



Intelligent Models for Predicting the Compressive Strength of Green Concrete Made with Fine and Coarse Grains of Waste Copper Slag

Yaser Moodi^{1*}, Naser Safaeian Hamzehkolaei², Iman Afshoon³

¹Department of Civil Engineering, Sirjan University of Technology, Sirjan, Iran.

²Department of Civil Engineering, Bozorgmehr University of Qaenat, Qaenat, Iran.

³Department of Civil Engineering, National University of Skills (NUS), Tehran, Iran.

ARTICLE INFO

Article Type:

Original Research

Received: 02.14.2024

Revised: 05.28.2024

Accepted: 09.11.2024

Keyword:

Green Concrete
Copper Slag
Concrete Aggregates
Compressive Strength
Prediction Models
Genetic Programming
ANFIS

*Corresponding Author:

Yaser Moodi

Email:

y.moodi.civil@sirjantech.ac.ir

ABSTRACT

In recent years, using copper slag waste as a substitute for aggregate materials in concrete has become popular due to economic savings and environmental benefits. However, the time-consuming and costly nature of the experimental studies has prompted the use of artificial intelligence-based models to predict concrete properties. Thus far, no method has been proposed to estimate the compressive strength of concretes with copper slag as a substitute for natural aggregates. This study presents an effective relationship for estimating the compressive strength of such concrete based on a robust database of 458 samples from valid laboratory studies. The dataset included variables such as the ratio of water-to-powdered materials, amount of powdered materials, amount of fine and coarse aggregates, copper slag percentage, and concrete curing age. Two intelligent models, Genetic Programming (GP) and Adaptive Neuro-Fuzzy Inference System (ANFIS), were used. The Particle Swarm Optimization (PSO) algorithm was employed to tune parameters and optimize the ANFIS model. Results showed that the ANFIS model ($R^2=0.94$) outperformed the GP model in generalization capability and accuracy. The hybrid ANFIS-PSO model with optimal parameter tuning achieved the best performance ($R^2=0.96$) compared to other models. Through sensitivity analysis of the input variables, it was determined that curing age and powdered materials had the highest positive effects, respectively, while the ratio of water-to-powdered material had the most negative effect on the compressive strength of green concrete containing copper slag. An increase in the volume of fine aggregates also led to a significant decrease in the compressive strength of this type of concrete. The proposed GP-based predictive model enables the estimation of compressive strength and the conduct of supplementary parametric studies without the need for complex calculations and additional costs.



EXTENDED ABSTRACT

Introduction

The production of pure copper leads to a large amount of copper slag waste. Using these wastes as a substitute for aggregate can greatly contribute to environmental problems. Gupta and Siddique believe that the glassy texture and low water absorption of copper slag particles will improve the characteristics of fresh self-compacting concrete. Replacing all-natural fine aggregate with copper slag will cause holes, small cracks, and the formation of needle-shaped pieces of ettringite in the microstructure of concrete at the age of 28 days, resulting in a decrease in strength. Sheikh et al. (2022) the use of 40% of copper slag fine aggregate in the production of green roller concrete increases the compressive strength at the ages of 7, 28 and 91 days by 11.84%, 17.01% and 23.58%, respectively.

It should be noted that the high costs of experimental work and the time-consuming nature of scientific research in the experimental environment have led to the tendency to use estimating methods. In this study, by collecting 458 specimens from past research, an effort was made to predict the compressive strength of green concrete containing copper slag fine and coarse grains using the two methods of genetic programming (GP) and fuzzy-neural logic inference system (ANFIS).

Methodology

Initially, the database for this research was built using 458 experimental specimens of green concrete containing copper slag fine and coarse grains from previous studies. 70% of the total data of the database were randomly selected for training data and the rest were used for test data. Using the training data, two ANFIS and GP methods were trained to estimate the compressive strength of green concrete containing fine and coarse copper slag waste. In addition, PSO was used for optimizing the ANFIS method.

The variables of ANFIS and GP methods were as follows: water to powder materials ratio, the amount of powder materials consumed, the amount of fine grains, the amount of coarse grains, the percentage of copper slag and the processing age as the input parameters, and the compressive strength of green concrete as the output variable.

