



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

Shoab Mansouri, Alireza Rahai ¹, Seyed Hadi Rashedi ², Fereydoun Moghaddas Nejad * ³

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.

Review History:

Received: Feb. 06, 2024
Revised: Oct. 14, 2024
Accepted: Nov. 03, 2024
Available Online: Nov. 19, 2024

Keywords:

Carbonation Depth
Prediction
Machine Learning
Artificial Neural Network
MOEA/D; Optimization

1- Introduction

Concrete is the most commonly used material in various construction, industrial, and civil projects, such as building construction, transportation infrastructure, water protection, and port structures. One critical factor in evaluating concrete performance is its durability, essential for maintaining the integrity and safety of reinforced concrete structures throughout their lifespan [1-3]. Several factors influence concrete durability, with carbonation as a significant issue due to CO₂ diffusion into concrete pores [4-6].

Several studies have utilized ANN models for carbonation depth prediction. These models have been trained on diverse variables, including cement type, water-to-binder ratio, fly ash content, aggregate size, and environmental conditions. Studies demonstrate that optimizing ANN hidden neuron counts can enhance accuracy [7-9].

Feature selection methods, like the MOEA/D-ANN hybrid algorithm, improve ML model performance by identifying relevant features, reducing overfitting, and enhancing interpretability, especially with large datasets [10]. The MOEA/D-ANN model used in this study combines heuristic optimization with ANN to predict carbonation depth

by analyzing significant factors like time, relative humidity, and CO₂ concentration, achieving high accuracy in prediction.

2- Methodology

The study collected 198 data samples from previous research [11-17], covering various material weight ratios like water-to-binder, fine aggregate, and superplasticizer, which are key for concrete property prediction. Selected ratios include water-to-cement, coarse aggregate-to-binder [18], and fly ash-to-cement ratios, which aid in estimating carbonation depth [19].

In this study, 37 input variables from 9 main factors, like water-to-cement and aggregate ratios, were used to predict carbonation depth, with feature selection improving model accuracy. Table 1 shows descriptive statistics for material weights, covering mean, standard deviation, minimum, and maximum values for key variables.

A new feature selection method, MOEA/D-ANN, was developed in this study. It involves two objectives: the first measures the number of selected input variables, and the second evaluates the ANN model's prediction error. A random population is created, and input variables are selected

*Corresponding author's email: moghadas@aut.ac.ir



Table 1. Descriptive statistics of variables

| Variable | Abbrv. | Min | Max | Mean | Std Dev |
|---------------------------------------|--------|-------|------|-------|---------|
| Cement (kg/m ³) | C | 120 | 494 | 263.2 | 79.2 |
| Fly Ash (kg/m ³) | F | 0 | 280 | 100.2 | 80.3 |
| Coarse Aggregate (kg/m ³) | CA | 501.8 | 1071 | 691.9 | 157.6 |
| Fine Aggregate (kg/m ³) | FA | 790 | 1258 | 1061 | 114.3 |
| Water (kg/m ³) | W | 112 | 220 | 165 | 12 |
| Superplasticizer (kg/m ³) | S | 0 | 7.7 | 0.7 | 1.7 |
| Cycle (days) | CY | 3 | 126 | 39.6 | 32.2 |
| Relative Humidity (%) | RH | 55 | 70 | 64.6 | 4.7 |
| CO ₂ Concentration (%) | CC | 1 | 50 | 10.3 | 12.7 |
| Carbonation Depth (mm) | CD | 0 | 57 | 9.9 | 10.2 |

for each vector. The first objective is calculated based on the selected variables, and the second objective is determined using the mean squared error (R^2) of the ANN. MOEA/D iterates to achieve Pareto efficiency in solving the feature selection problem.

3- Results and discussion

Previous studies often overlooked specific input ratios, such as superplasticizer-to-binder, fly ash-to-water, and water-to-aggregate, which this study includes to potentially impact carbonation depth. MOEA/D-ANN was used to identify optimal variables, while the RReliefF method selected 13 top features based on weight. Both methods highlighted shared and unique variables, with most inputs represented as weight ratios.

ANN using general data achieved 98% accuracy for carbonation depth prediction, outperforming previous models. By selecting relevant features with MOEA/D-ANN and RReliefF, the model improved prediction performance, reaching an R^2 of 0.99 with fewer input variables.

A sensitivity analysis was performed to assess how input variables affect concrete carbonation depth prediction accuracy. Time, relative humidity, and carbon dioxide concentration were found to have the most significant impact. According to the results in Figures 1 to 3, as these variables (cycle days, relative humidity, and CO₂ concentration) increased, carbonation depth also increased. Notably, the depth rises with CO₂ concentration from 1% to 25%, then stabilizes at nearly constant levels.

