

# پیش‌بینی عمق کربناته شدن بتن و بررسی عوامل تأثیرگذار از طریق مدل‌های یادگیری ماشین و بهینه‌سازی

شعب منصور<sup>۱</sup>، علیرضا رهایی<sup>۲</sup>، سیدهادی راشدی<sup>۳</sup>، فریدون مقدس‌نژاد<sup>۴\*</sup>

۱- دانشجوی کارشناسی ارشد، دانشکده عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران، shoaib.mansouri@aut.ac.ir

۲- استاد، دانشکده عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران، rahai@aut.ac.ir

۳- دانشجوی دکتری، دانشکده عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران، h.rashedi@aut.ac.ir

۴- استاد، دانشکده عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران، moghadas@aut.ac.ir

\*moghadas@aut.ac.ir

## چکیده

پیش‌بینی دقیق عمق کربناته شدن بتن برای محافظت در برابر پیامدهای زیان‌بار مانند ترک‌خوردگی و خوردگی بسیار مهم است. با این وجود، به دلیل پیچیدگی‌های فرآیند و انبوه متغیرهای موجود، تشخیص پارامترهایی که بیشترین اهمیت را در مدل‌سازی عمق کربناته بتن دارند، چالش بزرگی محسوب می‌شود. این مطالعه به توسعه یک روش انتخاب ویژگی هابرید (ترکیبی) به نام MOEA/D-ANN می‌پردازد. هدف این روش شناسایی مهم‌ترین متغیرهایی است که به دستیابی بالاترین دقت پیش‌بینی کمک می‌کنند. این روش پیشنهادی الگوریتم تکاملی بهینه‌سازی چند هدفه مبتنی بر جداسازی<sup>۱</sup> را با شبکه‌های عصبی مصنوعی<sup>۲</sup> ترکیب می‌کند تا با استفاده از قدرت روش‌های بهینه‌سازی و یادگیری ماشین، مشکل انتخاب ویژگی را به طور موثر حل کند. برای ارزیابی عملکرد روش معرفی شده از الگوریتم (RReliefF) که یک الگوریتم رتبه‌بندی ویژگی است، نیز بهره‌گرفته شده است. از روش ANN برای پیش‌بینی عمق کربناته بتن و از روش‌های ترکیبی MOEA/D-ANN و RReliefF برای یافتن متغیرهای تأثیرگذار استفاده شده است. نتایج بدست آمده نشان داده‌اند که مدل ایجاد شده با استفاده از رویکرد MOEA/D-ANN، با ترکیب متغیرهای تعیین شده توسط آن، درصد خطا را کاهش و دقت را افزایش داد. در این مدل به مقدار قابل توجه ضریب تعیین  $R^2 = 0.99$  می‌رسد، که بر دقت خوب آن در پیش‌بینی عمق کربناته بتن و تأیید انتخاب دقیق متغیرهای تأثیرگذار تأکید می‌کند. همچنین نتایج نشان داده که با افزایش نسبت آب به سیمان به میزان ۱۰ درصد، عمق کربناته شدن بتن به میزان ۱۵ درصد افزایش می‌یابد.

## کلمات کلیدی

عمق کربناته شدن، پیش‌بینی، یادگیری ماشین، شبکه عصبی مصنوعی، MOEA/D، بهینه‌سازی.

<sup>1</sup> Multi objective Evolutionary Algorithm based on Decomposition (MOEA/D)

<sup>2</sup> Artificial Neural Networks (ANN)

بتن متداولترین مصالح مورد استفاده در پروژه های مختلف ساختمانی، صنعتی و عمرانی از جمله ساخت و ساز ساختمان، حمل و نقل، حفاظت از آب و سازه های بنادر است. یکی از عناصر مهم در ارزیابی عملکرد بتن دوام آن است. دوام بتن نقش مهمی را در حفظ عملکرد و ایمنی سازه های بتن مسلح در طول عمر مفید آنها دارد [۱]. عوامل متعددی بر دوام بتن تأثیر می گذارند. کربناته شدن یکی از مشکلات متداول است که در نتیجه انتشار دی اکسید کربن ( $CO_2$ ) در محیط اتفاق می افتد [۲]. کربناته شدن زمانی اتفاق می افتد که دی اکسید کربن ( $CO_2$ ) از محیط به منافذ یک سازه بتنی نفوذ کند [۳]. در نتیجه این نفوذ  $CO_2$  با اجزاء سیمان هیدراته واکنش داده و منجر به تشکیل کربنات کلسیم ( $CaCO_3$ ) و در نتیجه منجر به کاهش PH به حدود عدد ۹ می شود [۴]. ناحیه کربناته در سازه های بتنی می تواند باعث خوردگی آرماتورهای فولادی شود که منجر به آسیب های فیزیکی مانند پوسته شدن و ترک می شود [۴]. علاوه بر این، اثرات مخرب دیگر مانند کاهش مقاومت فشاری بتن، کاهش سطح مقطع فولاد و تأثیر عملکرد توامان بین فولاد و بتن را در پی دارد. در نتیجه، مقاومت سازه بتن مسلح ضعیف می شود و منجر به کاهش طول عمر سازه می شود [۷-۵].

هزینه خوردگی آرماتورها با صرف میلیاردها دلار در سال قابل توجه است [۸]. بنابراین، تشخیص به موقع و نظارت مستمر کربناته شدن بتن نقش مهمی در حفظ سلامت ساختاری بتن دارد [۹]. اگرچه چندین روش آزمایشگاهی برای اندازه گیری عمق کربناته شده بتن<sup>۱</sup> وجود دارد، درحالی که روش های سنتی پرهزینه، زمان بر و تا حد زیادی مخرب هستند [۹]. همچنین اطلاعات محدودی در مورد اثر این عوامل موثر بر عمق کربناته شدن موجود می باشد [۱۰]. از این رو، قابلیت پیش بینی دقیق پیشرفت کربناته شدن از طریق مدل های قابل اعتماد می تواند نقش مهمی در جلوگیری از آسیب های آینده و افزایش اقدامات ایمنی و به تبع آن حداقل رساندن خسارات اقتصادی ایفا کند [۱۰]. پیش بینی دقیق کربناته شدن در بتن مسلح در افزایش دوام و ایمنی [۱۱] و همچنین در تصمیم گیری آگاهانه در مورد استراتژی های تعمیر و نگهداری برای چنین سازه هایی از اهمیت بالایی برخوردار است [۱۲]. بنابراین، پیش بینی دقیق عمق کربناته شده چالش بزرگی می باشد. برای این منظور، مدل های مبتنی بر یادگیری ماشین (ML) را می توان برای یادگیری رفتار پیچیده کربناته شدن با استفاده از داده های تجربی به کار گرفت [۱۳].

مدل های ML مختلفی برای این منظور به کار گرفته شده اند و از میان آنها، مدل های شبکه عصبی مصنوعی (ANN) به طور مکرر انتخاب و به طور گسترده مورد استفاده قرار گرفته اند [۲۳-۲۴ و ۲۶].

به این ترتیب، لو و لیو [۱۴] دو مدل ANN را برای تخمین عمق کربناته شدن در بتن پیش تنیده معرفی کردند: یکی بر اساس پس انتشار<sup>۲</sup> و دیگری با استفاده از توابع پایه شعاعی<sup>۳</sup>. برای پیش بینی عمق کربناته شدن، سطح تنش در بتن، سن آزمایش، نسبت سیمان به سنگدانه ریز و سنگدانه درشت، و نسبت آب به سیمان به عنوان ویژگی ها (یعنی متغیرها) در نظر گرفته شدند [۲۷-۳۱]. یک شبکه عصبی (NN) برای تخمین عمق کربناته شده توسط تافس و همکاران [۱۵] استفاده شده است. این محققین متغیرهای مختلفی مانند نوع سیمان، نسبت آب به مواد چسباننده، خاکستر بادی، سیمان، سرباره کوره بلند، کل آب موثر، کل سنگدانه، سنگدانه های با اندازه های کمتر از ۰/۱۲۵، ۰/۲۵ و ۴ میلی متر، روان کننده، ماده هوازا و مدت زمان کربناته شدن به عنوان متغیرهای مستقل در نظر گرفتند. این محققین از روش های انتخاب متغیر، به ویژه انتخاب ویژگی های<sup>۴</sup> متوالی، برای تعیین مناسب ترین ویژگی ها و حذف هرگونه ویژگی نامربوط یا اضافی از مجموعه داده ورودی اصلی مورد استفاده در آزمایش های خود استفاده کردند.