Results and discussion

In the results section, firstly, the relationship presented using the GP method to estimate the compressive strength of concretes containing fine and coarse grains of copper slag is discussed. The relationship presented using the GP method is in the form of relationship 1:

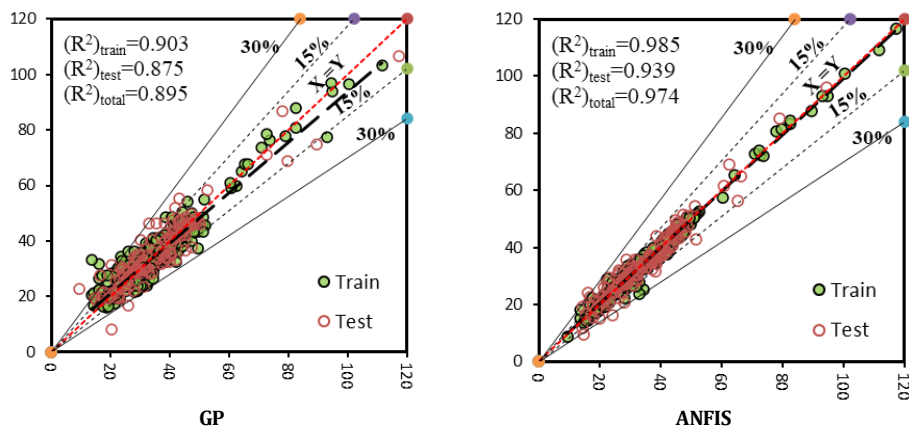
$$\begin{aligned}
 F_c = & 0.2817(B) + 0.1409FA + \left[\frac{2.787B + 1.394FA \times 1.394d}{144.1(CA^3) + \frac{(W/B)}{FA}} \right] \\
 & + e^{\frac{W/B}{FA}} \left[0.01014 \left(CS^3 + \frac{(W/B)}{FA} \right) + 0.01942 \left(B^3 + \frac{CA}{FA} \right) \right] \\
 & - 0.1072e^{(-d)}(B^3 - d + 0.0571) \times +0.1409CA^6 - 0.3523
 \end{aligned} \tag{1}$$

To compare the GP and ANFIS models, the statistical indices for the training, testing, and total samples were calculated separately and are presented in Table 1. To compare the models, it is better to use the statistical indicators of the test samples. Generally, both ANFIS and GP models are sufficiently accurate to estimate the compressive strength of concrete containing fine and coarse copper slag grains. However, the ANFIS method has a higher accuracy than the GP method for estimating this resistance. So the values of MSE, RMSE, MAE, and SD of the GP model were approximately 2.60, 1.61, 1.57, and 1.67 times the values of the ANFIS model in the test samples. It is worth mentioning that this ratio of statistical indices of the GP model to the ANFIS model was greater in training samples.

Table 1. The statistical indices of ANFIS and GP models.

	Training specimens				Test specimens			
	R ²	RMSE	MAE	SD	R ²	RMSE	MAE	SD
ANFIS	0.985	1.79	1.28	0.06	0.939	3.13	2.40	0.12
GP	0.903	4.39	3.91	0.16	0.875	5.04	3.79	0.20
ANFIS-PSO	0.986	1.79	1.12	0.06	0.961	2.95	2.39	0.09

For further comparisons of the presented models, the compressive strength results estimated by these models against the actual results for the test specimens and the correlation coefficient of experimental and predicted data are presented in Figure 1. The correlation coefficient (R^2) between the actual results and the predicted results of the ANFIS model was approximately 1.08 times the corresponding value of the GP model, which shows that the performance of the ANFIS model for estimating the compressive strength of green concrete produced with copper slag is better. Nevertheless, the combined ANFIS-PSO model with the particle swarm optimization algorithm increased the correlation coefficient of the model by 2.34% (for test samples).



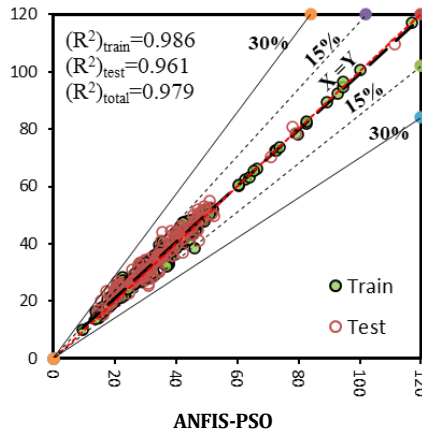


Figure 1. Experimental results against predicted results with GP and ANFIS models.

