور از ۴۰ داده جمع‌آوری شده حاصل از ۱۰ طرح اختلاط استفاده شد [۹]. سونبی^۴ و همکاران خواص تازه بتن خودتراکم حاوی پودر سنگ آهک را با استفاده از روش ماشین‌های بردار پشتیبان^۵ پیش‌بینی کرده و عملکرد مدل را مورد ارزیابی قرار دادند. در این ارزیابی، دو تابع چند جمله‌ای کرنل^۶ و شعاعی پایه کرنل^۷ بررسی شد. عملکرد تابع پایه شعاعی در پیش‌بینی خواص تازه بتن خود تراکم به سطح مشاهداتی ما نزدیک‌تر بود. این پژوهش شش آزمایش بتن تازه را مورد بررسی قرار داده و نتایج این دو تابع و عملکرد روش ماشین‌های بردار پشتیبان تحلیل شد [۱۰]. منصور و همکاران رفتار بتن تقویت شده با الیاف FRP^۸ را با استفاده از روش‌های متنوع هوش مصنوعی مورد ارزیابی قرار دادند. ایشان از چهار روش داده مبنای تخمین مقاومت بتن مسلح شده استفاده کرده و نتایج آن را براساس شاخص‌های خطا گزارش نمودند [۱۱]. در سالیان اخیر، روش مدل‌سازی دیگری به نام اسپلاین رگرسیون چندمتغیره تطبیقی

در سال‌های اخیر، استفاده از بتن خودتراکم بسیار رواج یافته و مقالات مختلفی پیرامون این بتن منتشر شده است. این بتن برای اولین بار در دهه ۱۹۸۰ برای استفاده در ساخت آسمان خراش‌ها توسعه یافت. معرفی بتن خودتراکم، پیشرفت‌های تکنولوژیکی عظیمی را به دنبال داشته است. ساخت این بتن، موجب می‌شود جریان بتن از میان آرماتورها بدون نیاز به ویریه و متراکم‌سازی، فقط با وزن خود بتن صورت پذیرد. استفاده از بتن خودتراکم به کاهش زمان ساخت، هزینه و کاهش میزان سروصدا در کارگاه‌های ساختمانی می‌انجامد [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، مدت‌ها با افزایش آب به سیمان تأمین می‌شد، که در تحقیقات بعدی روشن شد، مقدار زیاد آب و همچنین سیمان، نتایج زیان‌آوری به دنبال دارد [۲].

در بتن خودتراکم، فوق روان‌کننده و مواد پودری برای به دست آوردن کارایی بالا و گرانروی مناسب و عدم جداشدگی، مهم است [۳]. با توجه به اینکه مصرف زیاد سیمان و فوق روان‌کننده، هزینه‌های زیادی را در پی داشته، استفاده از ترکیب‌های معدنی مثل خاکستر بادی به عنوان جایگزین درصدی از سیمان، مورد توجه قرار گرفته است. خاکستر بادی خصوصیت سیالیت بتن^۱ را افزایش می‌دهد و ترک خوردگی‌های بتن را به واسطه کاهش حرارت هیدراتاسیون ناشی از حجم سیمان کاهش می‌دهد، بدون آنکه هزینه زیادی در پی داشته باشد. [۴و۵]. حجم مواد پودری مورد استفاده در بتن خودتراکم، در مقایسه با دیگر بتن‌ها، بیشتر و این مورد، اهمیت استفاده از نوع، جنس و ترکیب وزنی مناسب این مواد به منظور دوام و مقاومت بیشتر بتن و همچنین اثرات متقابل آن از جمله کاهش تولید گازهای آلاینده در تولید سیمان و مشارکت در توسعه پایدار را نمایان می‌سازد [۶و۷]. از اینرو، امروزه استفاده از روش‌های هوش مصنوعی برای مدل‌سازی و پیش‌بینی مسائل در مهندسی عمران به علت مزایای قابل تأمل آن، بسیار فراگیر شده است. از طرفی گستردگی مواد و مصالح مورد استفاده در این نوع

^۵Support vector machin^۶ polynomial^۷ Radial basis function^۸ Fiber Reinforced Polymers^۱ Rheology^۲ Raghu^۳ Ayaz et al^۴Sonebi

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

λ_m ، پارامتر هموارسازی نامیده می‌شود. هر $\lambda_m(x)$ تابعی پایه است و می‌تواند تابع کثیرالجزءه‌ای چندقطعه‌ای، یا حاصلضرب دو تابع کثیرالجزءه‌ای چندقطعه‌ای یا بیش‌تر که پیش از این در مدل جا داشت، باشد. ضرایب β ثابت هستند و با استفاده از روش کوچک‌ترین مربعات برآورد می‌شوند. چون تابع پایه به فضای مدل اضافه می‌شود، اثرهای متقابل بین BF ها که پیش از این در مدل وجود داشتند نیز مورد توجه قرار می‌گیرند. سپس BF ها اضافه می‌شوند تا مدل به حداکثر تعداد از جمله برسد که به مدلی تعمداً با برازش کامل می‌انجامد. برای کاهش تعداد جمله‌ها، از رشته حذفی موخر پیروی می‌شود. هدف روش حذفی موخر، پیدا کردن مدل نزدیک به حد مطلوب با حذف متغیرهای غیر اصلی است. مسیر موخر، توابع پایه همراه با کمترین سهم نسبت به مدل را حذف کرده تا اینکه بهترین زیر مدل را بیابد. بنابراین، توابع پایه حفظ شده در مدل بهینه نهایی، از مجموعه تمام توابع پایه انتخابی انتخاب می‌شوند، که در مرحله انتخابی مقدم مورد استفاده قرار گرفت. زیرمجموعه‌های مدل با استفاده از روش ارزیابی متقابل تعمیم یافته (GCV^6) مقایسه می‌شوند. معادله این آزمون، میزان انطباق است که اعداد بزرگ، توابع پایه را تخمین می‌زند و برای کاهش احتمال برازش کامل به کار می‌رود. برای داده‌های آموزشی با N مشاهده، GCV برای مدل به شرح ذیل محاسبه می‌شود [۱۲]:

$$GCV = \frac{\frac{1}{N} \sum_{i=1}^N [y_i - f(x_i)]^2}{\left[1 - \frac{M + d \times (M-1)/2}{N}\right]^2} \quad (2)$$