همچنین اکپینر و اوانواکوا [۱۰] از ANN برای پیش بینی عمق کربناته شده استفاده کردند، که در آن با استفاده از ۱۸ متغیر ورودی طبقه بندی شده در شش گروه به ترتیب: ترکیب سیمان، ترکیب خاکستر بادی، پارامترهای طرح اختلاط، شرایط عمل آوری

<sup>1</sup> Carbonation Depth (CD)

<sup>2</sup> Backpropagation

<sup>3</sup> Radial Basis Function kernel (RBF)

<sup>4</sup> Feature selection

بتن، شرایط محیطی، و سن نمونه استفاده نمودند. در آن مطالعه، یک بررسی اولیه برای تعیین مقدار بهینه نرون‌های پنهان برای مدل ANN مورد استفاده انجام شد. نتایج نشان داد که ANN دقیقاً می‌تواند عمق کربناته شدن را زمانی که تعداد نرون‌های پنهان ده بود تخمین بزند. فلیکس و همکاران [۱۶] یک مدل عددی مبتنی بر ANN را ایجاد کردند که نوع سیمان، مقاومت فشاری، رطوبت نسبی، محتوای افزودنی، شرایط نوردی، میزان CO<sub>2</sub> و سن از متغیرهای مستقل مدل بودند. چهار روش تنظیم وزن سیناپسی برای آموزش بسیاری از ساختارهای ANN مورد استفاده قرار گرفت و ثابت شد که الگوریتم لوبنبرگ-مارکوآرت<sup>۱</sup> موثرترین روش آموزش از نظر کارایی است. مطالعات انجام شده توسط کلوش و همکاران [۴]، آکپینار و اووانواکوا [۱۷]، و فلیکس و همکاران [۱۸] تأثیر قابل توجه استفاده از ANN را برای تجزیه و تحلیل تأثیر ویژگی‌ها بر روی عمق کربناته شدن در بتن مخلوط شده با خاکستر بادی نشان داده اند. به طور خاص، این مطالعات نشان داده‌اند که تغییرات در محتوای سیمان و خاکستر بادی، نسبت آب به مواد چسبنده، غلظت CO<sub>2</sub>، رطوبت نسبی و دما می‌تواند منجر به تغییرات قابل توجهی در عمق کربناته شدن شود. شایان ذکر است که کار آکپینار و اووانواکوا [۱۸] براساس تحقیقات قبلی آنها در سال ۲۰۱۶ [۱۰] استوار است. احسانی و همکاران [۱۹] یک روش جدید به نام MOEA/D-ANN برای انتخاب ویژگی‌ها معرفی کرده‌اند که به شناسایی مهم‌ترین متغیرها برای پیش‌بینی دقیق عمق کربناته شدن کمک می‌کند. این روش نسبت به روش‌های سنتی مانند RReliefF در کاهش زمان آموزش و بهبود دقت پیش‌بینی عملکرد بهتری داشته است. نتایج نشان داده است که مدل ANN که از مجموعه ویژگی‌های بهینه انتخاب شده توسط MOEA/D-ANN استفاده می‌کند، بالاترین دقت پیش‌بینی را دارد و این روش می‌تواند برای پیش‌بینی سایر خواص بتن نیز به کار رود.

روش‌های انتخاب ویژگی<sup>۲</sup> با شناسایی و انتخاب مشخصه‌های مرتبط از متغیرهای ورودی، نقش مهمی در یادگیری ماشین ایفا می‌کنند. این روش‌ها مزایای متعددی را هم در تحقیقات و هم در کاربردهای عملی ارائه می‌دهند. این روش‌ها با تمرکز بر ویژگی‌های اطلاعاتی، عملکرد مدل و دقت پیش‌بینی را افزایش می‌دهند و از انطباق بیش از حد و گرفتن مهم‌ترین عوامل مرتبط با متغیر هدف جلوگیری می‌کنند. علاوه بر این، روش‌های انتخاب ویژگی با کاهش تعداد مشخصه‌ها، کارایی محاسباتی را بهبود می‌بخشد که منجر به زمان اجرای سریع‌تر و استفاده کارآمد از منابع، به‌ویژه با مجموعه داده‌های با مقیاس بزرگ می‌شود. مشخصه‌های انتخاب‌شده، قابلیت تفسیر مدل را افزایش می‌دهد و بینش‌های ارزشمندی را برای محققان فراهم می‌کند تا براساس مرتبط‌ترین داده‌ها، تصمیم‌های آگاهانه بگیرند. علاوه بر این، این روش‌ها با حذف ویژگی‌های اضافی و خطاها، به بهبود کیفیت داده‌ها کمک می‌کنند و در نتیجه نمایش بهتری از الگوهای بنیادین ایجاد می‌کنند. این مجموعه داده بهبود یافته توانایی مدل را برای درک ارتباطات مهم و ایجاد پیش‌بینی‌های دقیق افزایش می‌دهد. در حالی که روش‌های انتخاب ویژگی مزایای ارزشمندی در بهبود عملکرد و قابلیت تفسیر مدل ارائه می‌دهند، هنوز محدودیت‌ها و شکاف‌هایی وجود دارد که باید برطرف شوند. تحقیقات آینده باید بر روی توسعه روش‌های انتخاب ویژگی قوی‌تر و سازگارتر تمرکز کند که بتواند ساختارهای پیچیده داده‌ها و روابط غیر خطی را برای افزایش بیشتر اثربخشی انتخاب ویژگی در یادگیری ماشین را در نظر بگیرد.

در این تحقیق، یک روش انتخاب ویژگی هایبرید (ترکیبی) به نام MOEA/D-ANN براساس الگوریتم بهینه‌سازی ابتکاری MOEA/D و ANN توسعه داده شده است. هدف اصلی این تحقیق بررسی تمامی متغیرهای بالقوه‌ای است که می‌تواند بر روی عمق کربناته شدن تأثیر بگذارد و با استفاده از روش فیلترینگ و بهینه‌سازی با دو تابع هدف، مهم‌ترین آن‌ها را شناسایی کند. از روش ANN برای توسعه مدل پیش‌بینی عمق کربناته شدن، با در نظر گرفتن تمام متغیرهای ورودی مربوطه استفاده شده است. قبل از استفاده آن‌ها در مدل‌های پیش‌بینی، اهمیت عوامل ورودی با استفاده از روش‌های MOEA/D و RReliefF ارزیابی شده است. به دنبال آن، عملکرد مدل‌های توسعه‌یافته با استفاده از شاخص‌های آماری مختلف برای ارزیابی دقت آن‌ها و اندازه‌گیری خطاهای احتمالی مورد ارزیابی قرار گرفته است. یکی از نوآوری‌های اصلی این پژوهش، انجام تحلیل حساسیت بر روی سه متغیر

<sup>1</sup> Levenberg-Marquardt(LM)

<sup>2</sup> Feature Selection



درشت، فوق روان کننده به سنگدانه ریز، فوق روان کننده به آب، آب به سیمان، خاکستر بادی به آب، آب به سنگدانه درشت و آب به سنگدانه ریز. علاوه بر این، نسبت سنگدانه ریز به سیمان، خاکستر بادی به سنگدانه ریز، سنگدانه ریز به سنگدانه درشت، سنگدانه درشت به سیمان، خاکستر بادی به سنگدانه درشت، و خاکستر بادی به سیمان نیز به عنوان متغیرهای ورودی بر حسب درصد وزنی در نظر گرفته شده است. شرایط آزمایش با مدت چرخه (روز)، درصد رطوبت نسبی و درصد غلظت CO<sub>2</sub> نشان داده شده است. هدف مدل پیش‌بینی این است که عوامل متنوعی را که بر عمق کربناته شدن تأثیر می‌گذارند با در نظر گرفتن این متغیرهای ورودی به‌دقت ثبت کند که در این تحقیق در مجموع ۳۷ متغیر را در بر می‌گیرد. این مدل پیش‌بینی تضمین می‌کند که نسبت‌های مختلف بین اجزاء بتن را در نظر می‌گیرد و درک دقیق‌تری از فرآیند کربناته شدن ارائه می‌کند. جدول ۲ آمار توصیفی وزن مواد موجود در مجموعه داده را گزارش می‌کند که پارامترهای میانگین، انحراف معیار، حداقل و حداکثر برای متغیرهای ورودی و خروجی اصلی محاسبه شده‌اند.

جدول ۲ آمار توصیفی متغیرها

متغیرها	مخفف	میانگین	انحراف معیار	حداقل	حداکثر
<b>متغیرهای ورودی اصلی</b>					
سیمان (kg/m <sup>3</sup> )	C	۲۶۳/۲	۷۹/۲	۱۲۰	۴۹۴
خاکستر بادی (kg/m <sup>3</sup> )	F	۱۰۰/۲	۸۰/۳	۰	۲۸۰
سنگدانه درشت (kg/m <sup>3</sup> )	CA	۶۹۱/۹	۱۵۷/۶	۵۰۱/۸	۱۰۷۱
سنگدانه ریز (kg/m <sup>3</sup> )	FA	۱۰۶۱/۶	۱۱۴/۳	۷۹۰	۱۲۵۸
آب (kg/m <sup>3</sup> )	W	۱۶۵	۱۲	۱۱۲	۲۲۰
فوق روان کننده (kg/m <sup>3</sup> )	S	۰/۷	۱/۷	۰	۷/۷
چرخه (روز)	CY	۳۹/۶	۳۲/۲	۳	۱۲۶
درصد رطوبت نسبی	RH	۶۴/۶	۴/۷	۵۵	۷۰
درصد غلظت CO <sub>2</sub>	CC	۱۰/۳	۱۲/۷	۱	۵۰
<b>متغیر خروجی</b>					
عمق کربناته شدن (mm)	CD	۹/۹	۱۰/۲	۰	۵۷