Conclusion

The ANFIS model predicted the concrete compressive strength parameter with a correlation coefficient of 0.97 and an average squared error of 5.17. These results show the high accuracy and power of the ANFIS model in estimating the compressive strength of green concrete containing copper slag.

The results estimated by GP had a correlation coefficient of $R^2=0.87$ with the experimental results and the standard deviation of the results was equal to 0.17.

Although the GP model provides a user-friendly relationship for estimating the compressive strength of concrete containing copper slag, its correlation coefficient is approximately 8% lower than the ANFIS model. On the other hand, the mean square parameter of the ANFIS model error is approximately 53% lower than that of the GP model.

Using the particle swarm algorithm to adjust the parameters and optimize the ANFIS model improved the learnability (for training data) and generalization power (according to the test data) of this model, and decreased the error values and standard deviation of the response.



مدل‌های هوشمند برای پیش‌بینی مقاومت فشاری بتن سبز ساخته‌شده با ریزدانه و درشت‌دانه‌های ضایعات سربراره مس

یاسر مودی^{۱*}، ناصر صفائیان حمزه کلائی^۲، ایمان افشون^۳

۱- دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران.

۲- گروه مهندسی عمران، دانشکده مهندسی، دانشگاه بزرگمهر قاناق، قاناق، ایران.

۳- گروه مهندسی عمران، دانشگاه ملی مهابت، تهران، ایران.

چکیده

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

دریافت مقاله: ۱۴۰۲/۱۱/۲۵

بازنگری مقاله: ۱۴۰۳/۰۳/۰۸

پذیرش مقاله: ۱۴۰۳/۰۶/۲۱

کلید واژگان:

بتن سبز

سربراره مس

سنگدانه‌های بتن

مقاومت فشاری

مدل پیش‌بینی

برنامه‌ریزی ژنتیک

سیستم استنتاج فازی-عصبی

در سال‌های اخیر استفاده از ضایعات سربراره مس به‌عنوان جایگزین مصالح سنگدانه در بتن به دلیل صرفه اقتصادی و کمک به محیط‌زیست رواج یافته است. از طرفی، زمان‌بر بودن و هزینه زیاد مطالعات آزمایشگاهی سبب تمایل به استفاده از مدل‌های مبتنی بر هوش مصنوعی برای پیش‌بینی خواص انواع مختلف بتن شده است. با این وجود، تاکنون رابطه‌ای برای تخمین مقاومت فشاری بتن‌های حاوی سربراره مس به‌عنوان جایگزین ریزدانه‌ها و درشت‌دانه‌های طبیعی ارائه نشده است. در این مطالعه، با جمع‌آوری بانک داده قدرتمند شامل ۴۵۸ نمونه از مطالعات آزمایشگاهی معتبر، یک رابطه مؤثر برای تخمین مقاومت فشاری این نوع بتن ارائه شده است. مجموعه داده‌های جمع‌آوری شده شامل متغیرهای ورودی مختلفی از جمله نسبت آب به مواد پودری، مقدار مواد پودری، مقدار ریزدانه‌ها، مقدار درشت‌دانه‌ها، درصد سربراره مس و سن عمل‌آوری بتن می‌باشد. بدین منظور، از دو مدل هوشمند مبتنی بر برنامه‌ریزی ژنتیک^۱ (GP) و سیستم استنتاج منطق فازی-عصبی^۲ (ANFIS) استفاده شده است. همچنین، از الگوریتم ازدحام ذرات (PSO) برای تنظیم پارامترها و بهینه‌سازی مدل ANFIS بهره گرفته شد. نتایج در حالت کلی بیان‌گر قابلیت تعمیم‌پذیری و دقت بیشتر مدل ANFIS ($R^2 = 0.94$) نسبت به مدل GP می‌باشد. مدل ترکیبی ANFIS-PSO با تنظیم بهینه پارامترها، بهترین جواب ($R^2 = 0.96$) را در مقایسه با سایر مدل‌ها ارائه کرد. با تحلیل حساسیت متغیرهای ورودی مشخص گردید که سن عمل‌آوری و مواد پودری به ترتیب بیشترین تأثیر مثبت را دارند و نسبت آب به مواد پودری نیز بیشترین تأثیر منفی بر مقاومت فشاری بتن سبز حاوی سربراره مس را دارد؛ افزایش حجم ریزدانه‌ها نیز باعث افت شدید مقاومت فشاری این نوع بتن‌های می‌شود. رابطه پیشنهادی بر مبنای مدل GP، تخمین مقاومت فشاری و انجام مطالعات پارامتری تکمیلی را بدون نیاز به انجام محاسبات پیچیده و هزینه اضافی امکان‌پذیر می‌سازد.