که در آن M تعداد توابع پایه، d پارامتر برآورد، N تعداد مشاهدات است و $f(x_i)$ مقدار پیش‌بینی شده مدل مارس را مشخص می‌کند. صورت کسر، خطای میانگین مربعات مدل مورد ارزیابی در داده‌های آموزشی است، که به وسیله صورت کسر برآورد می‌شود. صورت کسر، واریانس صعودی را در مورد افزایش پیچیدگی مدل در نظر می‌گیرد. لازم به ذکر است که $(M-1)/2$ تعداد گره‌های تابع مبنا است. ارزیابی متقابل تعمیم یافته، نه تنها تعداد توابع پایه مدل، بلکه تعداد گره‌ها را نیز برآورد می‌کند. [۱۲]. در هر مرحله حذفی تابع

(مارس)^۱ توسط فریدمن^۲ معرفی شد [۱۲] که در زمینه مهندسی عمران و به ویژه خاک و آب مورد بررسی قرار گرفته است [۱۳ و ۱۴]. هدف اصلی در این مقاله، ارزیابی دقت مدل مارس در پیش‌بینی مقاومت فشاری بیست و هشت روزه بتن خودتراکم حاوی خاکستریادی، مقایسه آن با مدل شبکه عصبی مصنوعی با توجه به الگوی ساختاری استفاده از الگوریتم کمترین مربعات خطا در هر دوروش و در نهایت اعتبارسنجی آن می‌باشد.

۲- روش‌شناسی

۲-۱- مدل اسپلاین رگرسیونی چندمتغیره تطبیقی (MARS)

اسپلاین رگرسیونی چندمتغیره تطبیقی، روش رگرسیونی غیر خطی و ناپارامتریک است که پاسخ‌های غیرخطی را بین ورودی‌ها و خروجی یک سیستم به وسیله مجموعه‌ای از قطعه‌های خطی تکه‌ای (کثیرالجزءه‌های چندقطعه‌ای^۳) 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 [۱۲]. روش مارس، توابع پایه را با جست‌وجو به روش مرحله‌ای ایجاد می‌کند. الگوریتم رگرسیون انطباقی^۴، 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 می‌یابند، 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 جکابسنز^۵ [۱۵] برای انجام تحلیل‌های ارائه شده در این مقاله مورد استفاده قرار می‌گیرد. مدل مارس، به عنوان ترکیب خطی BF ها و روابط متقابل آنها ایجاد و به صورت زیر بیان می‌شود:

⁴ Adaptive regression algorithm

⁵ Jekabsons

⁶ Generalized Cross Validation

¹ Multivariate Adaptive Regression Splines(MARS)

² Friedman

³ Splines

$$R = \frac{\sum_{i=1}^M (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^M (O_i - \bar{O})^2 \sum_{i=1}^M (P_i - \bar{P})^2}} \quad (3)$$

$$RMSE = \frac{\sum_{i=1}^M (P_i - O_i)^2}{M} \quad (4)$$

$$MAE = \frac{\sum_{i=1}^M |P_i - O_i|}{M} \quad (5)$$

۳- بحث و نتایج

۳-۱- جمع آوری و تحلیل داده‌های آزمایشگاهی

در این مطالعه، ۱۰۹ داده آزمایشگاهی با شرایط اختلاط یکنواخت برای پیش‌بینی مقاومت فشاری بیست و هشت روزه بتن خودتراکم حاوی پودر خاکستر بادی به صورت ۷۵ درصد آموزش و ۲۵ درصد آزمون در نظر گرفته شد. این داده‌ها از تحقیقات بوزوبا و لاجمی^۳ [۵]، قزل و خیاط^۴ [۱۸]، بوی و همکاران^۵ [۱۹]، پاتل و همکاران^۶ [۲۰]، سونبی^۷ [۲۱]، کنان و گانسن^۸ [۲۲]، گونسی و همکاران^۹ [۲۳]، صدیق^{۱۰} [۲۴]، دیانشواران و همکاران^{۱۱} [۲۵] و بینگول و توهمکو^{۱۲} [۲۶] دریافت شد. عملکرد مطلوب این مدل در پیش‌بینی مقاومت بیست و هشت روزه بتن خودتراکم، تا حد زیادی به جامعیت داده‌های آموزشی بستگی دارد. دسترسی به انواع زیادی از داده‌های تجربی مورد نیاز برای توسعه روابط بین متغیرهای مخلوط خودتراکم، از اهمیت زیادی برخوردار است. پارامترهای در نظر گرفته شده برای ورودی مدل آموزشی، شامل درشت‌دانه، ریزدانه، سیمان، پودرخاکستر بادی، فوق روان کننده و نسبت آب به چسباننده^{۱۳} (سیمان + پودرخاکستر بادی) می‌باشد. در انتخاب مناسب‌ترین حالت پارامترهای ورودی به جهت آموزش بهتر برای توسعه مدل، پس از تولید تصادفی داده‌ها (رندوم سازی) و کنترل پیشینه و کمینه‌ها، از روش سعی و خطا استفاده شد. در این روش، متغیرهای ورودی به لحاظ حالت و چینش آموزش مدل (مقدار، درصد و یا نسبت مواد شرکت کننده در طرح اختلاط)

پایه برای کوچک کردن معادله (۱) حذف می‌شود، تا اینکه مدل به قدر کافی برازش شده تشخیص داده شود. مارس روشی انطباقی است، زیرا انتخاب توابع پایه و موقعیت‌های گره متغیر داده محور و خاص مسئله موجود است [۱۶].

۳-۲- مدل شبکه عصبی پرسپترون چندلایه^۱ (MLP-NN)

ساختار شبکه عصبی مصنوعی، به گونه‌ای است که نرون‌ها در دسته‌هایی به نام لایه مرتب می‌شوند. ساختار معمولی شبکه عصبی از سه لایه تشکیل شده است. لایه ورودی، داده‌ها را در شبکه توزیع می‌کند، لایه پنهان داده‌ها را پردازش می‌کند و لایه خروجی نتایج را به ازای ورودی‌های مشخص استخراج می‌کند [۱۶]. در این تحقیق، تعداد لایه‌های پنهان و تعداد نرون‌ها در لایه پنهان، بر مبنای مقایسه عملکرد شبکه‌ها انتخاب شد که برای تشکیل شبکه از تابع آموزش Levenberg-Marquardt و تابع انتقال purelin و logsigmoid استفاده گردید. بهترین معیار برای مقایسه عملکرد شبکه‌های ایجاد شده برای مرحله ارزیابی آموزش، ریشه میانگین مربعات خطا^۲ می‌باشد، که مدل برازش شده خطی بین داده‌های مشاهده شده و داده‌های پیش‌بینی شده انجام گردید [۱۷]. در مثال تحلیل شده (مقاومت فشاری بیست و هشت روزه) با استفاده از مارس در بخش بعدی، همان داده‌ها با استفاده از الگوریتم MLP با نرم افزار Matlab نیز برای اهداف تطبیقی مورد ارزیابی قرار گرفتند.