4- Conclusions

This study aims to accurately predict concrete carbonation depth, essential for preventing cracks and corrosion. Data




Fig. 1. Sensitivity analysis on the input variable cycle (days) (CY)

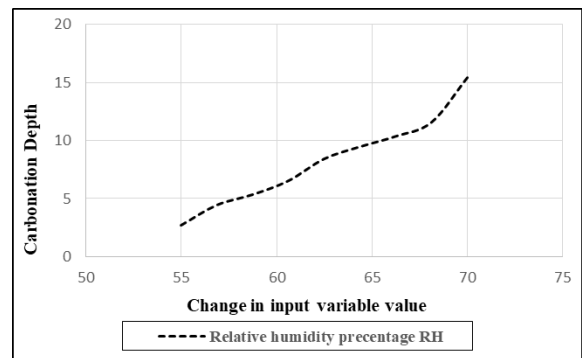


Fig. 2. Sensitivity analysis on the input variable relative humidity percentage (RH)

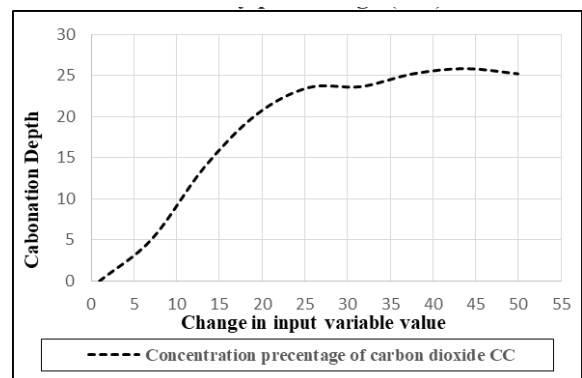



Fig. 3. Sensitivity analysis on the input variable carbon dioxide concentration percentage (CC)

from multiple sources led to 198 carbonation depth samples and 37 input variables, with the most significant ones related to concrete mix ratios. A new feature selection method, MOEA/D-ANN, was introduced to improve accuracy and address computational complexity, alongside the conventional RReliefF method. After removing redundant variables, 13 remained, leading to a model with an R^2 value of 0.99, highlighting its high accuracy. The results showed that key variables like cycle, humidity, CO₂ concentration, and mix ratios significantly affect carbonation depth. This model's framework can be extended to other concrete properties and structural failure predictions.

References

- [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] 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.
- [3] S.H. Rashedi, A. Rahai, P. Tehrani, Seismic performance evaluation of RC bearing wall structures, *Computers, and Concrete*, 30(2) (2022) 113-126.
- [4] S.O. Ekolu, Model for natural carbonation prediction (NCP): Practical application worldwide to real life functioning concrete structures, *Engineering Structures*, 224 (2020) 111126.
- [5] 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.
- [6] 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.
- [7] 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.
- [8] C. Lu, R. Liu, Predicting carbonation depth of prestressed concrete under different stress states using artificial neural network, *Advances in Artificial Neural Systems*, (2009).
- [9] 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.
- [10] P. Akpinar, 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.
- [11] R. Kazemi, A hybrid artificial intelligence approach for modeling the carbonation depth of sustainable concrete containing fly ash, *Scientific Reports*, 14(1) (2024) 11948.
- [12] 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.
- [13] 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.
- [14] 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.
- [15] 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.
- [16] 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.
- [17] K. Sisomphon, L. Franke, Carbonation rates of concretes containing high volume of pozzolanic materials, *Cement and Concrete Research*, 37(12) (2007) 1647-1653.
- [18] A. Younsi, P. Turcry, E. Rozière, A. Aît-Mokhtar, A. Loukili, Performance-based design and carbonation of concrete with high fly ash content, *Cement and Concrete Composites*, 33(10) (2011) 993-1000.
- [19] 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.



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

شعب منصور، علیرضا رهایی^{1b}، سیدهادی راشدی^{1b}، فریدون مقدس‌نژاد^{1b*}

دانشکده عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران.

تاریخچه داوری:

دریافت: ۱۴۰۲/۱۱/۱۷
بازنگری: ۱۴۰۳/۰۷/۲۳
پذیرش: ۱۴۰۳/۰۸/۱۳
ارائه آنلاین: ۱۴۰۳/۰۸/۲۹

کلمات کلیدی:

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

خلاصه: پیش‌بینی دقیق عمق کربناته شدن بتن برای محافظت در برابر پیامدهای زیان‌بار مانند ترک خوردگی 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 هابیرید (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 را با شبکه‌های عصبی مصنوعی 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 (RRelief) که یک الگوریتم رتبه بندی ویژگی است، نیز بهره گرفته شده است. 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 داده اند 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.

۱- مقدمه

مانند پوسته شدن و ترک می‌شود [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 می‌شود و منجر به کاهش طول عمر سازه می‌شود [۵-۷]. 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 اندازه‌گیری عمق کربناته شده بتن^۱ وجود دارد، درحالی که روش‌های سنتی پرهزینه، زمان‌بر و تا حد زیادی مخرب هستند [۹]. همچنین اطلاعات محدودی در مورد اثر این عوامل موثر بر عمق کربناته شدن موجود می‌باشد [۱۰]. از این رو، قابلیت پیش‌بینی دقیق پیشرفت کربناته شدن از طریق مدل‌های قابل اعتماد می‌تواند نقش مهمی در جلوگیری از آسیب‌های آینده و افزایش اقدامات ایمنی و به تبع آن حداقل رساندن خسارات اقتصادی