## ۲-۲ آماده سازی داده ها


از میان داده‌های مورد استفاده در این تحقیق، هیچ داده‌ای به صورت گم شده یا مفقود وجود نداشت و نیازی به تکمیل آنها نبود. هنگام کار با متغیرهای متعددی که محدوده‌های متنوعی دارند، استفاده از روش‌های مقیاس‌بندی مناسب در طول پیش‌پردازش داده‌ها بسیار مهم است. به عنوان مثال، در مجموعه داده مورد استفاده در این تحقیق، محدوده مقادیر برای سنگدانه درشت بین ۵۰۱/۸ و ۱۰۷۱ است، در حالی که فوق روان کننده از ۰ تا ۷/۷ است. در مورد روش‌های ML که از فاصله اقلیدسی به عنوان تابع هدف استفاده می‌کنند، احتمال دست کم گرفتن غیرواقعی اهمیت فوق‌روان کننده نسبت به سنگدانه درشت وجود دارد که برای حل این مشکل، انجام عملیات مقیاس‌گذاری روی داده‌ها برای اطمینان از آماده‌سازی مناسب داده‌ها بسیار مهم است [۴۹]. متغیرهای ورودی در این تحقیق با استفاده از معادله‌ی (۱) در محدوده ۰/۱ و ۰/۹ مقیاس بندی شدند [۵۰].

$$S = 0.1 + 0.8 \times \frac{j - j_{\min}}{j_{\max} - j_{\min}} \quad (1)$$

در جایی که متغیرهای  $S$ ،  $z$ ،  $j_{\min}$  و  $j_{\max}$  به ترتیب مقدار مقیاس شده، مقدار اصلی و مقدار حداقل و حداکثر داده های متغیر مربوطه را به ترتیب نشان می دهند. پس از مرحله پیش پردازش، مجموعه داده به صورت تصادفی به دو گروه مجزا تقسیم شد: مجموعه آموزشی، که ۸۵ درصد از داده ها را تشکیل می دهد و داده های آزمون، شامل ۱۵ درصد باقی مانده است. داده های اعتبارسنجی برای تنظیم دقیق هایپرپارامترها در مدل های مختلف ML استفاده شده اند. به عبارت دیگر، در طول هر تکرار، توزیع داده ها به شرح زیر است: ۷۰٪ برای آموزش، ۱۵٪ برای آزمایش و ۱۵٪ دیگر برای اعتبارسنجی.

### ۳-۲ شبکه عصبی مصنوعی

شبکه عصبی مصنوعی (ANN) عملکرد مغز انسان را تکرار می کند و به عنوان یک ابزار قوی برای تجزیه و تحلیل داده ها مورد استفاده قرار می گیرد و آنها را در زمینه یادگیری ماشین (ML) بسیار موثر می کند [۵۱]. مشابه شبکه های عصبی بیولوژیکی، ANN از واحدهای پردازش توزیع شده و موازی، شبیه نرون ها تشکیل شده اند. یکی از مزیت های قابل توجه این شبکه ها ظرفیت آنها برای مدل سازی مسائل پیچیده و غیرخطی بدون توجه به عوامل موثر بر آنها است [۱۶]. شبکه عصبی مصنوعی به عنوان یک روش مدل سازی غیرخطی و به عنوان یک روش قوی برای ایجاد ارتباطات بین متغیرهای ورودی و خروجی شناخته شده است [۵۲]. شبکه های عصبی مصنوعی به طور کلی از سه لایه تشکیل شده اند: (۱) لایه ورودی از ویژگی های ورودی تشکیل شده است، (۲) لایه (های) پنهان که می تواند شامل چندین لایه باشد که عملیات پیچیده غیرخطی را انجام می دهد (۳) لایه خروجی که متغیر خروجی را ذخیره می کند [۵۳]. شکل ۱ پیکربندی یک شبکه عصبی مصنوعی و ارتباطات بین لایه ورودی، لایه (های) پنهان و لایه خروجی را نشان می دهد.



شکل ۱ ساختار شبکه عصبی مصنوعی

معادله (۲) نحوه پیش بینی متغیر وابسته در ساختار شبکه عصبی مصنوعی را نشان می دهد.

$$y_j = f\left(\sum_{i=1}^n w_{ij} \cdot x_i + b_j\right) \quad (2)$$

در این معادله  $y_j$  خروجی نرون  $J$  است،  $f$  نشان‌دهنده تابع فعال‌سازی است،  $w_{ij}$  نشان‌دهنده وزن اتصال ورودی  $x_i$  به نرون  $J$ ، عبارت بایاس نرون  $J$  و  $n$  نشان‌دهنده تعداد متغیرهای ورودی است.

با توجه به اینکه در این روش احتمال برازش کردن بیش از حد داده‌ها وجود دارد، نویسندگان ۱۵ درصد از داده‌ها را به اعتبار سنجی اختصاص دادند. این زیر مجموعه از داده‌ها به عنوان معیاری برای توقف الگوریتم عمل می‌کند. برای توضیح بیشتر، اگر اختلاف بین دقت داده‌های آموزش و داده‌های اعتبارسنجی از یک مقدار مشخص از پیش تعریف شده در طول آموزش مدل فراتر رود، الگوریتم پایان می‌یابد. روش پیشنهادی از برازش بیش از حد شبکه عصبی مصنوعی جلوگیری می‌کند و ایجاد یک مدل پیش‌بینی صحیح را ممکن می‌سازد. در این تحقیق از شبکه عصبی مصنوعی برای دو منظور استفاده شده است. اولی ساخت مدل پیش‌بینی توسط شبکه عصبی مصنوعی و دومی توسعه روش جدید انتخاب ویژگی می‌باشد.

RReliefF به‌طور گسترده به عنوان یک روش بسیار موثر برای اولویت بندی متغیرهای ورودی از طریق انتخاب ویژگی شناخته شده است. علاوه بر این، این روش یک روش فیلترینگ است و برای چالش‌های رگرسیون استفاده می‌شود. مطالعات قبلی نشان داده‌اند که این روش انتخاب ویژگی را به خوبی انجام می‌دهد. RReliefF یک رویکرد انتخاب ویژگی مرسوم را بکار می‌گیرد که تشابه و عدم تشابه مقادیر پاسخ را در میان همسایگان در نظر می‌گیرد. این رویکرد شامل تخصیص مقادیر متمایز به همسایگانی است که مقادیر پاسخ یکسانی را به اشتراک می‌گذارند و پیش‌بینی‌کننده‌هایی را که مقادیر متفاوتی را به همسایگانی که مقادیر پاسخ متفاوتی از خود نشان می‌دهند، را در نظر می‌گیرد. با این وجود، وقتی نوبت به محاسبه وزن‌های نهایی برای پیش‌بینی‌کننده‌ها در RReliefF می‌رسد، از وزن‌های میانی استفاده می‌شود. این وزن‌های میانی در تعیین وزن‌های نهایی تعیین شده به پیش‌بینی‌کننده‌ها کمک شایانی می‌کنند [۵۴ و ۵۵].

MOEA/D-ANN روش‌های بهینه‌سازی می‌باشد که در مهندسی روسازی در تحقیقات قبلی بطور گسترده‌ای مورد استفاده قرار گرفته‌اند [۵۶]. در مطالعات قبلی عسگری و همکاران [۵۷]، احسانی و همکاران [۵۸، ۵۹]، نشان داده شده که استفاده از ترکیب الگوریتم‌های بهینه‌سازی ابتکاری و روش‌های یادگیری ماشین، پتانسیل قابل توجهی در انتخاب مؤثر ویژگی‌هایی را دارد که بر متغیر خروجی تأثیر می‌گذارند. یکی از الگوریتم‌های بهینه‌سازی ابتکاری چندهدفه قدرتمند MOEA/D است که توسط ژانگ و لی [۶۰] ارائه شده است. این الگوریتم بهینه‌سازی در زمینه‌های مختلف مورد استفاده قرار گرفته و نتایج قابل قبولی را ارائه کرده است. MOEA/D مسئله بهینه‌سازی چند هدفه را به چندین مشکل فرعی تک هدفه تقسیم می‌کند. در مقاله ژانگ و لی [۶۰]، سه روش برای تجزیه توابع هدف ارائه شده است (روش جمع وزنی<sup>۱</sup>، روش بسط چبیشو<sup>۲</sup> و روش تقاطع مرزی<sup>۳</sup>)، اما در این مطالعه، تنها از روش چبیشو استفاده شده است. با استفاده از معادله (۳) تا (۵)، روش چبیشو می‌تواند یک مسئله با ۵ تابع هدف را تجزیه کند.

$$\left\{ \begin{array}{l} \min f_1(x) \\ \min f_2(x) \\ \vdots \\ \min f_n(x) \end{array} \right\} \rightarrow \min g^{te}(x|\theta, u^*, p) = \|f(x) - u^*\|_{\theta, p} \quad (۳)$$

$$\|f(x) - u^*\|_{\theta, p} = \sqrt[p]{\sum_{i=1}^n \theta_i |f_i(x) - u_i^*|^p} \quad (۴)$$

<sup>1</sup> Weighted Sum Approach

<sup>2</sup> Chebyshev Approach

<sup>3</sup> Boundary Intersection

اگر  $p$  به بی نهایت تمایل داشته باشد، می توان آن را به شکل زیر نوشت:

$$\lim_{x \rightarrow \infty} g^{te}(x|\theta, u^*, p) = \max_{1 \leq i \leq n} \theta_i |f_i(x) - u_i^*| \quad (5)$$

که در آن  $x$ ،  $f(x)$ ،  $\theta$  و  $u^*$  به ترتیب متغیرهای تصمیم‌گیری مسئله، تابع هدف، بردار ضرایب وزنی و نقطه مطلوب هستند. به بی نهایت تمایل داشتن  $p$  با استفاده از مراحل زیر پس از بسط دادن رفع می‌شود:

#### الف) آماده سازی

الف-۱) کارایی پارتو<sup>۱</sup> تقریباً برابر با تهی در نظر گرفته می‌شود ( $EP = \emptyset$ ).