۳-۲- شاخص‌های ارزیابی مدل‌های پیشنهادی

برای اندازه‌گیری عملکرد مدل‌های ارائه شده در مرحله آموزش و آزمون، شاخص‌های آماری شامل ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) به شرح زیر مورد محاسبه قرار گرفت که در روابط زیر نمایش داده شده است. در این روابط Pi داده‌های پیش‌بینی، Oi داده‌های مشاهداتی و M تعداد داده‌ها می‌باشد.

⁸ Kannan and Ganesan

⁹ Gu'neyisi, et al

¹⁰ Siddique

¹¹ Dhiyaneshwaran, et al

¹² Bingöl and Tohumcu

¹³ Binder

¹ Multi layer perceptron neural network

² Root Mean Square Error

³ Bouzoubaa and Lachemi

⁴ Ghezal and Khayat

⁵ Bui, et al

⁶ Patel, et al

⁷ Sonebi

مورد بررسی قرار گرفتند. برای این منظور نتایج مرحله آزمون در ۴ سناریو مختلف، با استفاده از روش مارس بررسی شد و ارزیابی شاخص‌های آماری خطا، ضریب همبستگی و ریشه میانگین مربعات خطا به عنوان معیاری برای انتخاب داده‌هایی با بهترین برآورد، نشان داد که حالت شماره یک، سناریو برگزیده در این ارزیابی بوده است. جدول ۱ شرح سناریوها، تعداد ورودی و حالات مختلف ورودی‌های توسعه دهنده مدل و نتایج نظیر هر کدام را شرح داده است. در نهایت مقاومت فشاری ۲۸ روزه

$$CS_{28} = f(C, PFA, \frac{W}{B}, SP, F.A, C.A) \quad (6)$$

بتن خودتراکم تابعی از متغیرهای ورودی متناسب با رابطه زیر می‌باشد. پس از انتخاب بهترین حالت مربوط به داده‌های ورودی در مدل-های مارس و شبکه عصبی، به منظور ارزیابی پارامترهای ورودی مورد استفاده در پیش‌بینی مقاومت فشاری بتن، محدوده و میانگین و انحراف معیار پارامترهای ورودی و خروجی به منظور تحلیل بهتر در جدول ۲ ارائه شده است.

جدول ۱- نتایج برازش مدل برای انتخاب بهترین حالت ورودی داده‌ها

شماره سناریو	یک	دو	سه	چهار
تعداد داده ورودی	۶	۵	۵	۷
داده‌های ورودی	سیمان، درشت دانه، ریزدانه، درصد وزنی فوق روان کننده (نسبت به چسباننده)، خاکستر بادی، نسبت آب به چسباننده	سیمان، نسبت درشت دانه به ریزدانه، درصدوزنی فوق روان کننده (نسبت به چسباننده)، خاکستر بادی، نسبت آب به چسباننده	نسبت آب به سیمان، نسبت درشت دانه به ریزدانه، فوق روان کننده، خاکستر بادی، نسبت آب به چسباننده	آب، سیمان، درشت دانه، ریزدانه، فوق روان کننده، خاکستر بادی، نسبت آب به چسباننده
R	۰/۹۵	۰/۹۱	۰/۸۹	۰/۹۲
RMSE	۳/۰۰۷	۳/۶۸۲	۴/۰۰۳	۳/۳۹۴

جدول ۲- ارزیابی آماری پارامترهای مورد استفاده در پیش‌بینی مقاومت بتن

متغیر	واحد	محدوده	میانگین	انحراف معیار	
ورودی‌ها					
سیمان (C)	X1	Kg	۱۶۰ - ۵۵۰	۲۹۸/۰۲	۸۵/۵۶
پودر خاکستر بادی (PFA)	X2	Kg	۰ - ۳۳۰	۱۴۳/۷۳	۷۲/۱۶
نسبت آب به چسباننده (W/B)	X3	-	۰/۳۲ - ۰/۸۷	۰/۵	۰/۱۲
فوق روان کننده (SP)	X4	%	۰ - ۱	۰/۳۴	۰/۲۲
ریزدانه (F.A)	X5	Kg	۴۷۸ - ۱۰۷۹	۸۳۶/۵۲	۸۵/۳۵
درشت دانه (C.A)	X6	Kg	۵۹۰ - ۹۳۴/۶	۸۲۵/۲۲	۴۴/۶
خروجی					
مقاومت فشاری ۲۸ روزه (CS28)	Y	MPa	۱۰/۲ - ۸۰/۹	۴۰/۴۱	۱۴/۴۶

هر تابع پایه بصورت جداگانه صورت پذیرفته و روابط مربوط به این برازش ارائه شده است. در این مطالعه از ۱۲ تابع چندتکه‌ای خطی برای توسعه مدل پیشنهادی فشاری استفاده شد. همچنین بیشترین مقدار عکس‌العمل برای آزادی متغیرهای ورودی ۲ و

۳-۲- توسعه مدل مارس

جزئیات تحلیلی پارامترهای تنظیم کننده کاربر در روش مارس شامل نوع تابع پایه مورد استفاده، تعداد آنها و بیشترین مقدار عکس‌العمل هر تابع بعد از آزمون و خطا بررسی شد. برازش در

شاخص ارزیابی متقابل تعمیم یافته ۴۶/۷۰۳ بوده است. جدول ۳ ارائه شده است. در این جدول X_1 تا X_6 پارامترهای ورودی مدل توابع پایه و معادلات متناظر هر کدام را مشخص کرد. این توابع و روابط ارائه شده مربوط، به منظور انتخاب بهترین مدل و رابطه نهایی بهینه از خروجی مورد نظر با توجه به رابطه مارس (رابطه ۱) بتن خودتراکم حاوی خاکستر بادی مطابق رابطه زیر است:

$$Y = 50.75 + (0.09076*BF^1) - (0.2425*BF^2) - (19.99*BF^3) - (1485*BF^4) - (0.3855*BF^5) + (0.4058*BF^6) - (0.09764*BF^7) + (0.1186*BF^8) + (0.08774*BF^9) + (0.1371*BF^{10}) + (8.466*BF^{11}) - (5.295*BF^{12}) \quad (7)$$