بتن متداول‌ترین مصالح مورد استفاده در پروژه‌های مختلف ساختمانی، صنعتی و عمرانی از جمله ساخت و ساز ساختمان، حمل و نقل، حفاظت از آب و سازه‌های بنادر است. یکی از عناصر مهم در ارزیابی عملکرد بتن دوام آن است. دوام بتن نقش مهمی را در حفظ عملکرد و ایمنی سازه‌های بتن مسلح در طول عمر مفید آنها دارد [۱]. عوامل متعددی بر دوام بتن تأثیر می‌گذارند. کربناته شدن یکی از مشکلات متداول است که در نتیجه انتشار دی‌اکسید کربن (CO_2) در محیط اتفاق می‌افتد [۲]. کربناته شدن زمانی اتفاق می‌افتد که دی‌اکسید 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 (C_3CO_3) و در نتیجه منجر به کاهش PH به حدود عدد ۹ می‌شود [۴]. ناحیه کربناته در سازه‌های بتنی می‌تواند باعث خوردگی آرماتورهای فولادی شود که منجر به آسیب‌های فیزیکی

1 Carbonation Depth (CD)

* نویسنده عهده‌دار مکاتبات: moghadas@aut.ac.ir



افزودنی، شرایط نوردی، میزان CO₂ 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 لوبنرگ-مارکواریت⁴ موثرترین روش آموزش از نظر کارایی است. مطالعات انجام شده توسط کلوش و همکاران [۴]، آکپینار و اووانوکوا [۱۷]، و فلیکس و همکاران [۱۸] تأثیر قابل توجه استفاده از ANN را برای تجزیه و تحلیل تأثیر ویژگی‌ها بر روی عمق کرناته شدن در بتن مخلوط شده با خاکستر بادی نشان داده‌اند. به طور خاص، این مطالعات نشان داده‌اند که تغییرات در محتوای سیمان و خاکستر بادی، نسبت آب به مواد چسبیده، غلظت CO₂، رطوبت نسبی و دما می‌تواند منجر به تغییرات قابل توجهی در عمق کرناته شدن شود. شایان ذکر است که کار آکپینار و اووانوکوا [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 کرناته 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^۵ 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

ایفا کند [۱۰]. پیش‌بینی دقیق کرناته شدن در بتن مسلح در افزایش دوام و ایمنی [۱۱] و همچنین در تصمیم‌گیری آگاهانه در مورد استراتژی‌های تعمیر و نگهداری برای چنین سازه‌هایی از اهمیت بالایی برخوردار است [۱۲]. بنابراین، پیش‌بینی دقیق عمق کرناته شده چالش بزرگی می‌باشد. برای این منظور، مدل‌های مبتنی بر یادگیری ماشین (ML) را می‌توان برای یادگیری رفتار پیچیده کرناته شدن با استفاده از داده‌های تجربی به کار گرفت [۱۳]. مدل‌های ML مختلفی برای این منظور به کار گرفته شده‌اند و از میان آنها، مدل‌های شبکه عصبی مصنوعی (ANN) به طور مکرر انتخاب و به طور گسترده مورد استفاده قرار گرفته‌اند [۲۳-۲۴ و ۲۶].

به این ترتیب، لو و لیو [۱۴] دو مدل ANN را برای تخمین عمق کرناته شدن در بتن پیش‌تئیده معرفی کردند: یکی بر اساس پس انتشار^۱ و دیگری با استفاده از توابع پایه شعاعی^۲. برای پیش‌بینی عمق کرناته شدن، سطح تنش در بتن، سن آزمایش، نسبت سیمان به سنگدانه ریز و سنگدانه درشت، و نسبت آب به سیمان به عنوان ویژگی‌ها (یعنی متغیرها) در نظر گرفته شدند [۲۵ و ۲۷-۳۱]. یک شبکه عصبی (NN) برای تخمین عمق کرناته 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، سنگدانه‌های با اندازه‌های کمتر از ۰/۱۲۵، ۰/۲۵ و ۴ میلی‌متر، روان کننده، ماده هوازا و مدت زمان کرناته شدن به عنوان متغیرهای مستقل در نظر گرفتند. این محققین از روش‌های انتخاب متغیر، به‌ویژه انتخاب ویژگی‌های^۳ متوالی، برای تعیین مناسب‌ترین ویژگی‌ها و حذف هرگونه ویژگی نامربوط یا اضافی از مجموعه داده ورودی اصلی مورد استفاده در آزمایش‌های خود استفاده کردند.

همچنین آکپینر و اووانوکوا [۱۰] از ANN برای پیش‌بینی عمق کرناته شده استفاده کردند، که در آن با استفاده از ۱۸ متغیر ورودی طبقه‌بندی شده در شش گروه به ترتیب: ترکیب سیمان، ترکیب خاکستر بادی، پارامترهای طرح اختلاط، شرایط عمل‌آوری 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 کرناته 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