* نویسنده مسئول: یاسر مودی

پست الکترونیکی:

y.moody.civil@sirjantech.ac.ir

¹ Genetic Programming (GP)

² Adaptive Neuro-Fuzzy Inference System (ANFIS)



مقدمه

بتن یکی از پرمصرف‌ترین مصالح ساختمانی است و حدود ۵۵ تا ۸۰ درصد حجم بتن را سنگدانه‌های طبیعی تشکیل می‌دهند [۱]. امروزه توسعه شهرنشینی و صنعت ساخت‌وساز منجر به افزایش استفاده از بتن شده و در نتیجه حجم زیادی از مصالح سنگی موردنیاز است. با این وجود، محدودیت‌های زیست محیطی در فرایند استخراج و تولید مصالح سنگی در کنار عواملی همچون افزایش آلاینده‌گی‌ها و هزینه‌های تولید باعث محدودیت استفاده از سنگدانه‌های طبیعی خواهد شد. بنابراین، در سال‌های اخیر، استفاده از مواد ضایعاتی به‌عنوان مصالح جایگزین ریزدانه‌ها و درشت‌دانه‌های طبیعی در بتن رواج یافته است.

سرباره مس یکی از مواد ضایعاتی است که به میزان قابل توجه در بیشتر کشورها دردسترس می‌باشد. هنگام تولید یک تن مس خالص تقریباً ۲/۲ تا ۳ تن ضایعات سرباره مس تولید می‌شود [۲]. از سرباره مس به‌صورت محدود در تولید کاشی و سرامیک، ساخت انواع شیشه، لایه‌های زیرسازی و روسازی، مصالح پرکننده و زهکشی، صنعت بتن و سند بلاست استفاده می‌شود [۳]. مشخصات ویژه سرباره مس مانند چگالی، سختی و مقاومت سایشی بالا، جذب آب کم به‌همراه درگیری و قفل و بست مناسب با خمیر سیمان امکان استفاده از این مواد ضایعاتی به‌عنوان جایگزین ریزدانه‌ها و درشت‌دانه‌های بتن را فراهم می‌کند [۴-۶]. بنابراین، به‌کارگیری ضایعات سرباره مس علاوه بر بهبود مشخصات بتن تولیدی و کاهش هزینه‌های ساخت، می‌تواند معضلات زیست محیطی در تأمین مصالح سنگی طبیعی و نگهداری ضایعات سرباره مس را کاهش دهد.