جدول ۳- توابع پایه و روابط مربوطه در روش مارس برای پیش بینی مقاومت فشاری

تابع پایه	رابطه
BF^1	$\max(0, X_1 - 350)$
BF^2	$\max(0, 350 - X_1)$
BF^3	$\max(0, X_4 - 0.015)$
BF^4	$\max(0, 0.015 - X_4)$
BF^5	$\max(0, X_3 - 0.39) * \max(0, 220 - X_2)$
BF^6	$\max(0, X_5 - 786)$
BF^7	$\max(0, 786 - X_5)$
BF^8	$\max(0, X_6 - 800)$
BF^9	$\max(0, X_2 - 60)$
BF^{10}	$BF2 * \max(0, X_4 - 0.015)$
BF^{11}	$BF2 * \max(0, 0.015 - X_4)$
BF^{12}	$BF3 * \max(0, X_6 - 900)$


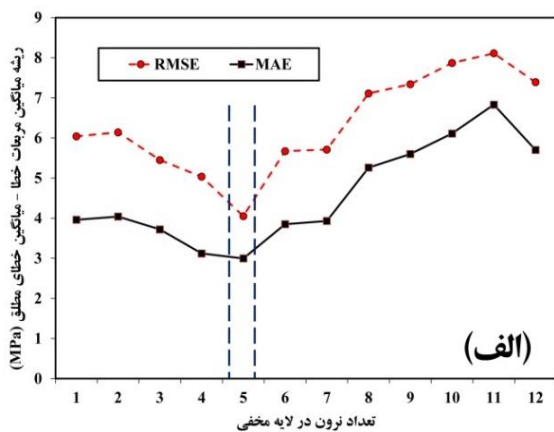
جدول ۴- تجزیه و تحلیل واریانس در مدل مارس

تابع واریانس	GCV	انحراف استاندارد	متغیر(ها)
۱	۱۰۶۰/۸۱۴	۱۷/۲۴	سیمان
۲	۳۶۰/۵۶۵	۸/۷۸۳	پودرخاکستر بادی
۳	۲۵۶/۶۹۳	۵/۷۹۳	فوق روان کننده
۴	۱۱۶/۱۰۱	۵/۹۱	ریزدانه
۵	۱۷۳/۳۵۵	۴/۳۵	درشت دانه
۶	۱۰۷/۰۴۳	۴/۵۶	سیمان، فوق روان کننده
۷	۵۰/۱۸۴	۳/۸۱۵	پودرخاکستر بادی، فوق روان کننده

بعد از تعیین مدل بهینه مارس، با گروه بندی برای جمع کردن تمام توابع پایه که در برگیرنده یک متغیر است و گروه بندی دیگر این توابع که در برگیرنده اثرهای متقابل دو به دو است (و حتی اثرهای متقابل سطح بالاتر)، روش شناخته شده ای به عنوان تجزیه و تحلیل واریانس (ANOVA^۱) می تواند برای ارزیابی سهم متغیرهای ورودی و توابع پایه مورد استفاده قرار گیرد [۱۲]. جدول ۴ تجزیه و تحلیل واریانس را برای مدل بسط یافته مارس پیش بینی مقاومت فشاری بیست و هشت روزه بتن خودتراکم نشان می دهد. ستون اول در جدول ۴ تعداد تابع تحلیل واریانس را فهرست می کند. ستون دوم دلیل اهمیت تابع تحلیل واریانس متناظر را با فهرست کردن میزان شاخص GCV برای مدل همراه با تمام توابع پایه را نشان می دهد. ستون سوم انحراف استاندارد این تابع و ستون آخر، متغیرهای ورودی خاص و اثرگذار بر هر تابع اصلی را در ارتباط با تابع تحلیل واریانس نشان می دهد.

¹ Analysis Of Variance

عنوان مدل نهایی انتخاب شده است. ارزیابی تعداد نرون بررسی شده در لایه مخفی نشان داد، توسعه مدل با ۵ نرون بهترین عملکرد را در تخمین مقاومت فشاری داشته است. شکل (الف) ارزیابی شاخص‌های خطای ریشه میانگین مربعات خطا و میانگین خطای مطلق را در مدل نهایی شبکه عصبی نمایش داده است. در این مطالعه نرخ آموزش ۰/۳ و شاخص مومنتوم ۰/۱۵ و تعداد دور آموزش مدل ۲۰۰۰ بوده است. ساختار معماری مدل پیشنهادی مقاومت فشاری با استفاده از روش شبکه عصبی مصنوعی نیز در شکل (ب) ارائه شده است.



شکل ۱- توسعه مدل شبکه عصبی مصنوعی؛ الف: ارزیابی نرون در لایه مخفی، ب: ساختار معماری مدل مقاومت فشاری

۳-۴- ارزیابی عملکرد مدل‌های پیشنهادی

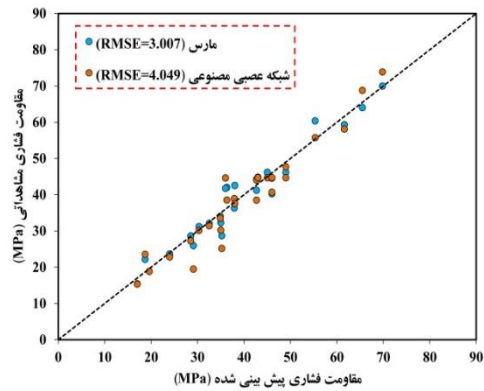
همان‌طور که در جدول ۵ نشان داده شده است، ضریب همبستگی (R) در مرحله آموزش برای روش مارس و شبکه عصبی مصنوعی، به ترتیب ۰/۹۶ و ۰/۹۵ می‌باشد. همچنین، مقدار شاخص آماری RMSE به ترتیب ۴/۲۵۰ و ۴/۶۲۶ بدست آمده است. بدین ترتیب، شاخص‌های آماری، نشان می‌دهد هر دو مدل، با آموزش

در تحلیل مبتنی بر واریانس در جدول ۴، سیمان در تابع واریانس شماره یک (۱۷/۲۴ / ۱۰۶۰ = GVC و انحراف معیار ۸۱۴) بیش‌ترین مشارکت را در توسعه مدل ایفا نموده است. همچنین پودر خاکستر بادی (۸/۷۸۳ / ۳۶۰ = GVC و انحراف معیار ۵۶۵) بعد از سیمان سهم بیشتری در تشکیل مدل داشته است. در ارزیابی دوگانه متغیرها نیز سیمان و فوق‌روان کننده (۱۰۷ / ۰۴۳ = GVC و انحراف معیار ۴/۵۶) مشارکت بیشتری در مدلسازی مقاومت فشاری داشته است.