- 1 Backpropagation
- 2 Radial Basis Function kernel (RBF)
- 3 Feature selection

4 Levenberg-Marquardt(LM)
5 Feature Selection

۲- روش تحقیق

۲-۱- جمع آوری داده ها

داده‌های مورد استفاده در این پژوهش از مطالعات انجام شده توسط محققان قبلی استخراج شده [۴-۵ و ۳۲-۴۶] که در نهایت، ۱۹۸ داده جمع آوری شده است. داده‌های استخراج شده، اطلاعات وزن مواد را در نسبت‌های اختلاط مختلف نشان می‌دهد. نسبت‌های وزنی مواد، مانند نسبت‌های آب به مواد چسبنده، سنگدانه‌های ریز و فوق روان‌کننده، معمولاً متغیرهای ورودی برای پیش‌بینی ویژگی‌های بتن در نظر گرفته می‌شوند [۱]. با این حال، مشخص نیست که کدام نسبت وزن مواد می‌تواند عملکرد مدل‌های پیش‌بینی را بهبود بخشد. به این ترتیب، نسبت آب به سیمان، نسبت سنگدانه درشت به مواد چسبنده، نسبت فوق روان‌کننده به سیمان، از جمله نسبت‌های بهبود و همکاران بودند که در تحقیقات قبلی استفاده شده اند [۴۷]. در حالی که برخی نسبت‌های دیگر برای تخمین عمق کرناتنه شدن بتن، مانند نسبت‌های خاکستر بادی - سیمان، آب، چسب و فوق روان‌کننده - چسب توسط قوامی و همکاران استفاده شده است [۴۸].

در مطالعات مرتبط با استفاده از مدل‌های یادگیری ماشین و روش‌های بهینه‌سازی برای پیش‌بینی رفتار مواد مختلف، تعداد داده‌های ورودی متغیر بوده است. جدول ۱ تعداد داده‌های استفاده شده در برخی از تحقیقات مشابه را نشان می‌دهد:

با توجه به منابع معتبر و کتب علمی [۲۰-۲۲]، تعداد داده‌های ورودی توصیه شده برای مدل‌های پیش‌بینی مواد معمولاً بین ۲۰۰ تا ۱۰۰۰ نمونه می‌باشد. با توجه به تعداد داده‌های استفاده شده در تحقیقات مختلف و

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 هابیرید (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 کرناتنه 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 کرناتنه 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 RReliefF و MOEA/D 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 ورودی کلیدی در طرح اختلاط بتن می‌باشد. این پارامترها شامل زمان، درصد رطوبت نسبی و درصد غلظت دی‌اکسید کربن هستند. این متغیرها به عنوان عوامل مؤثر بر مقدار عمق کرناتنه شدن بتن انتخاب شده‌اند و نقش بسیار مهمی در پیش‌بینی دقیق این عمق دارند.

جدول ۱. بررسی تعداد داده‌های ورودی در تحقیقات مشابه

Table 1. Examining the number of input data in similar research

| تعداد داده‌های مورد استفاده در تحقیق | تحقیق انجام شده |
|--------------------------------------|---------------------------|
| ۱۰۳۰ | پیش‌بینی مقاومت فشاری بتن |
| ۱۸۹ | پیش‌بینی دوام بتن |
| ۴۲۵ | برآورد مقاومت بتن |
| ۵۰۰ | پیش‌بینی خوردگی فولاد |
| ۳۰۰ | پیش‌بینی عمر خستگی مواد |

سنگدانه ریز به کل سنگدانه، آب به کل سنگدانه، فوق روان کننده به کل سنگدانه، فوق روان کننده به سیمان، فوق روان کننده به سنگدانه 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 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_2 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.

توصیه‌های علمی، تعداد ۱۹۸ نمونه داده‌ای که در این مطالعه استفاده شده است، در محدوده قابل قبول برای پیش‌بینی رفتار بتن قرار دارد. این تعداد داده‌ها توانسته است به ما در دستیابی به مدل دقیق و قابل اطمینانی برای پیش‌بینی عمق کربناته شدن بتن کمک کند.

در تحقیق حاضر، ۹ متغیر اصلی وجود داشته است که بر اساس آن‌ها ۳۷ متغیر ورودی، نظیر نسبت آب به سیمان و سایر موارد، تعریف شده‌اند. سپس با استفاده از روش انتخاب ویژگی (Feature Selection)، متغیرهای تأثیرگذار انتخاب شدند، که این امر به افزایش دقت مدل منجر گردید. برای پرداختن به این موضوع مهم، تمام نسبت‌های وزن مواد در مجموعه داده اولیه گنجانده شده‌اند. متغیرهای ورودی مورد استفاده در این مطالعه شامل آب، سیمان، فوق روان‌کننده، خاکستر بادی، سنگدانه‌های ریز و درشت، کل سنگدانه (بر حسب کیلوگرم بر متر مکعب)، و همچنین نسبت‌های این متغیر که به‌صورت زیر آمده است: سیمان به مواد چسباننده، خاکستر بادی به مواد چسباننده، سنگدانه درشت به مواد چسباننده، سنگدانه ریز به مواد چسباننده، آب به مواد چسباننده، فوق روان‌کننده به مواد چسباننده، سیمان به کل سنگدانه، خاکستر بادی به کل سنگدانه، سنگدانه درشت به کل سنگدانه،