تحقیقات انجام‌شده در رابطه با استفاده از سرباره مس برای تولید انواع مختلف بتن حاکی از آن است که بهترین نتایج با به‌کارگیری حدود ۷۰ درصد حجمی سرباره مس در مخلوط‌های سیمانی ارائه شده است. همچنین، حدود ۶۷ درصد تحقیقات انجام‌شده در خصوص استفاده از سرباره مس در تولید بتن از نسبت آب به سیمان ۰/۴ تا ۰/۶ استفاده کرده‌اند [۷]. گوپتا و صدیق^۱ معتقد هستند که بافت شیشه‌ای و جذب آب کم ریزدانه‌های سرباره مس باعث بهبود مشخصات بتن تازه خودمترکم خواهد شد. نتایج تحقیقات آنها نشان داد که با افزایش جایگزینی سرباره مس تا حجم ۳۰ درصد، مقاومت فشاری بتن به دلیل ایجاد ساختار مترکم ژل C-S-H بهبود می‌یابد [۸] ولی در حجم‌های جایگزینی بالاتر از ۳۰ درصد، افت جزئی در مقاومت بتن‌های سبز مشاهده شده است. مطالعات نشان داده است که جایگزین کردن کل ریزدانه‌های طبیعی با سرباره مس باعث ایجاد حفرات، ریزترک‌ها و تشکیل قطعات سوزنی شکل اترینگایت در ریزساختار بتن و در نتیجه افت مقاومت (در سن ۲۸ روز) خواهد شد؛ هرچند که با افزایش سن از ۲۸ به ۳۶۵ روز در بتن‌های حاوی ۱۰۰ درصد ریزدانه‌های سرباره مس، لایه‌های C-S-H بسیار زیادی تشکیل می‌شود و هیچ‌گونه اترینگایتی نیز مشاهده نمی‌شود [۹]. الجابری^۲ و همکاران مدعی شدند که در بتن با عملکرد بالا تا ۵۰ درصد جایگزینی ریزدانه‌های طبیعی با سرباره مس، موجب بهبود مقاومت بتن نسبت به طرح کنترلی شده است. ایشان افت مقاومت بتن در حجم‌های بیشتر از ۵۰ درصد سرباره مس را به علت وجود آب آزاد در ساختار بتن نسبت داده‌اند [۱]. نتایج تحقیقات آمبیلی و همکاران نشان داد که با جایگزینی ۱۰۰ درصد ریزدانه سرباره مس در بتن‌های فوق توانمند، مقاومت فشاری بتن حدود ۲۵ درصد کاهش یافته است بنابراین، به علت دردسترس بودن و قیمت کم این ضایعات، استفاده از سرباره مس به‌عنوان مصالح جایگزین، آینده امیدوارکننده‌ای برای تولید بتن سبز در مناطق همجوار با کارخانه تولید مس ارائه می‌دهد [۱۰]. موسوی و همکاران [۱۱] اثر استفاده همزمان از سرباره مس به‌عنوان مصالح جایگزین ریزدانه‌ها و درشت‌دانه‌های طبیعی در بتن غلتکی را بررسی کردند. نتایج این تحقیق حاکی از آن است که مقاومت فشاری نمونه‌های ۹۱ روزه تا ۴۰ درصد و مقاومت کششی و خمشی آن‌ها تا ۶۰ درصد جایگزینی نسبت به نمونه شاهد افزایش یافت. تصاویر میکروسکوپ

¹ Gupta & Siddique² Al-Jabri

الکترونی روبشی^۱ (SEM) نشان داد که استفاده از حجم کم سرباره مس باعث تقویت ریزساختار بتن و پرکردن فضاهای خالی می‌شود. در بتن‌های تولیدشده با سرباره مس، جذب آب سطحی کمتر از ۷ درصد است و در ۶۰ درصد سرباره مس، جذب آب موینه، عمق نفوذ آب و نفوذ امواج اولتراسونیک به ترتیب ۴۷/۳۲، ۲/۷۶ و ۱۲/۲۲ درصد نسبت به بتن شاهد کاهش یافته است. همچنین، هزینه‌های تولید در بتن سبب حاوی سرباره مس در حدود ۷/۷ تا ۴۶/۱۸ درصد کاهش یافته است. شیخ و همکاران مشاهده کردند استفاده از ۴۰ درصد ریزدانه‌های سرباره مس در ساخت بتن غلتکی سبب مقاومت فشاری در سن ۷، ۲۸ و ۹۱ روز را به ترتیب ۱۱/۸۴، ۱۷/۰۱ و ۲۳/۵۸ درصد افزایش می‌دهد. آنها بر اساس تصاویر SEM نتیجه گرفتند که دلایل افت مقاومت در بتن‌های حاوی حجم‌های بالای سرباره مس و بتن کنترلی، ناشی از وجود ذرات هیدراته‌نشده، ریزترک‌ها، حفرات و قطعات اترنگایت است [۱۲]. شریفی و همکاران نشان دادند که با کاهش میزان نسبت آب به سیمان از ۰/۵۱ به ۰/۴۸ در بتن‌های حاوی صفر تا ۱۰۰ درصد سرباره مس، پارامتر مقاومت فشاری در سن ۲۸ و ۹۰ روز به ترتیب ۲۷ و ۲۴ درصد نسبت به بتن بدون سرباره افزایش می‌یابد [۱۳].