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 [۲۷]. متغیرها و محل‌های گره برای هر متغیر، از طریق روش جست و جوی سریع اما متمرکز تعیین می‌شوند. همچنین انتخاب مقدم و روش حذفی موخر، به عنوان تضمین کننده مدل بهینه تشخیص داده می‌شود [۱۲]. صرف‌نظر از توانایی کمک به برآورد متغیرهای ورودی، مزیت دیگر مارس سرعت همگرایی آن است [۲۷] که در زمان پردازش آن مشهود است. اما شبکه عصبی به لحاظ ساختار الگوریتم، به خاطر کارآمد نبودن در انجام سریع محاسبات، به دلیل فرایند طولانی تعیین پیکربندی شبکه بهینه، مورد انتقاد قرار گرفته است، چرا که این الگوریتم از راه قیاس شناخته نمی‌شود، بلکه از طریق رویکرد آزمون و خطا تعیین می‌شود [۲۷]. از این رو، روش مارس به عنوان روشی با پردازش سریع در این پژوهش مورد توجه بوده است.

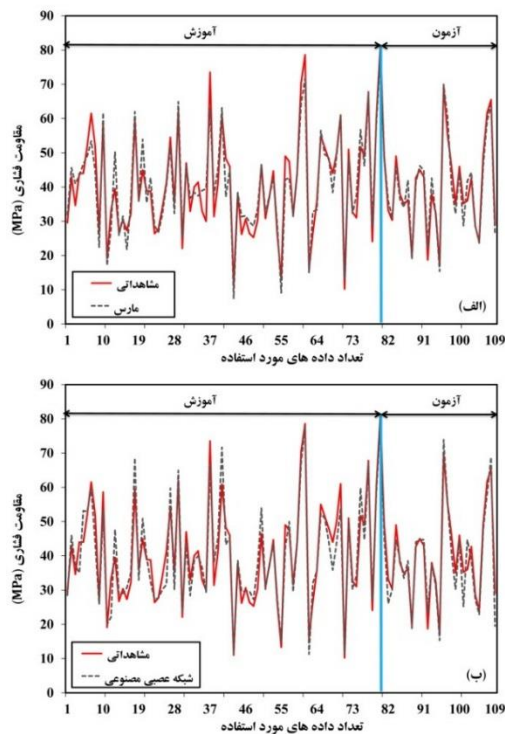
۳-۳- توسعه مدل شبکه عصبی مصنوعی

در این مطالعه از شبکه عصبی پرسپترون چندلایه با یک لایه مخفی استفاده شد. برای آموزش و آزمایش شبکه‌ها به ترتیب از ۷۵ درصد (۸۲ عدد) و ۲۵ درصد (۲۷ عدد) داده‌ها استفاده شده است. ملاک تعیین مدل نهایی، عملکرد آن در مرحله آزمون می‌باشد. لازم به ذکر است که با هر بار آنالیز مدل شبکه عصبی مصنوعی در نرم‌افزار متلب، وزن‌های متفاوتی به شبکه اختصاص داده می‌شود؛ در نتیجه با هر بار آنالیز جواب متفاوتی حاصل می‌گردد. برای مرتفع کردن این مسئله برای هر مدل شبکه عصبی مصنوعی ۱۲ بار آنالیز انجام شده که در نهایت بهترین جواب به



شکل ۳- مقایسه مقادیر پیش‌بینی مقاومت فشاری ۲۸ روزه مرحله آزمون روش مارس و شبکه عصبی مصنوعی

شکل ۴، مقایسه‌ای بین داده‌های آزمایشگاهی و نتایج محاسباتی مارس و شبکه عصبی مصنوعی در پیش‌بینی مقاومت فشاری بتن خودتراکم را با استفاده از نمودار سری زمانی نشان داده است. مدل مارس در تخمین بیشینه‌ها و کمینه‌های محلی موفقیت بیشتری در مقایسه با شبکه عصبی مصنوعی، هم در مرحله آموزش و هم در مرحله آزمون داشته است. ضعف شبکه عصبی مصنوعی (شکل ۴ ب) در تخمین کمینه و بیشینه‌های محلی بویژه در مقادیر مقاومت فشاری بیشتر از ۳۵ مگاپاسکال در مرحله آموزش و کمتر از ۴۰ مگاپاسکال در مرحله آزمون نمایان تر بوده است.




شکل ۴- مقایسه مقادیر مشاهداتی و محاسباتی مارس و شبکه عصبی مصنوعی در نمودار سری زمانی

مطلوبی مواجه بوده‌اند. از طرف دیگر، شاخص آماری (R)، در مرحله آزمون برای مدل مارس و شبکه عصبی به ترتیب ۰/۹۵ و ۰/۹۱ و RMSE برای مدل‌های مذکور ۳/۰۰۷ و ۴/۰۴۹ تعیین گردید. عملکرد مدل مارس ارائه شده در مرحله آموزش و آزمون، از دقت بیشتری در پیش‌بینی مقاومت فشاری بتن خودتراکم برخوردار بوده است. از این رو می‌توان به عنوان ابزاری معتبر در داده کاوی و پژوهش‌های هوش مصنوعی در بتن مورد استفاده قرار گیرد.