جدول ۲. آمار توصیفی متغیرها

Table 2. Descriptive statistics of variables

| متغیرها | مخفف | میانگین | انحراف معیار | حداقل | حداکثر |
|--------------------------------|------|---------|--------------|-------|--------|
| متغیرهای ورودی اصلی | | | | | |
| سیمان (kg/m^3) | C | ۲۶۳/۲ | ۷۹/۲ | ۱۲۰ | ۴۹۴ |
| خاکستر بادی (kg/m^3) | F | ۱۰۰/۲ | ۸۰/۳ | ۰ | ۲۸۰ |
| سنگدانه درشت (kg/m^3) | CA | ۶۹۱/۹ | ۱۵۷/۶ | ۵۰۱/۸ | ۱۰۷۱ |
| سنگدانه ریز (kg/m^3) | FA | ۱۰۶۱/۶ | ۱۱۴/۳ | ۷۹۰ | ۱۲۵۸ |
| آب (kg/m^3) | W | ۱۶۵ | ۱۲ | ۱۱۲ | ۲۲۰ |
| فوق روان‌کننده (kg/m^3) | 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_2 | CC | ۱۰/۳ | ۱۲/۷ | ۱ | ۵۰ |
| متغیر خروجی | | | | | |
| 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 ۵۰/۱/۸ و ۱۰۷/۱ 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 غبرواقعی اهمیت فوق‌روان‌کننده 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 ، j ، j_{\min} و j_{\max} به ترتیب مقدار مقیاس شده، مقدار اصلی و مقدار حداقل و حداکثر داده‌های متغیر مربوطه را به ترتیب نشان می‌دهند. پس از مرحله پیش‌پردازش، مجموعه داده به صورت تصادفی به دو گروه مجزا تقسیم شد: مجموعه‌ی آموزش، که ۸۵ درصد از داده‌ها را تشکیل می‌دهد و داده‌های آزمون، شامل ۱۵ درصد باقی مانده است. داده‌های اعتبارسنجی برای تنظیم دقیق هاینپارامترها در مدل‌های مختلف ML استفاده شده‌اند. به عبارت دیگر، در طول هر تکرار، توزیع داده‌ها به شرح زیر است: ۷۰٪ برای آموزش، ۱۵٪ برای آزمایش و ۱۵٪ دیگر برای اعتبارسنجی.

۲-۳- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی (ANN) عملکرد مغز انسان را تکرار می‌کند و به عنوان یک ابزار قوی برای تجزیه و تحلیل داده‌ها مورد استفاده قرار می‌گیرد و آنها را در زمینه یادگیری ماشین (ML) بسیار موثر می‌کند [۵۱]. مشابه شبکه‌های عصبی بیولوژیکی، ANN از واحدهای پردازش توزیع شده و موازی، شبیه نرون‌ها تشکیل شده‌اند. یکی از مزیت‌های قابل توجه این شبکه‌ها ظرفیت آنها برای مدل‌سازی مسائل پیچیده و غیرخطی بدون

توجه به عوامل موثر بر آنها است [۱۶]. شبکه عصبی مصنوعی به عنوان یک روش مدل‌سازی غیرخطی و به عنوان یک روش قوی برای ایجاد ارتباطات بین متغیرهای ورودی و خروجی شناخته شده است [۵۲]. شبکه‌های عصبی مصنوعی به طور کلی از سه لایه تشکیل شده‌اند: (۱) لایه ورودی از ویژگی‌های ورودی تشکیل شده است، (۲) لایه‌های (های) پنهان که می‌تواند شامل چندین لایه باشد که عملیات پیچیده غیرخطی را انجام می‌دهد (۳) لایه خروجی که متغیر خروجی را ذخیره می‌کند [۵۳]. شکل ۱ پیکربندی یک شبکه عصبی مصنوعی و ارتباطات بین لایه‌های ورودی، لایه‌های (های) پنهان و لایه خروجی را نشان می‌دهد.


معادله (۲) نحوه پیش‌بینی متغیر وابسته در ساختار شبکه عصبی مصنوعی را نشان می‌دهد.

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

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

با توجه به اینکه در این روش احتمال برآزش کردن بیش از حد داده‌ها وجود دارد، نویسندگان ۱۵ درصد از داده‌ها را به اعتبارسنجی 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 برآزش 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 اولویت‌بندی 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



شکل ۱. ساختار شبکه عصبی مصنوعی

Fig. 1. Structure of artificial neural network

(روش جمع وزنی^۱، روش بسط چیشو^۲ و روش تقاطع مرزی^۳)، اما در این مطالعه، تنها از روش چیشو استفاده شده است. با استفاده از معادله (۳) تا (۵)، روش چیشو می‌تواند یک مسئله با ۵ تابع هدف را تجزیه کند.

$$\left\{ \begin{array}{l} \min f_1(x) \\ \min f_2(x) \\ \vdots \\ \min f_n(x) \end{array} \right\} \rightarrow \min g^{te}(x | \theta, u^*, p) = \quad (3)$$

$$\|f(x) - u^*\|_{\theta, p}$$

$$\|f(x) - u^*\|_{\theta, p} = \sqrt[p]{\sum_{i=1}^n \theta_i |f_i(x) - u_i^*|^p} \quad (4)$$

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 RRelief می‌رسد، از وزن‌های میانی استفاده می‌شود. این وزن‌های میانی در تعیین وزن‌های نهایی تعیین شده به پیش‌بینی‌کننده‌ها کمک شایانی می‌کنند [۵۴ و ۵۵].