استفاده از سرباره مس در تولید سایر مصالح مورد استفاده در مهندسی عمران نیز بررسی شده است. اورسکوویچ^۲ و همکاران [۱۴] مدعی شدند که استفاده از سنگدانه‌های ضایعاتی سرباره مس در تولید مخلوط آسفالتی تأثیر مثبت بر مشخصات لایه سطحی، سفتی و مقاومت شیاردار دارد و تقریباً هیچ تأثیر منفی روی خواص باقی‌مانده به‌جز مقاومت در برابر ترک ندارد. علاوه بر این، افزودن سرباره مس به مخلوط لایه پایه باعث بهبود مقاومت در برابر ترک شد اما بر سفتی، شیارشدن و مقاومت در برابر خستگی تأثیر منفی خواهد گذاشت. در هر دو مورد، افزودن سرباره مس بر استحکام، حساسیت آب یا مقاومت در برابر یخ‌زدگی تأثیری ندارد. به‌طور کلی می‌توان نتیجه گرفت که سرباره مس پتانسیل استفاده به‌عنوان یک جایگزین مناسب برای سنگدانه‌های طبیعی در مخلوط‌های آسفالتی برای لایه‌های سطحی و پایه را دارد.

با توجه به محدودیت‌های مصالح و هزینه زیاد مطالعات آزمایشگاهی، استفاده از روش‌های مبتنی بر هوش مصنوعی در سال‌های اخیر توسعه یافته است [۱۵؛ ۱۶]. در سال ۱۹۹۲ روش برنامه‌ریزی ژنتیک^۳ (GP) بر مبنای نظریه تکاملی داروین را برای اولین بار کوزا ارائه کرد. کاربردی بودن و دقت بالای این روش هوش مصنوعی در تعیین ارتباط بین داده‌ها باعث شد تا به‌طور گسترده برای حل مسائل مهندسی استفاده شود [۱۷]. در سال ۲۰۰۱، فریرا^۴ روش برنامه‌ریزی بیان ژن^۵ (GEP) را ارائه داد که برخلاف روش GP استاندارد، با استفاده از یک طول ثابت از رشته کاراکترها به حل مسئله می‌پردازد [۱۸]. آشور^۶ و همکاران با استفاده از این روش یک مدل هوشمند برای تخمین مقاومت برشی تیرهای عمیق ارائه کردند [۱۹]. به دلیل توانمندی و دقت مناسب، این روش در زمینه‌های مختلف مهندسی عمران برای تخمین مقاومت برشی ستون‌های بتن مسلح دایره‌ای [۱۸]، مقاومت فشاری انواع مختلف بتن [۱۸] و همچنین تخمین مقاومت فشاری ستون‌های محصورشده با FRP استفاده شده است [۲۰-۲۳]. روش سیستم استنتاج تطبیقی فازی-عصبی^۷ (ANFIS) یکی دیگر از روش‌های پرکاربرد هوش مصنوعی می‌باشد. در این الگوریتم‌ها ویژگی‌های برجسته سیستم استنتاج فازی (FIS) و شبکه‌های عصبی مصنوعی با یکدیگر ترکیب می‌گردند. در سیستم استنتاج تطبیقی فازی-عصبی قوانین فازی نمونه‌ها از طریق شبکه‌های عصبی^۸ (ANN) تعیین می‌شود [۲۴]. سبحانی و همکاران [۲۵] از شبکه‌های

¹ Scanning Electron Microscopy (SEM)

² Orešković

³ Genetic Programming (GP)

⁴ Ferreira

⁵ Gene Expression Programming (GEP)

⁶ Ashour

⁷ Adaptive Neuro-Fuzzy Inference System (ANFIS)

⁸ Artificial Neural Networks (ANN)

ANFIS, ANN و تحلیل رگرسیون برای پیش‌بینی مقاومت فشاری بتن بدون اسلامپ استفاده کردند. جمالی و همکاران [۲۶] از روش ANFIS برای تخمین مقاومت فشاری ستون‌های محصورشده با FRP استفاده کردند. امروزه صنایع تولیدی، بیشتر از قبل به مس و مشتقات آن نیازمند هستند. از طرفی، تولید حجم بالای مس خالص، افزایش ضایعات سرباره را در پی دارد. بنابراین، لازم است تا امکان‌سنجی استفاده از این ماده ضایعاتی برای جایگزین ریزدانه‌ها یا درشت‌دانه‌های طبیعی در تولید انواع بتن بررسی شود. از طرفی در برخی موارد، بررسی آزمایشگاهی مشخصات بتن حاوی سرباره مس به دلیل در دسترس نبودن سرباره مس، محدودیت‌های تجهیزات و فضای آزمایشگاهی و هزینه‌های زیاد تهیه مصالح و انجام آزمایش‌ها امکان‌پذیر نمی‌باشد. بنابراین، ارائه یک مدل هوشمند برای تخمین مقاومت فشاری بتن‌های حاوی سرباره مس علاوه بر برطرف کردن محدودیت‌های آزمایشگاهی، امکان بررسی تأثیر متغیرهای مختلف تأثیرگذار بر مقاومت فشاری این بتن‌ها را بدون نیاز به تجهیزات و مصالح مصرفی و با هزینه بسیار کم فراهم می‌کند.