جدول ۵- ارزیابی عملکرد مدل مارس در مقایسه با شبکه عصبی

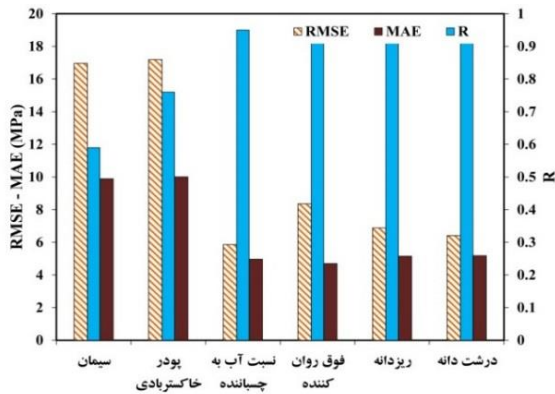
مصنوعی پرسپترون چندلایه				
مدل	R	RMSE	MAE	
آموزش	MARS	۰/۹۶	۴/۲۵۰	۳/۳۰۵
	MLP-NN	۰/۹۵	۴/۶۲۶	۳/۶۲۵
آزمون	MARS	۰/۹۵	۳/۰۰۷	۲/۳۸۷
	MLP-NN	۰/۹۱	۴/۰۴۹	۲/۹۹۵

در این پژوهش، شکل‌های (۲) و (۳)، نمودار پراکندگی مقادیر مقاومت فشاری مشاهداتی و پیش‌بینی نظیر آن توسط مدل پیشنهادی مارس و شبکه عصبی مصنوعی را در مرحله آموزش و آزمون نشان می‌دهد. همانطور که در شکل قابل مشاهده است، داده‌ها در اطراف خط ایده‌آل (خط نیمساز ۴۵ درجه) متمرکز شده که نشان از همبستگی مقادیر واقعی و محاسباتی مدل می‌باشد. همچنین مقادیر پیش‌بینی شبکه عصبی در مقایسه با مارس دچار انحراف بیشتری از مقادیر واقعی شده است.



شکل ۲- مقایسه مقادیر پیش‌بینی مقاومت فشاری ۲۸ روزه مرحله آموزش روش مارس و شبکه عصبی مصنوعی

داده است. دیگر پارامترهای تاثیرگذار بر مقاومت بتن به ترتیب فوق روان کننده، درشت دانه و ریزدانه می‌باشد که از کم به زیاد گزارش شده است. شرح کامل تجزیه و تحلیل حساسیت پارامترها در جدول ۶ نشان داده شده است. شکل ۵ نیز تاثیر حذف هر پارامتر مستقل را بر نتایج شاخص‌های خطا نمایش داده است.



شکل ۵- نتیجه آنالیز حساسیت انجام شده با استفاده از مارس

۳-۵- آنالیز حساسیت پارامترهای مستقل

تاثیرپذیری متغیر وابسته بر متغیرهای مستقل و اثرگذاری هر یک از این پارامترها بر یکدیگر را آنالیز حساسیت می‌نامند [۲۸]. از این رو، در این پژوهش به منظور تعیین میزان اثرگذاری هر پارامتر ورودی بر مقاومت فشاری ۲۸ روزه بتن خودتراکم حاوی پودر خاکستر بادی، مدل مارس برای انجام آنالیز حساسیت برگزیده شده است. برای این منظور، هر بار یکی از پارامترهای ورودی حذف و اثر آن بر خروجی مدل تحلیل و بررسی شده است. نتایج آنالیز حساسیت نشان داد، حذف متغیرهای ورودی سیمان (۵۹ / RMSE=۱۶ / ۹۷, MAE=۹ / ۸۹, R=۰ / ۷۶) بیشترین تاثیر را در مدل توسعه یافته مقاومت فشاری ۲۸ روزه داشته‌اند. همچنین نسبت آب به سیمان (۹۵ / RMSE=۵ / ۸۶, R=۰ / ۹۶, MAE=۴ / ۷۶) کمترین میزان تاثیر را در خروجی مدل از خود نشان

جدول ۶- تاثیر حذف پارامترهای مستقل از ورودی مدل

پارامترهای ورودی	R	RMSE	MAE
$CS_{28} = f(PFA, W/B, SP, C, A, F, A)$	۰ / ۵۹	۱۶ / ۹۷	۹ / ۸۹
$CS_{28} = f(C, W/B, SP, C, A, F, A)$	۰ / ۷۶	۱۷ / ۱۹	۱۰ / ۰۱
$CS_{28} = f(C, PFA, SP, C, A, F, A)$	۰ / ۹۵	۵ / ۸۶	۴ / ۹۶
$CS_{28} = f(C, PFA, W/B, C, A, F, A)$	۰ / ۹۱	۸ / ۳۶	۴ / ۷۰
$CS_{28} = f(C, PFA, SP, W/B, F, A)$	۰ / ۹۱	۶ / ۸۸	۵ / ۱۵
$CS_{28} = f(C, PFA, SP, W/B, C, A)$	۰ / ۹۴	۶ / ۴۱	۵ / ۱۸

مقادیر واقعی و محاسباتی با یکدیگر سازگار بوده و دقت پیش‌بینی‌ها با خطای قابل قبولی مشاهده شده است. مدل مارس با RMSE و MAE کمتر (۲/۵۶۱ و ۳/۰۲۹) و همچنین ضریب همبستگی بالاتر (۰/۹۸) نسبت به شبکه عصبی مصنوعی در وضعیت بهتری مشخص می‌باشد. با توجه به نتایج بدست آمده در اعتبارسنجی مدل‌های پیشنهادی و دقت مقادیر پیش-بینی شده مدل‌های توسعه یافته، صحت ارزیابی آنها مورد تایید بوده است.

۳-۶- اعتبارسنجی مدل‌های پیشنهادی

برای صحت‌سنجی مدل‌ها و کنترل شرایط اعتمادپذیری آنها در این مطالعه از ۶ طرح اختلاط استفاده نشده که شرح مقادیر آن در جدول ۷ گزارش شده، استفاده گردید. داده‌های ورودی این ارزیابی از مطالعه گونسی و همکاران [۲۹] جمع‌آوری و در جدول ۷ ارائه شده است. نتایج این ارزیابی در جدول ۸ به وضوح نشان می‌دهد برای هر شش نمونه مقایسه

جدول ۷- داده‌های ورودی برای ارزیابی دقت پیش‌بینی مدل‌ها

نمونه	ورودی‌ها					
	C (Kg/m3)	PFA (Kg/m3)	W/B	SP (%)	F.A (Kg/m3)	C.A (Kg/m3)
SCC1	۴۴۰	۱۱۰	۰/۳۲	۰/۰۱۶	۷۱۳/۵	۹۱۶/۸
SCC2	۳۳۰	۲۲۰	۰/۳۲	۰/۰۲۲	۶۹۹/۶	۸۹۸/۹
SCC3	۲۲۰	۳۳۰	۰/۳۲	۰/۰۳	۶۸۵/۸	۸۸۱/۱
SCC4	۳۶۰	۹۰	۰/۴۴	۰/۰۰۸	۸۵۵/۱	۸۵۵/۱
SCC5	۲۷۰	۱۸۰	۰/۴۴	۰/۰۱	۸۴۱/۹	۸۴۱/۹
SCC6	۱۸۰	۲۷۰	۰/۴۴	۰/۰۱	۸۲۸/۶	۸۲۸/۶