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

- 1 Weighted Sum Approach
- 2 Chebyshev Approach
- 3 Boundary Intersection

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

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

که در آن θ ، $f(x)$ 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 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

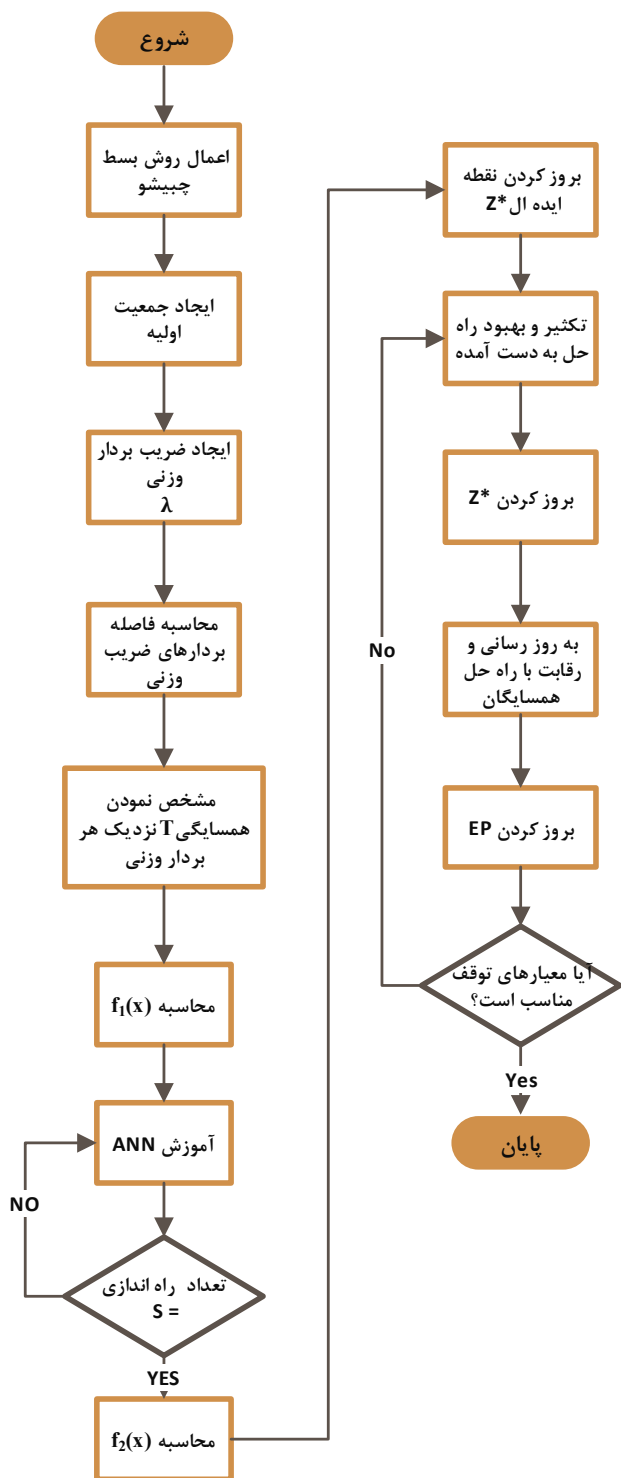
ب) به روزرسانی (حلقه اصلی) برای همه اعضای گروه

- 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



شکل ۲. فلوجارت الگوریتم MOEA/D-ANN

Fig. 2. MOEA/D-ANN algorithm flowchart



شکل ۳. نتایج MOEA/D-ANN

Fig. 3. MOEA/D-ANN results

هدف مشخص و دیگری براساس هدف دیگر بهتر عمل می کند. برای رفع این مشکل می توان از فرآیندهای تصمیم گیری چند معیار استفاده کرد. در این تحقیق از روش تحلیل رابطه خاکستری^۱ به عنوان فرآیندی برای تصمیم گیری با معیارهای متعدد با هدف شناسایی مطلوب ترین و بهینه ترین 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 می کند:

$$s_j^*(q) = \frac{\max a_j(q) - a_j(q)}{\max a_j(q) - \min a_j(q)} \quad (۶)$$

که در آن $a_j(q)$ و $s_j^*(q)$ به ترتیب مقدار واقعی و مقیاس تابع هدف j از نقطه q_{th} را نشان می دهند. ضریب رابطه خاکستری^۲ برای دو تابع هدف با معادله (۷) محاسبه می شود.

$$\xi_j(q) = \frac{\Delta_{\min} + \xi \Delta_{\max}}{\Delta_{0j}(q) + \xi \Delta_{\max}} \quad (۷)$$

تصادفی ایجاد می شود و در هر بردار، تعدادی متغیر ورودی انتخاب می شود. تابع هدف اول براساس متغیرهای انتخاب شده محاسبه می شود و هر یک از داده های جامعه مدنظر با استفاده از ANN تحت آموزش قرار می گیرند و میانگین مربعات خطا) R^2 برای تعیین مقدار تابع هدف دوم محاسبه می شود. MOEA/D برای رسیدن به بهینگی پارتو و حل مسئله انتخاب ویژگی تکرار می شود.

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 می دهد، زیرا یک الگوریتم انتخاب ویژگی چند هدفه است. شکل ۳ نتایج این روش را نشان می دهد، که افزایش تعداد متغیرهای ورودی در مجموعه بهینه منجر به کاهش کمتر خطای مدل می شود. از این رو، ایجاد تعادل بین خطا و پیچیدگی مدل، که مستقیماً با تعداد متغیرهای ورودی مرتبط است، بسیار مهم است.