الف-۲) بردارهای ضریب وزنی ایجاد شده و پس از محاسبه فاصله بین ضرایب وزنی، همسایگی  $T$  نزدیک هر بردار وزنی مشخص می‌شود.

الف-۳) گروه اولیه ایجاد می‌شود و متعاقباً توابع هدف محاسبه می‌شوند.

الف-۴) به روز کردن نقاط ایده آل مد نظر

ب) به روزرسانی (حلقه اصلی) برای همه اعضای گروه

ب-۱) تکثیر

ب-۲) بهبود بخشیدن راه حل بدست آمده

ب-۳) به روز کردن نقطه ایده آل

ب-۴) به روز رسانی و رقابت با راه حل همسایگان

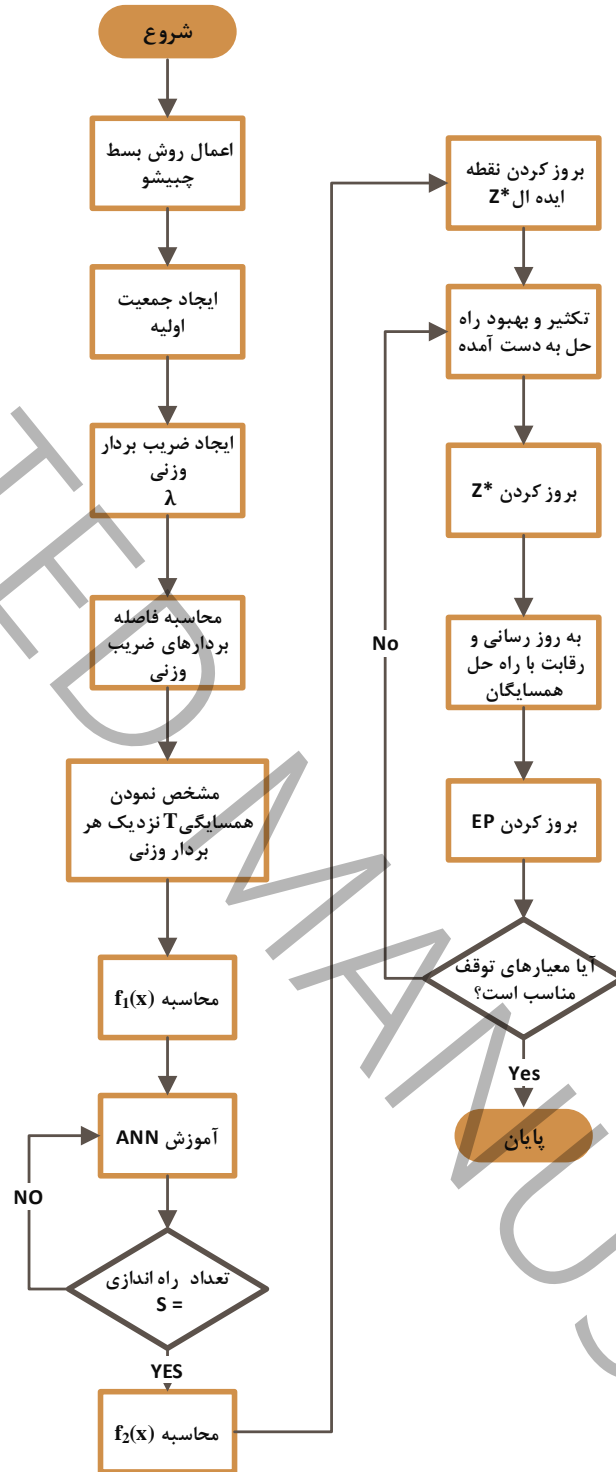
ب-۵) به روز رسانی EP

ج) معیارهای توقف. در صورت عدم رضایت، الگوریتم دوباره از مرحله ۲ اجرا می‌شود.

یک روش انتخاب ویژگی جدید در این مطالعه با استفاده از MOEA/D-ANN توسعه یافته است. در شکل ۲ روند متوالی MOEA/D-ANN را نشان می‌دهد. دو تابع هدف مدنظر قرار گرفته شده است که تابع هدف اول تعداد متغیرهای ورودی انتخاب شده را نشان می‌دهد، در حالی که تابع هدف دوم خطای مدل پیش بینی ANN را نشان می‌دهد. ابتدا یک جمعیت تصادفی ایجاد می‌شود و در هر بردار، تعدادی متغیر ورودی انتخاب می‌شود. تابع هدف اول براساس متغیرهای انتخاب شده محاسبه می‌شود و هر یک از داده‌های جامعه مدنظر با استفاده از ANN تحت آموزش قرار می‌گیرند و میانگین مربعات خطا ( $R^2$ ) برای تعیین مقدار تابع هدف دوم محاسبه می‌شود. MOEA/D برای رسیدن به بهینگی پارتو و حل مسئله انتخاب ویژگی تکرار می‌شود.

<sup>1</sup>Pareto optimal






شکل ۲ فلوجارت الگوریتم MOEA/D-ANN

### ۳- نتایج

#### ۳-۱ نتایج انتخاب ویژگی

در این مطالعه، روش MOEA/D-ANN به عنوان یک روش جدید انتخاب ویژگی معرفی شده است. این روش بهینگی پارتو را ارائه می‌دهد، زیرا یک الگوریتم انتخاب ویژگی چند هدفه است. شکل ۳ نتایج این روش را نشان می‌دهد، که افزایش تعداد متغیرهای ورودی در مجموعه بهینه منجر به کاهش کمتر خطای مدل می‌شود. از این رو، ایجاد تعادل بین خطا و پیچیدگی مدل، که مستقیماً با تعداد متغیرهای ورودی مرتبط است، بسیار مهم است.



شکل ۳ نتایج MOEA/D-ANN

نقاط نشان داده شده در شکل ۳ راه حل‌های غیر غالب هستند، به طوری که نمی‌توان دو تابع هدف در نظر گرفته شود. انتخاب بهترین راه حل بهینه در این نقاط پیچیده است زیرا با مقایسه دو نقطه با یکدیگر، یکی بر اساس یک هدف مشخص و دیگری بر اساس هدف دیگر بهتر عمل می‌کند. برای رفع این مشکل می‌توان از فرآیندهای تصمیم‌گیری چند معیار استفاده کرد. در این تحقیق از روش تحلیل رابطه خاکستری<sup>۱</sup> به عنوان فرآیندی برای تصمیم‌گیری با معیارهای متعدد با هدف شناسایی مطلوب‌ترین و بهینه‌ترین نتیجه استفاده شده است. مراحل تعیین نقطه بهینه در زیر آورده شده است [۴۸].  
در ابتدا، GRA تابع هدف را با معادله (۶) بازه صفر و یک مقیاس می‌کند:

$$s_j^*(q) = \frac{\max a_j(q) - a_j(q)}{\max a_j(q) - \min a_j(q)} \quad (6)$$

که در آن  $a_j(q)$  و  $s_j^*(q)$  به ترتیب مقدار واقعی و مقیاس تابع هدف  $j$ th از نقطه  $q$ th را نشان می‌دهند. ضریب رابطه خاکستری<sup>۲</sup> برای دو تابع هدف با معادله (۷) محاسبه می‌شود.

$$\xi_j(q) = \frac{\Delta_{\min} + \xi \Delta_{\max}}{\Delta_{0j}(q) + \xi \Delta_{\max}} \quad (7)$$

در جایی که  $\xi_j(q)$  نشان دهنده GRC برای تابع هدف  $j$  از نقطه  $q$  ام است،  $\xi$  برابر با ۰/۵ در نظر گرفته می‌شود و  $\Delta_{0j}(q)$  از معادله (۸) تعیین می‌شود.  $\Delta_{\max}$  و  $\Delta_{\min}$  به ترتیب حداقل و حداکثر  $\Delta_{0j}(q)$  هستند.

<sup>1</sup> Grey relational analysis (GRA)

<sup>2</sup> Grey Relational Coefficient (GRC)

$$\Delta_{0j} = \|a_0(q) - s_j^*(q)\| \quad (8)$$

$a_0(q)$  دنباله توالی مرجع است و  $s_j^*(q)$  مقدار مقیاس تابع هدف  $j$  از نقطه  $q_{th}$  است. در نهایت درجه رابطه خاکستری<sup>۱</sup> از طریق معادله (۹) تعیین می‌شود.

$$GRG_j = \frac{1}{n} \sum_{q=1}^n \xi_j(q) \quad (9)$$

GRG با اهمیت داده‌ها رابطه مستقیم دارد و رتبه‌بندی بر این اساس انجام می‌شود. نتایج GRA نشان می‌دهد که این تعداد بهینه متغیرها است که منجر به خطای میانگین مربعات (MSE)<sup>۲</sup> برابر با ۰/۰۰۰۸۵ می‌شود. متغیرهای بهینه انتخاب شده توسط MOEA/D-ANN در جدول ۳ ارائه شده است.