جدول ۸- ارزیابی مدل‌ها در مرحله اعتبارسنجی

مدل	نمونه	مقاومت فشاری واقعی	مقاومت فشاری محاسباتی	میزان خطا (MPa)	R	RMSE (MPa)	MAE (MPa)
MARS	SCC1	۶۹/۸	۷۰/۱۵	۰/۳۵	۰/۹۸	۳/۰۲۹	۲/۵۶۱
	SCC2	۶۰/۹	۶۴/۲۱	۳/۳۱			
	SCC3	۴۷/۵	۴۲/۲۸	-۵/۲۲			
	SCC4	۵۲/۱	۴۹/۱۴	-۲/۹۶			
	SCC5	۴۴/۷	۴۱/۹۸	-۲/۷۲			
	SCC6	۳۰/۳	۲۹/۴۸	-۰/۸۲			
MLP-NN	SCC1	۶۹/۸	۶۷/۱۸	-۲/۶۱	۰/۹۵	۳/۸۲	۳/۵۹
	SCC2	۶۰/۹	۵۹/۰۴	-۱/۸۵			
	SCC3	۴۷/۵	۵۲/۶۷	۵/۱۷			
	SCC4	۵۲/۱	۵۷/۵۷	۵/۴۷			
	SCC5	۴۴/۷	۴۸/۰۸	۳/۳۸			
	SCC6	۳۰/۳	۲۷/۲۴	-۳/۰۵			

۴- نتیجه گیری

همبستگی در خروجی مدل، تاثیر بیشتری نسبت به متغیرهای ورودی دیگر بر مقاومت فشاری داشته است. بعد از سیمان، حذف متغیر پودر خاکستر بادی ($RMSE=17/19$) و $MAE=10/01$ بیشترین اثر را بر عملکرد مدل داشته است.

اعتبارسنجی مدل‌های پیشنهادی از طریق شش طرح اختلاط استفاده نشده مورد بررسی قرار گرفت که مدل مارس و شبکه عصبی در تخمین داده‌های اعتبارسنجی عملکرد قابل قبولی را در محدوده پایگاه داده استفاده شده گزارش کردند. مارس ($MAE=2/561$ و $RMSE=3/029$ ، $R=0/98$) در ارزیابی اعتبارسنجی به عنوان روش نوین هوشمند مصنوعی نشان داد ابزار مورد اعتمادی در ارتباط با داده کاوی خواص بتن می‌باشد.

در این پژوهش، برتری و عملکرد مناسب روش مارس نسبت به شبکه عصبی مصنوعی جهت تخمین مقاومت فشاری ۲۸ روزه بتن خودتراکم حاوی پودر خاکستریادی با دفت بالا نشان داده شده است. همچنین روش مارس با توجه به الگوی ساختاری بررسی توابع پایه و تناسب و تحلیل واریانسی آنها و گزارش تحلیل‌های آماری دقیق به عنوان روش نوین و کارآمد و سریع در پیش‌بینی خواص بتن معرفی گردید.

- در دراین مطالعه، مقاومت فشاری ۲۸ روزه بتن خودتراکم حاوی پودر خاکستر بادی با استفاده از روش اسپلین رگرسیونی تطبیقی براساس مجموعه کثیرالجملات چندجمله ای تخمین زده شد. همچنین برای مقایسه عملکرد این روش از مدل شبکه عصبی مصنوعی پرسپترون چندلایه نیز برای مقایسه تطبیقی استفاده شد. ۶ پارامتر ورودی شامل اجزای شرکت کننده در طرح اختلاط و یک پارامتر خروجی مقاومت فشاری ۲۸ روزه برای توسعه مدل استفاده گردید. ارزیابی و توسعه مدل مارس در مرحله آزمون ($R=0/95$ ، $MAE=3/007$ ، $RMSE=2/387$ و $MAE=2/387$) و مقایسه آن با روش شبکه عصبی مصنوعی پرسپترون چندلایه ($R=0/91$ ، $MAE=4/049$ ، $RMSE=2/995$)، عملکرد مناسب آن را در تخمین مقاومت فشاری ۲۸ روزه نشان داده است. همچنین ارزیابی عملکرد مدل با توجه به شاخص ضریب همبستگی، آموزش بهتر مدل مارس ($R=0/96$) نسبت به روش شبکه عصبی ($R=0/95$) را نشان می‌دهد، ولی در مرحله آزمون، شبکه عصبی ($R=0/95$) نسبت به مارس ($R=0/91$) عملکرد ضعیف‌تری در پیش‌بینی از خود بروز داده است.
- براساس نتایج آنالیز حساسیت، حذف متغیر ورودی سیمان ($RMSE=16/97$ و $MAE=9/89$) با ۳۶ درصد کاهش