نقاط نشان داده شده در شکل ۳ راه حل های غیر غالب هستند، به طوری که نمی توان 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

1 Grey relational analysis (GRA)
2 Grey Relational Coefficient (GRC)

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

Table 3. Factors affecting the carbonation depth (MOEA/D-ANN method)

| 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 | | |

متغیرهای بهینه انتخاب شده توسط MOEA/D-ANN در جدول ۳ ارائه شده است.

مطالعات قبلی مواد چسبنده، نسبت فوق روان کننده به مواد چسبنده، 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 RReliefF 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 بدست آمده از روش RReliefF تنها ۱۳ متغیر برتر با بیشترین وزن‌ها انتخاب شدند. متغیرهای انتخاب شده در شکل ۴ ارائه شده است. شایان ذکر است که RReliefF نسبت‌های فوق روان کننده به مواد چسبنده، دانه‌های ریز به کل سنگدانه، سنگدانه درشت به کل سنگدانه، فوق روان کننده به سنگدانه درشت، سنگدانه درشت به سیمان، سنگدانه درشت به سنگدانه درشت را شناسایی کرده است. در مطالعات قبلی متغیرهای ریزدانه

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


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

$a_0(q)$ دنباله توالی مرجع است و $s_j^*(q)$ مقدار مقیاس تابع هدف J از نقطه q_{th} است. در نهایت درجه رابطه خاکستری^۱ 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 $(MSE)^2$ برابر با ۰/۰۰۰۸۵ می‌شود.

- 1 Gray Relational Grade (GRG)
- 2 Mean Squared Error



شکل ۴. متغیرهای تاثیر گذار روش RReliefF

Fig. 4. Influential variables of RReliefF method

متغیرهای خاصی در مقایسه با سایر متغیرها تأثیر قوی تری بر عمق کربناته شدن می‌گذارند. از این رو برخی عوامل ممکن است بدون تأثیر قابل توجهی بر دقت مدل نادیده گرفته شوند. انتخاب ویژگی با استفاده از روش‌های MOEA/D-ANN و RReliefF انجام شد و نتایج در شکل ۵ نشان داده شده است. همان‌طور که در جدول ۴ مشاهده می‌شود، مدل پیشنهادی MOEA/D-ANN با ضریب تعیین ۰/۹۹ و تعداد متغیرهای محدودتر نسبت به برخی تحقیقات پیشین، دقت بسیار بالاتری را در پیش‌بینی عمق کربناته شدن بتن فراهم کرده است. این نتیجه نشان‌دهنده کارآمدی روش پیشنهادی در انتخاب دقیق متغیرهای تأثیرگذار و بهبود عملکرد مدل پیش‌بینی است.

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،

به سیمان و خاکستر بادی به سیمان در نظر گرفته نشده اند. متغیرهایی نظیر سنگدانه درشت، چرخه (روز)، درصد رطوبت نسبی، درصد غلظت CO_2 ، نسبت فوق روان‌کننده به مواد چسبنده، 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.

۳-۲- تجزیه و تحلیل مدل ANN

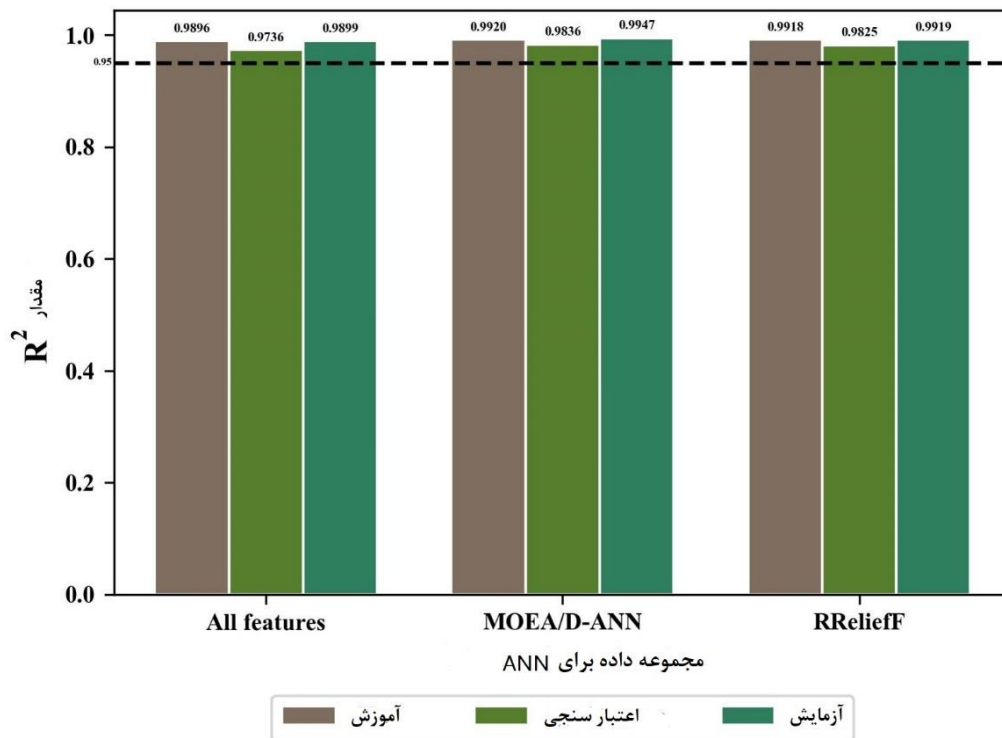
شکل ۵ مقدار R^2 را توسط عملکرد ANN را با استفاده از داده‌های عمومی و MOEA/D-ANN و رویکرد RReliefF در مجموعه داده‌های آموزشی، اعتبار سنجی و آزمایش نشان می‌دهد. ANN با استفاده از داده‌های کلی، دقت پیش‌بینی خوبی را برای عمق کربناته شدن نشان می‌دهد و به ضریب تعیین با مقدار ۰/۹۸ دست می‌یابد.