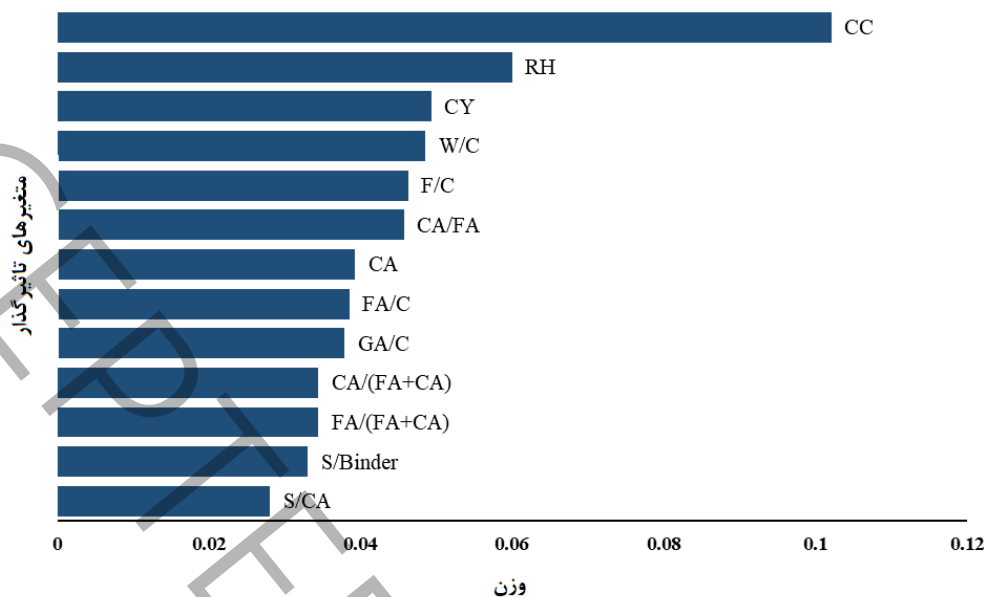
مطالعات قبلی مواد چسبیده، نسبت فوق روان‌کننده به مواد چسبیده، خاکستر بادی به آب، آب به دسته‌های مختلف سنگدانه‌ها (کل سنگدانه‌ها، دانه‌های ریز، دانه‌های درشت) و دانه‌های درشت به دانه‌های ریز را به عنوان متغیرهای ورودی در نظر نگرفته‌اند. با این حال، در اینجا، این نسبت‌ها به عنوان عواملی انتخاب شده‌اند که به طور بالقوه می‌توانند بر عمق کربناته شدن تأثیر بگذارند. از این رو، استفاده از یک روش انتخاب ویژگی قوی برای شناسایی متغیرهای بهینه (به عنوان مثال، MOEA/D-ANN) ضروری است. یکی دیگر از ویژگی‌های انتخاب شده RRelief است که از وزن ویژگی برای شناسایی ویژگی‌های مرتبط در یک مجموعه داده استفاده می‌کند. از آنجایی که تعداد بهینه متغیرها در MOEA/D-ANN، ۱۳ مورد تعیین شده، بنابراین در نتایج بدست‌آمده از روش RRelief تنها ۱۳ متغیر برتر با بیشترین وزن‌ها انتخاب شدند. متغیرهای انتخاب شده در شکل ۴ ارائه شده است. شایان ذکر است که RRelief نسبت‌های فوق روان‌کننده به مواد چسبیده، دانه‌های ریز به کل سنگدانه، سنگدانه درشت به کل سنگدانه، فوق روان‌کننده به سنگدانه درشت، سنگدانه درشت به سیمان، سنگدانه درشت به سنگدانه درشت را شناسایی کرده است. در مطالعات قبلی متغیرهای ریزدانه به سیمان و خاکستر بادی به سیمان در نظر گرفته نشده‌اند. متغیرهایی نظیر سنگدانه درشت، چرخه (روز)، درصد رطوبت نسبی، درصد غلظت CO<sub>2</sub>، نسبت فوق روان‌کننده به مواد چسبیده، نسبت آب به سیمان و سنگدانه درشت به سنگدانه ریز با هر دو روش انتخاب ویژگی شناسایی شدند. همچنین، هر روش متغیرهای منحصر به فردی را انتخاب کرده که برای مدل بصورت متغیر مهمی در نظر گرفته شده، که اکثر ورودی‌های انتخاب شده بصورت نسبت وزنی معرفی می‌شوند.

جدول ۳ عوامل موثر بر عمق کربناته شدن (روش MOEA/D-ANN)

ردیف	مخفف	ردیف	مخفف
۱	F	۸	W/FA
۲	CA	۹	W/CA
۳	Binder	۱۰	CA/FA
۴	S/Binder	۱۱	CY
۵	W/(CA+FA)	۱۲	RH
۶	W/C	۱۳	CC
۷	F/W		

<sup>1</sup> Gray Relational Grade (GRG)

<sup>2</sup> Mean Squared Error



شکل ۴ متغیرهای تاثیرگذار روش RReliefF

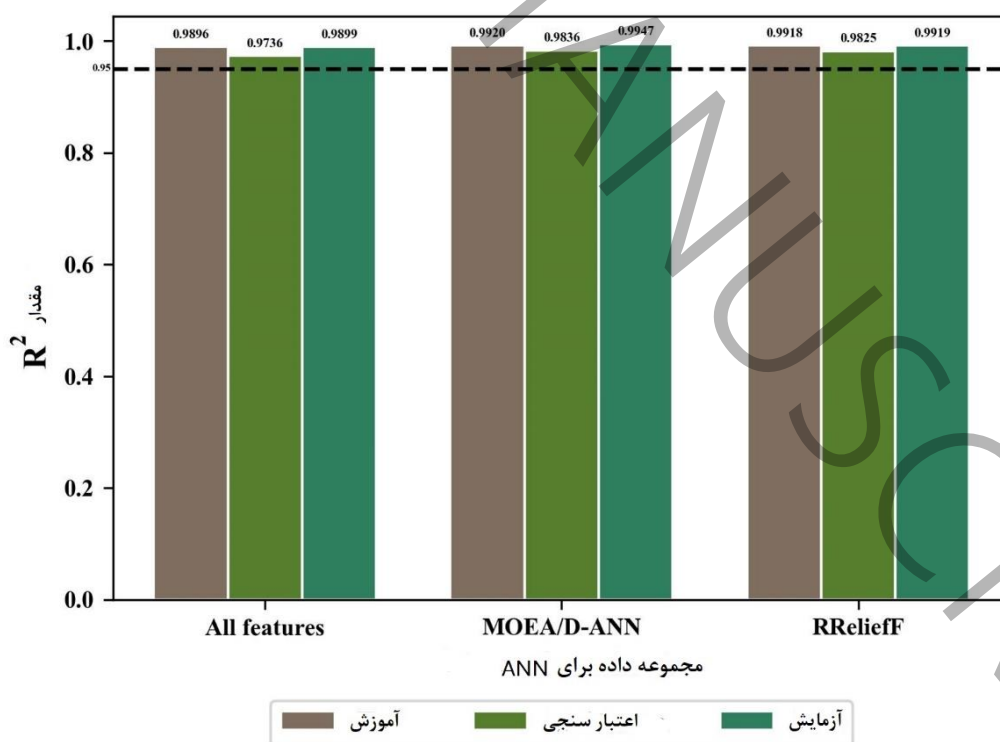
### ۲-۳ تجزیه و تحلیل مدل ANN

شکل ۵ مقدار  $R^2$  را توسط عملکرد ANN را با استفاده از داده های عمومی و MOEA/D-ANN و رویکرد RReliefF در مجموعه داده های آموزشی، اعتبار سنجی و آزمایش نشان می دهد. ANN با استفاده از داده های کلی، دقت پیش بینی خوبی را برای عمق کرناته شدن نشان می دهد و به ضریب تعیین با مقدار ۰/۹۸ دست می یابد. در مقایسه با مدل های مورد استفاده در تحقیقات قبلی، این مدل از دقت بهتری برخوردار بوده است [۴ و ۱۰ و ۱۲ و ۱۵ و ۱۷-۱۸ و ۶۱-۶۲]. خروجی این مدل با استفاده از چندین متغیر ورودی پیش بینی شده بود و جمع آوری دقیق هر یک از ۳۷ متغیر ممکن است چالش برانگیز باشد. در این بین، متغیرهای خاصی در مقایسه با سایر متغیرها تأثیر قوی تری بر عمق کرناته شدن می گذارند. از این رو برخی عوامل ممکن است بدون تأثیر قابل توجهی بر دقت مدل نادیده گرفته شوند. انتخاب ویژگی با استفاده از روش های MOEA/D-ANN و RReliefF انجام شد و نتایج در شکل ۵ نشان داده شده است. همان طور که در جدول ۴ مشاهده می شود، مدل پیشنهادی MOEA/D-ANN با ضریب تعیین ۰/۹۹ و تعداد متغیرهای محدودتر نسبت به برخی تحقیقات پیشین، دقت بسیار بالاتری را در پیش بینی عمق کرناته شدن بتن فراهم کرده است. این نتیجه نشان دهنده کارآمدی روش پیشنهادی در انتخاب دقیق متغیرهای تاثیرگذار و بهبود عملکرد مدل پیش بینی است.