- Programming (GEP) and Multivariate Adaptive Regression Splines (MARS)." *Journal of Hydrology* 529, (2015)1590-1600
- [14]. Zhang, W. G., and A. T. C. Goh. "Multivariate Adaptive Regression Splines Models for Analyses of Diaphragm Wall and Drilled Shafts—Numerical Case Studies." *Tunneling and Underground Construction*. ASCE, (2014).
- [15]. Jekabsons G. VariReg: a software tool for regression modelling using various modeling methods. Riga Technical University, <<http://www.cs.rtu.lv/jekabsons>,(2010).
- [16]. Hastie, Trevor, Robert Tibshirani, and Jerome Friedman. "Overview of supervised learning." *The elements of statistical learning*. Springer New York, (2009). 9-41
- [17]. رضایی بالف, محمد؛ محمدنجم‌زاده و عصمت راشدی، ارزیابی عمق آبشستگی در اطراف پایه های پل ها به همراه انباشت موانع با استفاده از مدل درخت تصمیم ، چهاردهمین کنفرانس هیدرولیک ایران، دانشکده مهندسی شهید نیکبخت، زاهدان (۱۳۹۴).
- [18]. Ghezal, A., and Kamal H. Khayat. "Optimizing self-consolidating concrete with limestone filler by using statistical factorial design methods." *Materials Journal* 99.3 (2002): 264-272.
- [19]. Bui, Van K., Yilmaz Akkaya, and Surendra P. Shah. "Rheological model for self-consolidating concrete." *Materials Journal* 99.6 (2002): 549-559.
- [20]. Patel, R., et al. "Development of statistical models for mixture design of high-volume fly ash self-consolidating concrete." *Materials Journal* 101.4 (2004): 294-302.
- [21]. Sonebi, Mohammed. "Medium strength self-compacting concrete containing fly ash: Modelling using factorial experimental plans." *Cement and Concrete research* 34.7 (2004): 1199-1208.
- [22]. Kannan, V., and K. Ganesan. "Mechanical properties of self-compacting concrete with binary and ternary cementitious blends of metakaolin and fly ash." *Journal of the South African Institution of Civil Engineering* 56.2 (2014): 97-105.
- [23]. Güneysi, Erhan, Mehmet Gesoglu, and Erdoğan Özbay. "Evaluating and forecasting the initial and final setting times of self-compacting concretes containing mineral admixtures by neural network." *Materials and structures* 42.4 (2009): 469-484.
- [24]. Siddique, Rafat. "Properties of self-compacting concrete containing class F fly ash." *Materials & Design* 32.3 (2011): 1501-1507.
- [25]. Dhiyaneshwaran, S., et al. "Study on durability characteristics of self-compacting concrete with fly ash." *Jordan Journal of Civil Engineering* 7.3 (2013): 342-353.
- [1]. Khatib, J. M. "Performance of self-compacting concrete containing fly ash." *Construction and Building Materials* 22.9 (2008): 1963-1971.
- [2]. Alabi, S. A., L. M. Olanitori, and J. O. Afolayan. "Optimum mix design for minimum concrete strength requirement using akure pit-sand as fine aggregate." *Journal of Emerging Trends in Engineering and Applied Sciences (JETEAS)* 3.4 (2012): 718-724.
- [3]. Aggarwal, Paratibha, et al. "Self-compacting concrete-procedure for mix design." *Leonardo electronic journal of practices and technologies* (2008),15-24
- [4]. Sonebi, Mohammed. "Medium strength self-compacting concrete containing fly ash: Modelling using factorial experimental plans." *Cement and Concrete research* (2004)34.7 1199-1208.
- [5]. Bouzoubaa, N., and M. Lachemi. "Self-compacting concrete incorporating high volumes of class F fly ash: preliminary results." *Cement and concrete research* 31.3 (2001): 413-420.
- [6]. Mehta, Povinder K. "Siliceous ashes and hydraulic cements prepared therefrom." U.S. Patent No.4,8 Au, (1978).
- [7]. اسکندری, حمید؛ امیرپاکزاد و مرتضی طیبی نیا، مدلسازی طرح اختلاط بهینه بتن خودتراکم، فصلنامه تحقیقات بتن، سال ششم، شماره دوم، صفحه ۳۸-۲۵، ۱۳۹۳.
- [8]. Prasad, BK Raghunath, Hamid Eskandari, and BV Venkatarama Reddy. "Prediction of compressive strength of SCC and HPC with high volume fly ash using ANN." *Construction and Building Materials* 23.1 (2009): 117-128.
- [9]. Ayaz, Yaşar, Adnan Fatih Kocamaz, and Mehmet Burhan Karakoç. "Modeling of compressive strength and UPV of high-volume mineral-admixed concrete using rule-based M5 rule and tree model M5P classifiers." *Construction and Building Materials* 94 (2015): 235-240.
- [10]. Sonebi, Mohammed, et al. "Modelling the fresh properties of self-compacting concrete using support vector machine approach." *Construction and Building Materials* ۶۴-۵۵ ۱۰۶, 2016.
- [11]. Mansouri, Iman, et al. "Predicting behavior of FRP-confined concrete using neuro fuzzy, neural network, multivariate adaptive regression splines and M5 model tree techniques." *Materials and Structures* 49.10 (2016): 4319-4334.
- [12]. Friedman, Jerome H. "Multivariate adaptive regression splines." *The annals of statistics* (1991): 1-67.
- [13]. Emamgolizadeh, S., et al. "Estimation of soil cation exchange capacity using Genetic Expression

- [26]. Bingöl, A. Ferhat, and İlhan Tohumcu. "Effects of different curing regimes on the compressive strength properties of self compacting concrete incorporating fly ash and silica fume." *Materials & Design* 51 (2013): 12-18.
- [27]. Zhang, W. G., and Anthony Teck Chee Goh. "Multivariate adaptive regression splines for analysis of geotechnical engineering systems." *Computers and Geotechnics* 48 (2013): 82-95.
- [28]. Najafzadeh, Mohammad, Mohammad Rezaie Balf, and Esmat Rashedi. "Prediction of maximum scour depth around piers with debris accumulation using EPR, MT, and GEP models." *Journal of Hydroinformatics* 18.5 (2016): 867-884.
- [29]. Güneyisi, Erhan, Mehmet Gesoğlu, and Erdoğan Özbay. "Strength and drying shrinkage properties of self-compacting concretes incorporating multi-system blended mineral admixtures." *Construction and Building Materials* 24.10 (2010): 1878-1887.

Prediction of Compressive Strength of Self-Compacting Concrete Containing Fly Ash Using Multivariate Adaptive Regression Splines (MARS)

Mohammad Javad Taheri Amiri

PhD student, Babol Noshirvani University of Technology

Ali Ashrafian *

Department of Civil Engineering, Tabari University of Babol

Javad Berenjjan

Assistant Professor, Tabari University of Babol

Omid Lotfi-Omran

PhD student, University of Guilan, Rasht, Iran

Abstract

Utilization of Self-compacting concrete can reduce expenses of the construction and time, therefore the use of artificial intelligence methods to estimation of concrete properties seems necessary. The main purpose of the study presented in this paper was to investigate the feasibility of using multivariate adaptive regression spline (MARS) for the prediction of 28-day compressive strength of self-compacting concrete with an optimal mixing ratio. Total of 94 dataset collected from the published paper were used in this study. To compare the performance of the technique, prediction was also done using a multilayer perceptron neural network model. MARS model in the training phase model (RMSE=4/250) was better performance than Neural Network (RMSE=4/626). The results of error indices of the testing stage in MARS and Neural Network methods respectively (RMSE=3/007) and (RMSE=4/049) were performed accurately in compressive strength prediction. The analysis indicated that the proposed MARS model can gain a high precision, which provides an alternative method for predicting the properties of SCC.

Keywords: Self-compacting concrete, Compressive strength, Fly ash, MARS, Artificial neural network.

* Corresponding Author: ali_ashrafian@yahoo.com