در مقایسه با مدل‌های 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 پیش‌بینی شده بود و جمع‌آوری دقیق هر یک از ۳۷ متغیر ممکن است چالش برانگیز باشد. در این بین،

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


Table 4. Comparison of the proposed model with previous models

| 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 |



شکل ۵. مقادیر R^2 برای مدل ANN

Fig. 5. R2 values for the ANN model



شکل ۶. مقادیر MSE برای مدل ANN

Fig. 6. MSE values for the ANN model

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.

۴- نتیجه‌گیری

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، RReliefF، 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

حذف کرده است که منجر به بهبود عملکرد کلی در مدل ANN در مقایسه با RReliefF و استفاده از همه ویژگی‌ها شده است. علاوه بر این، زمان اجرا روش MOEA/D-ANN کمتر از زمان اجرای RReliefF با همه ویژگی‌ها می‌باشد. این یافته کارایی محاسباتی MOEA/D-ANN را زمانی که در زمینه ANN اعمال می‌شود، برجسته می‌کند.

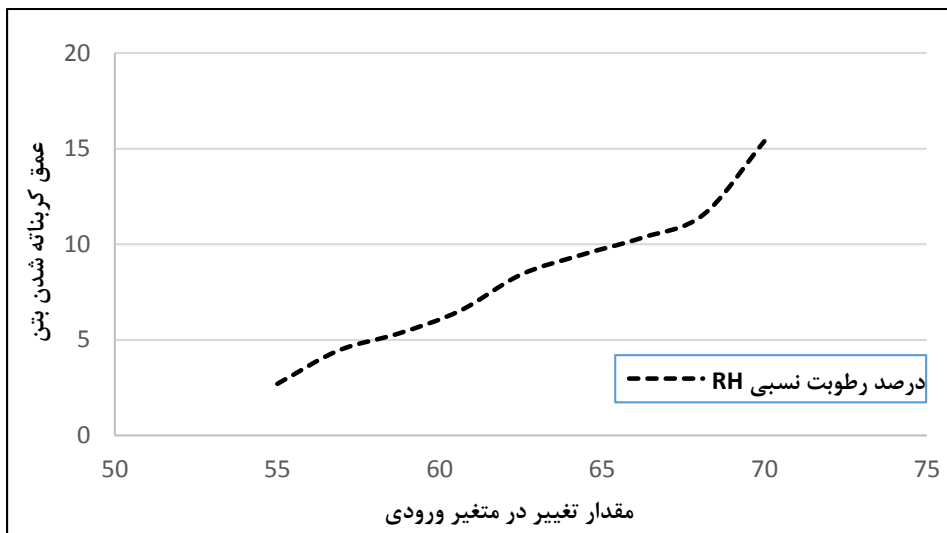
۳-۳- تحلیل حساسیت براساس تغییر در مقدار خروجی

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




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

Fig. 7. Sensitivity analysis on the input variable cycle (day) (CY)



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

Fig. 8. Sensitivity analysis on the input variable relative humidity percentage (RH)



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

Fig. 9. Sensitivity analysis on the input variable carbon dioxide concentration percentage (CC)

بتن، بالاترین سطح دقت را می‌دهند.

■ براساس روش RRelief، عوامل زیر تعیین کننده بودند، که عبارتند از: چرخه (روز)، رطوبت نسبی، غلظت CO₂، 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

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 داد که مدل ایجاد شده با استفاده از رویکرد MOEA/D-ANN، با ترکیب متغیرهای تعیین شده 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 CO₂ 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

- 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. Akpinar, 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*, 287 (2021) 123027.
- [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. Akpinar, I.D. Uwanuakwa, Intelligent prediction of concrete carbonation depth using neural networks, *Bulletin of the Transilvania University of Brasov. Series*

- [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, *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. Akpınar, 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.

- 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 relieff 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 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. Aît-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-SiO₂ 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*,

- [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.
- 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.

چگونه به این مقاله ارجاع دهیم

Sh. Mansouri, A. R. Rahai, S. H. Rashedi, F. Moghaddas Nejad, Predicting Concrete Carbonation Depth and Investigating the Influencing Factors through Machine Learning Approaches and Optimization, Amirkabir J. Civil Eng., 56(12) (2025) 1583-1604.

DOI: [10.22060/ceej.2024.22980.8086](https://doi.org/10.22060/ceej.2024.22980.8086)