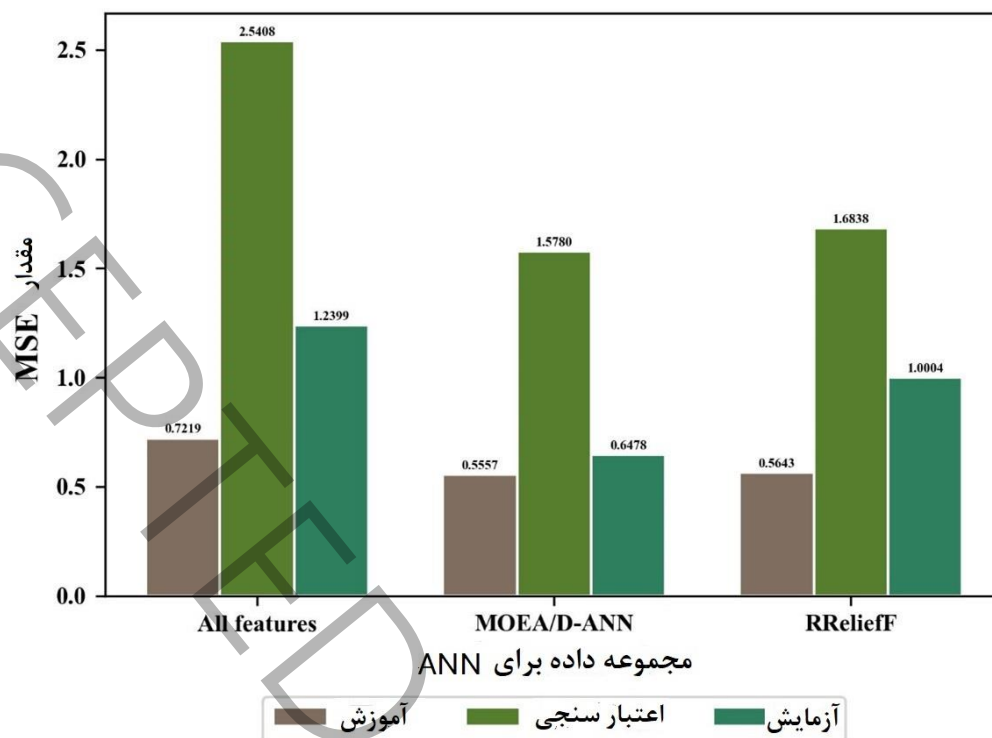
جدول ۴ مقایسه مدل ارائه شده با مدل‌های قبلی از نظر تعداد متغیر و دقت

تعداد متغیرها	ضریب تعیین ( $R^2$ )	محققان	روش مدل‌سازی
۱۲	۰/۹۲	Biswas <i>et al.</i> [۱۳]	SVM
۱۵	۰/۸۸	Zhang <i>et al.</i> [۶۳]	ANN
۸	۰/۹۵	Zhang <i>et al.</i> [۶۴]	Random Forest
۱۱	۰/۹	Kalooop <i>et al.</i> [۶۵]	MLR
۱۰	۰/۹۹	تحقیق حاضر	MOEA/D-ANN + ANN

روش MOEA/D-ANN از دو تابع هدف استفاده می‌کند: یکی برای به حداقل رساندن تعداد متغیرهای ورودی و دیگری برای به حداقل رساندن MSE شکل ۶ نشان می‌دهد، مدلی که از تمام ۳۷ متغیر ورودی استفاده می‌کند دارای MSE بالاتری نسبت به مدل ANN با روش‌های انتخاب ویژگی است. از نتایج می‌توان استنباط کرد که روش MOEA/D-ANN با موفقیت متغیرهایی را که در پیش‌بینی عمق کربناته شدن ضروری نیستند، حذف کرده است که منجر به بهبود عملکرد کلی در مدل ANN در مقایسه با RRelief و استفاده از همه ویژگی‌ها شده است. علاوه بر این، زمان اجرا روش MOEA/D-ANN کمتر از زمان اجرای RRelief با همه ویژگی‌ها می‌باشد. این یافته کارایی محاسباتی MOEA/D-ANN را زمانی که در زمینه ANN اعمال می‌شود، برجسته می‌کند.




شکل ۵ مقادیر  $R^2$  برای مدل ANN



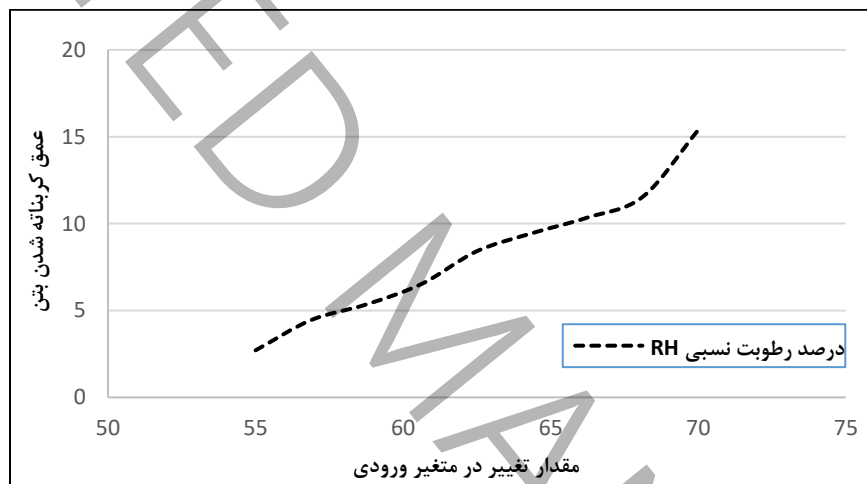
شکل ۶ مقادیر MSE برای مدل ANN

### ۳-۳ تحلیل حساسیت براساس تغییر در مقدار خروجی

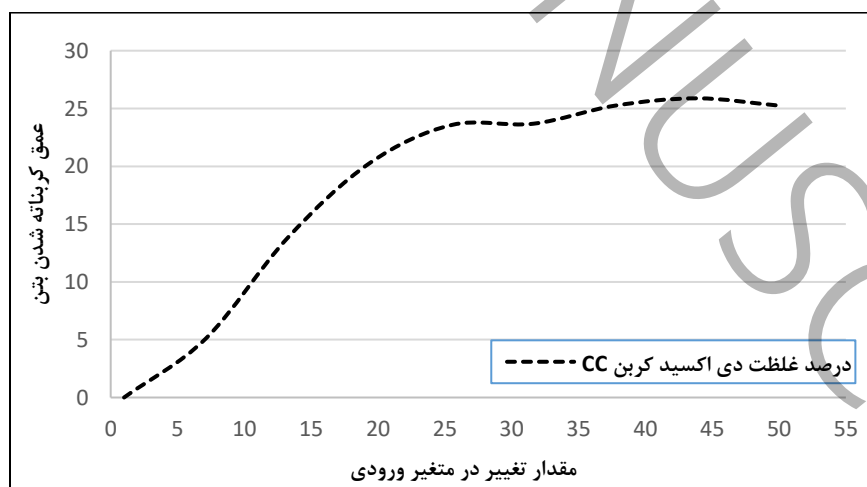
در این تحقیق، تحلیل حساسیت برای بررسی تأثیر متغیرهای ورودی مختلف بر دقت مدل پیش‌بینی عمق کربناته شدن بتن انجام شده است. این تحلیل‌ها نشان دادند که متغیرهایی مانند زمان، درصد رطوبت نسبی و درصد غلظت دی‌اکسید کربن بیشترین تأثیر را بر عمق کربناته شدن بتن دارند. بر اساس نتایج بدست آمده از اشکال ۷ تا ۹ با افزایش متغیرهای ورودی شامل چرخه (روز)، درصد رطوبت نسبی و درصد غلظت دی‌اکسید کربن، مقدار عمق کربناته شدن بتن روند افزایشی را نشان می‌دهد. همچنین با توجه به شکل ۹ می‌توان گفت، مقدار عمق کربناته شدن بتن در اثر افزایش غلظت دی‌اکسید کربن در بازه ۱ تا ۲۵ درصد، روند کاملاً صعودی داشته و پس از آن مقادیر تقریباً ثابت و نزدیک بهم را داده است.



شکل ۷ تحلیل حساسیت بر روی متغیر ورودی چرخه (روز) (CY)



شکل ۸ تحلیل حساسیت بر روی متغیر ورودی درصد رطوبت نسبی (RH)



شکل ۹ تحلیل حساسیت بر روی متغیر ورودی درصد غلظت دی اکسید کربن (CC)

#### ۴- نتیجه گیری

در این تحقیق پیش‌بینی دقیق عمق کربناته شدن بتن مورد بررسی قرار گرفته است که برای محافظت در برابر پیامدهای زیان‌بار مانند ترک خوردگی و خوردگی بسیار حائز اهمیت است. داده‌های مورد استفاده از منابع معتبر متعددی جمع‌آوری شده و در مجموع ۱۹۸ داده عمق کربناته شده و ۳۷ متغیر ورودی بدست آمده است. بیشتر ورودی‌ها براساس نسبت آنها در مخلوط بتن بوده که برای دقت مدل مهم است. برای افزایش دقت مدل و آدرس پیچیدگی محاسباتی، یک روش انتخاب ویژگی جدید، MOEA/D-ANN، معرفی شده است. علاوه بر این، یک رویکرد مرسوم برای انتخاب ویژگی، RRelief، بکار گرفته شده است.

روش MOEA/D-ANN برای شناسایی و حذف متغیرهای اضافی انجام شده، که در نتیجه ۱۳ متغیر باقی‌مانده برای ساخت مدل مورد استفاده قرار گرفته است. علاوه بر این، از روش RRelief برای تعیین اهمیت ورودی‌ها استفاده شده است و ۱۳ ویژگی با بیشترین وزن انتخاب شده‌اند. از روش ANN برای پیش‌بینی عمق کربناته بتن و از روش‌های ترکیبی MOEA/D-ANN و RRelief برای یافتن متغیرهای تأثیرگذار استفاده شده است. نتایج بدست آمده نشان داده‌اند که مدل ایجاد شده با استفاده از رویکرد MOEA/D-ANN، با ترکیب متغیرهای تعیین‌شده توسط آن، کاهش قابل توجهی را در درصد خطاها و افزایش دقت دارد. علاوه بر این، این مدل به مقدار قابل توجه ضریب تعیین  $R^2 = 0.99$  می‌رسد، که بر دقت استثنایی آن در پیش‌بینی عمق کربناته بتن و تأیید انتخاب دقیق متغیرهای تأثیرگذار تأکید می‌کند. نتایج کلیدی را می‌توان به شرح زیر خلاصه نمود:

- در روش GRA، تعداد بهینه ورودی برای MOEA/D-ANN، ۱۳ ورودی با MSE برابر با ۰/۰۰۰۸۵ می‌باشد. متغیرهای ورودی انتخاب شده عبارتند از خاکستر بادی، سنگدانه درشت، ماده چسبنده، چرخه (روز)، درصد رطوبت نسبی، درصد غلظت CO<sub>2</sub> و نسبت فوق روان کننده به ماده چسبنده، نسبت آب به کل سنگدانه، نسبت آب به سیمان، خاکستر بادی به آب، آب به سنگدانه ریز، آب به درشت‌دانه و نسبت درشت‌دانه به ریز دانه. استفاده از این متغیرها برای پیش‌بینی کربناته بتن، بالاترین سطح دقت را می‌دهند.
- براساس روش RRelief، عوامل زیر تعیین‌کننده بودند، که عبارتند از: چرخه (روز)، رطوبت نسبی، غلظت CO<sub>2</sub>، سنگدانه درشت، و نسبت فوق روان کننده به چسب، سنگدانه ریز به کل سنگدانه، سنگدانه درشت به کل سنگدانه، فوق روان کننده به سنگدانه درشت، نسبت آب به سیمان، سنگدانه درشت به سیمان، سنگدانه درشت به سنگدانه ریز، سنگدانه ریز به سیمان و خاکستر بادی به سیمان.
- چارچوب ارائه شده در این پژوهش ظرفیت گسترش به سایر خواص بتن را دارد، امکان توسعه مدل‌های پیش‌بینی برای انواع مختلف خرابی‌های سازه‌ای یا مصالحی که می‌تواند در سازه‌های بتنی ایجاد شود و شناسایی متغیرهایی که بر چنین شکست‌هایی تأثیر می‌گذارند، فراهم می‌کند.

شناسایی پارامترهای حیاتی موثر بر عمق کربناته شده به دلیل دشواری فرآیند و دخالت متغیرهای بسیاری که در آن نقش دارند دارای پیچیدگی زیادی است. لذا از نتایج این تحقیق می‌توان در شناخت رفتار بتن کمک گرفت و عوامل موثر بر آن را برای تحقیقات آتی مد نظر داشت. همچنین نتایج نشان داد که با افزایش نسبت آب به سیمان به میزان ۱۰ درصد، عمق کربناته شدن بتن به میزان ۱۵ درصد افزایش می‌یابد.



# Predicting Concrete Carbonation Depth and Investigating the Influencing Factors through Machine Learning Approaches and Optimization

Shoaib Mansouri, Alireza Rahai, Seyed Hadi Rashedi, Fereydoun Moghaddas Nejad\*<sup>1</sup>

Department of Civil Engineering, Amirkabir University of Technology, Tehran, Iran

## ABSTRACT

Accurate prediction of concrete carbonation depth is crucial for mitigating detrimental effects such as cracking and corrosion. However, due to the complexity of the process and the multitude of variables involved, identifying the most significant parameters for modeling carbonation depth poses a considerable challenge. This paper introduces a hybrid feature selection method known as MOEA/D-ANN. The primary aim of this method is to identify the most critical variables that contribute to achieving the highest prediction accuracy. The proposed approach combines a multi-objective evolutionary optimization algorithm based on decomposition with artificial neural networks to effectively address the feature selection problem using the strengths of optimization and machine learning techniques. To evaluate the performance of the introduced method, the conventional feature ranking algorithm RReliefF was also employed. ANN was used for predicting carbonation depth, while the combined methods of MOEA/D-ANN and RReliefF were utilized to identify influential variables. The results indicate that the model developed using the MOEA/D-ANN approach significantly reduced the error rate and increased accuracy by combining the selected variables. This model achieves a notable coefficient of determination ( $R^2 = 0.99$ ), highlighting its excellent accuracy in predicting concrete carbonation depth and confirming the precise selection of influential variables. Additionally, the results demonstrate that an increase in the water-to-cement ratio by 10% leads to a 15% increase in carbonation depth.

## KEYWORDS

Carbonation depth; prediction; machine learning; artificial neural network; MOEA/D; optimization.

---

\*<sup>1</sup> Corresponding Author: Email: [moghadas@aut.ac.ir](mailto:moghadas@aut.ac.ir)

- [1] H. Naseri, H. Jahanbakhsh, K. Khezri, A.A. Shirzadi Javid, Toward sustainability in optimizing the fly ash concrete mixture ingredients by introducing a new prediction algorithm, *Environment, development and sustainability*, 24(2) (2022) 2767-2803.
- [2] S.O. Ekolu, Model for natural carbonation prediction (NCP): Practical application worldwide to real life functioning concrete structures, *Engineering Structures*, 224 (2020) 111126.
- [3] W.Z. Taffese, E. Sistonen, Machine learning for durability and service-life assessment of reinforced concrete structures: Recent advances and future directions, *Automation in Construction*, 77 (2017) 1-14.
- [4] Y. Kellouche, B. Boukhatem, M. Ghrici, A. Tagnit-Hamou, Exploring the major factors affecting fly-ash concrete carbonation using artificial neural network, *Neural Computing and Applications*, 31 (2019) 969-988.
- [5] H. Xu, Z.Q. Chen, S.B. Li, W. Huang, D. Ma, Carbonation test study on low calcium fly ash concrete, *Applied Mechanics and Materials*, 34 (2010) 327-331.
- [6] A. Rahai, S.H. Rashedi, Evaluation of ductility of bearing concrete wall systems with regard to their boundary element, *Amirkabir Journal of Civil Engineering*, 49(1) (2017) 13-22.
- [7] S.H. Rashedi, A. Rahai, P. Tehrani, Seismic performance evaluation of RC bearing wall structures, *Computers and Concrete*, 30(2) (2022) 113-126.
- [8] I. Nunez, M.L. Nehdi, Machine learning prediction of carbonation depth in recycled aggregate concrete incorporating SCMs, *Construction and Building Materials*, 287 (2021) 123027.
- [9] I.D. Uwanuakwa, Deep learning modelling and generalisation of carbonation depth in fly ash blended concrete, *Arabian Journal for Science and Engineering*, 46(5) (2021) 4731-4746.
- [10] P. Akpınar, I.D. Uwanuakwa, Intelligent prediction of concrete carbonation depth using neural networks, *Bulletin of the Transilvania University of Brasov. Series III: Mathematics and Computer Science*, (2016) 99-108.
- [11] H. Lee, H.-S. Lee, P. Suraneni, Evaluation of carbonation progress using AIJ model, FEM analysis, and machine learning algorithms, *Construction and Building Materials*, 259 (2020) 119703.
- [12] W.Z. Taffese, E. Sistonen, J. Puttonen, CaPrM: Carbonation prediction model for reinforced concrete using machine learning methods, *Construction and Building Materials*, 100 (2015) 70-82.
- [13] R. Biswas, E. Li, N. Zhang, S. Kumar, B. Rai, J. Zhou, Development of hybrid models using metaheuristic optimization techniques to predict the carbonation depth of fly ash concrete, *Construction and Building Materials*, 346 (2022) 128483.
- [14] C. Lu, R. Liu, Predicting carbonation depth of prestressed concrete under different stress states using artificial neural network, *Advances in Artificial Neural Systems*, (2009).
- [15] W.Z. Taffese, F. Al-Neshawy, E. Sistonen, M. Ferreira, Optimized neural network based carbonation prediction model, in: *International Symposium Non-Destructive Testing in Civil Engineering (NDT-CE)*. Berlin, Germany, 2015, pp. 1074-1083.
- [16] E.F. Felix, E. Possan, R. Carrazedo, Analysis of training parameters in the ANN learning process to mapping the concrete carbonation depth, *Journal of building pathology and rehabilitation*, 4(1) (2019) 16.
- [17] P. Akpınar, I. Uwanuakwa, Investigation of the parameters influencing progress of concrete carbonation depth by using artificial neural networks, *Materiales de Construcción*, 70(337) (2020) e209-e209.
- [18] E.F. Felix, R. Carrazedo, E. Possan, Carbonation model for fly ash concrete based on artificial neural network: Development and parametric analysis, *Construction and Building Materials*, 266 (2021) 121050.

- [19] M. Ehsani, M. Ostovari, S. Mansouri, H. Naseri, H. Jahanbakhsh, F.M. Nejad, Machine learning for predicting concrete carbonation depth: A comparative analysis and a novel feature selection, *Construction and Building Materials*, 417 (2024) 135331.
- [20] P.C. Deka, *A primer on machine learning applications in civil engineering*, CRC Press, 2019.
- [21] K. Meshram, *Machine Learning Applications in Civil Engineering*, Elsevier, 2023.
- [22] V. Plevris, A. Ahmad, N.D. Lagaros, *Artificial Intelligence and Machine Learning Techniques for Civil Engineering*, IGI Global, 2023.
- [23] M. Ehsani, H. Naseri, R. Saeedi Nezhad, M. Etebari Ghasbeh, F. Moghadas Nejad, Compressive strength prediction of ordinary concrete, fly ash concrete, and slag concrete by novel techniques and presenting their optimal mixtures, *Amirkabir Journal of Civil Engineering*, 53(10) (2021) 4105-4124.
- [24] N. Roshan, M. Ghale Navi, A. Khosravi, Prediction of concrete compressive strength using machine learning regression algorithms, in: *The 12th National Congress of Civil Engineering*, Tehran, Iran, 2020, in Persian.
- [25] N. Shirzad, M. Taheri, A. Ashrafian, Development of a tree model to predict the depth of carbonation in concrete containing fly ash, in: *7th International Conference on Civil Engineering, Architecture and Urban Planning*, Tehran, Iran, 2022, in Persian.
- [26] H. Hosseinzadeh, A. Hosni, S. Arman, A. Safipour, (2022). Prediction of compressive strength of concrete based on group machine learning, in: *20th Concrete Day Conference and 14th National Concrete Conference*, Tehran, Iran, 2022, in Persian.
- [27] V.Q. Tran, H.V.T. Mai, Q.T. To, M.H. Nguyen, Machine learning approach in investigating carbonation depth of concrete containing Fly ash, *Structural Concrete*, 24(2) (2023) 2145-2169.
- [28] I.D. Uwanuakwa, P. Akpinar, Enhancing the reliability and accuracy of machine learning models for predicting carbonation progress in fly ash-concrete: A multifaceted approach, *Structural Concrete*, (2024).
- [29] H. Ji, H. Ye, Machine learning prediction of corrosion rate of steel in carbonated cementitious mortars, *Cement and Concrete Composites*, 143 (2023) 105256.
- [30] R. Kazemi, A hybrid artificial intelligence approach for modeling the carbonation depth of sustainable concrete containing fly ash, *Scientific Reports*, 14(1) (2024) 11948.
- [31] D. Wang, Q. Tan, Y. Wang, G. Liu, Z. Lu, C. Zhu, B. Sun, Carbonation depth prediction and parameter influential analysis of recycled concrete buildings, *Journal of CO2 Utilization*, 85 (2024) 102877.
- [32] C.D. Atiş, Accelerated carbonation and testing of concrete made with fly ash, *Construction and Building Materials*, 17(3) (2003) 147-152.
- [33] B. Das, S. Pandey, Influence of fineness of fly ash on the carbonation and electrical conductivity of concrete, *Journal of materials in civil engineering*, 23(9) (2011) 1365-1368.
- [34] P. Van den Heede, N. De Belie, A service life based global warming potential for high-volume fly ash concrete exposed to carbonation, *Construction and Building Materials*, 55 (2014) 183-193.
- [35] C.H. Huang, G.L. Geng, Y.S. Lu, G. Bao, Z.R. Lin, Carbonation depth research of concrete with low-volume fly ash, *Applied Mechanics and Materials*, 155 (2012) 984-988.
- [36] L. Jiang, Z. Liu, Y. Ye, Durability of concrete incorporating large volumes of low-quality fly ash, *Cement and concrete research*, 34(8) (2004) 1467-1469.
- [37] J. Khunthongkeaw, S. Tangtermsirikul, T. Leelawat, A study on carbonation depth prediction for fly ash concrete, *Construction and building materials*, 20(9) (2006) 744-753.

- [38] S. Lammertijn, N. De Belie, Porosity, gas permeability, carbonation and their interaction in high-volume fly ash concrete, *Magazine of Concrete Research*, 60(7) (2008) 535-545.
- [39] P. Nath, *Durability of concrete using fly ash as a partial replacement of cement*, Curtin University, 2010.
- [40] P. Nath, P. Sarker, Effect of fly ash on the durability properties of high strength concrete, *Procedia Engineering*, 14 (2011) 1149-1156.
- [41] P. Sulapha, S. Wong, T. Wee, S. Swaddiwudhipong, Carbonation of concrete containing mineral admixtures, *Journal of materials in civil engineering*, 15(2) (2003) 134-143.
- [42] M.K. Rao, D. Kumar, Durability assessment of concrete with class-F fly ash by chloride ion permeability, *International Journal of Recent Technology and Engineering*, 8 (2019) 8831-8836.
- [43] E. Roziere, A. Loukili, F. Cussigh, A performance based approach for durability of concrete exposed to carbonation, *Construction and Building Materials*, 23(1) (2009) 190-199.
- [44] K. Sisomphon, L. Franke, Carbonation rates of concretes containing high volume of pozzolanic materials, *Cement and Concrete Research*, 37(12) (2007) 1647-1653.
- [45] A. Younsi, P. Turcry, E. Rozière, A. Aït-Mokhtar, A. Loukili, Performance-based design and carbonation of concrete with high fly ash content, *Cement and Concrete Composites*, 33(10) (2011) 993-1000.
- [46] P. Zhang, Q. Li, Effect of fly ash on durability of high performance concrete composites, *Research Journal of Applied Sciences, Engineering and Technology*, 6(1) (2013) 7-12.
- [47] A. Behnood, V. Behnood, M.M. Gharehveran, K.E. Alyamac, Prediction of the compressive strength of normal and high-performance concretes using M5P model tree algorithm, *Construction and Building Materials*, 142 (2017) 199-207.
- [48] S. Ghavami, H. Naseri, H. Jahanbakhsh, F.M. Nejad, The impacts of nano-SiO<sub>2</sub> and silica fume on cement kiln dust treated soil as a sustainable cement-free stabilizer, *Construction and Building Materials*, 285 (2021) 122918.
- [49] S. Ghafari, M. Ehsani, F.M. Nejad, Prediction of low-temperature fracture resistance curves of unmodified and crumb rubber modified hot mix asphalt mixtures using a machine learning approach, *Construction and Building Materials*, 314 (2022) 125332.
- [50] A.A. Shirzadi Javid, H. Naseri, M.A. Etebari Ghasbeh, Estimating the optimal mixture design of concrete pavements using a numerical method and meta-heuristic algorithms, *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 45(2) (2021) 913-927.
- [51] S. Ranjbar, F.M. Nejad, H. Zakeri, A.H. Gandomi, Computational intelligence for modeling of asphalt pavement surface distress, in: *New Materials in Civil Engineering*, Elsevier, 2020, pp. 79-116.
- [52] S. Haykin, *Neural networks: a comprehensive foundation*, Prentice Hall PTR, 1998.
- [53] I.N. Da Silva, D. Hernane Spatti, R. Andrade Flauzino, L.H.B. Liboni, S.F. dos Reis Alves, I.N. da Silva, D. Hernane Spatti, R. Andrade Flauzino, L.H.B. Liboni, S.F. dos Reis Alves, *Artificial neural network architectures and training processes*, Springer, 2017.
- [54] M. Robnik-Šikonja, I. Kononenko, Theoretical and empirical analysis of ReliefF and RReliefF, *Machine learning*, 53 (2003) 23-69.
- [55] M.V. Selvi, S. Mishra, Input features selection using rrelieff algorithm for electricity demand forecasting, in: *2020 IEEE First International Conference on Smart Technologies for Power, Energy and Control (STPEC)*, IEEE, 2020, pp. 1-6.

- [56] S. Ghafari, S. Ranjbar, M. Ehsani, F.M. Nejad, P. Paul, Sustainable crumb rubber modified asphalt mixtures based on low-temperature crack propagation characteristics using the response surface methodology, *Theoretical and Applied Fracture Mechanics*, 123 (2023) 103718.
- [57] A. Askari, P. Hajikarimi, M. Ehsani, F. Moghadas Nejad, Prediction of rutting deterioration in flexible pavements using artificial neural network and genetic algorithm, *Amirkabir Journal of Civil Engineering*, 54(9) (2022) 3581-3602.
- [58] M. Ehsani, F. Moghadas Nejad, P. Hajikarimi, Developing an optimized faulting prediction model in Jointed Plain Concrete Pavement using artificial neural networks and random forest methods, *International journal of pavement engineering*, 24(2) (2023) 2057975.
- [59] M. Ehsani, P. Hamidian, P. Hajikarimi, F.M. Nejad, Optimized prediction models for faulting failure of Jointed Plain concrete pavement using the metaheuristic optimization algorithms, *Construction and Building Materials*, 364 (2023) 129948.
- [60] Q. Zhang, H. Li, MOEA/D: A multiobjective evolutionary algorithm based on decomposition, *IEEE Transactions on evolutionary computation*, 11(6) (2007) 712-731.
- [61] Z. Chen, J. Lin, K. Sagoe-Crentsil, W. Duan, Development of hybrid machine learning-based carbonation models with weighting function, *Construction and Building Materials*, 321 (2022) 126359.
- [62] K. Liu, M.S. Alam, J. Zhu, J. Zheng, L. Chi, Prediction of carbonation depth for recycled aggregate concrete using ANN hybridized with swarm intelligence algorithms, *Construction and Building Materials*, 301 (2021) 124382.
- [63] M. Zhang, L. Jiao, W. Ma, J. Ma, M. Gong, Multi-objective evolutionary fuzzy clustering for image segmentation with MOEA/D, *Applied Soft Computing*, 48 (2016) 621-637.
- [64] J. Zhang, G. Ma, Y. Huang, F. Aslani, B. Nener, Modelling uniaxial compressive strength of lightweight self-compacting concrete using random forest regression, *Construction and Building Materials*, 210 (2019) 713-719.
- [65] M.R. Kaloop, D. Kumar, P. Samui, J.W. Hu, D. Kim, Compressive strength prediction of high-performance concrete using gradient tree boosting machine, *Construction and Building Materials*, 264 (2020) 120198.