برای ارائه مدل هوشمند، به مجموعه داده‌های جامع نیاز می‌باشد. در این تحقیق، ابتدا یک بانک داده کامل از مطالعات آزمایشگاهی جمع‌آوری شده است به طوری که این مجموعه داده‌ها معرف رفتار این نمونه‌ها باشد. سپس، برای پرهیز از مطالعات آزمایشگاهی، جلوگیری از اتلاف وقت و همچنین کاهش هزینه‌های طراحی و محاسبات، از دو روش توانمند یادگیری ماشین ANFIS و GP برای تخمین مقاومت فشاری بتن‌های حاوی ریزدانه و درشت‌دانه‌های سرباره مس استفاده شد. بدین منظور از الگوریتم جستجوی سراسری برای تنظیم پارامترها و همچنین افزایش دقت و کارایی مدل ANFIS استفاده شد. همچنین، با انجام تحلیل حساسیت با استفاده از یک روش کارآمد، اثر متغیرهای ورودی تأثیرگذار بر مقاومت فشاری این بتن‌ها بررسی شده است. یک رابطه کاربرپسند بر مبنای مدل GP برای تخمین مقاومت فشاری این نمونه‌ها نیز ارائه شده است که امکان انجام مطالعه پارامتری و تحلیل حساسیت خروجی مدل را بدون نیاز به محاسبات پیچیده فراهم می‌سازد.

مجموعه داده‌ها

برای توسعه یک مدل پیش‌بینی قابل اعتماد و دقیق، یک پایگاه داده شامل نمونه‌های آزمایشگاهی همگن و جامع موردنیاز است. در این تحقیق، با مطالعه مراجع معتبر یک بانک داده‌ای شامل ۴۵۸ نمونه آزمایشگاهی از مطالعات تجربی گذشته با دقت جمع‌آوری شده است (پیوست ۱). پایگاه داده مورد استفاده در تحقیق حاضر شامل مطالعات انجام شده در رابطه با اثر جایگزینی ریزدانه‌ها و درشت‌دانه‌های طبیعی بتن با سرباره مس بر مقاومت فشاری انواع مختلف بتن معمولی، بتن خودمتراکم، بتن مقاومت بالا، بتن با عملکرد بالا و همچنین بتن متخلخل می‌باشد. تلاش شده است پارامترهای ورودی که بیشترین تأثیر در مقایسه با سایر پارامترها بر مقاومت فشاری بتن دارد انتخاب گردند. مشخصات آماری داده‌های مورد استفاده در جدول ۱ ارائه شده است.

مطابق جدول ۱، متغیرهای ورودی در این تحقیق شامل نسبت آب به مواد پودری (W/P)، مواد پودری (P)، ریزدانه طبیعی (FA)، درشت‌دانه طبیعی (CA)، درصد سرباره مس (CS) و سن عمل‌آوری (d) می‌باشد. مقاومت فشاری نمونه‌ها (Fc) نیز به عنوان متغیر خروجی مدل در نظر گرفته شده است.

جدول ۱. مشخصات آماری مجموعه داده‌ها.

پارامتر	واحد	نماد	حداقل	میانگین	حداکثر	انحراف معیار
نسبت آب به مواد پودری	—	W/P	۰/۳۰	۰/۴۵	۰/۵۹	۰/۰۶
مواد پودری	kg	P	۲۵۰/۰۰	۴۱۱/۵۶	۵۷۲/۲۸	۵۲/۴۸
ریزدانه‌های طبیعی	kg	FA	۳۴۰/۰۰	۷۸۱/۳۶	۱۱۵۳/۰۰	۱۴۸/۶۹

پارامتر	واحد	نماد	حداقل	میانگین	حداکثر	انحراف معیار
درشت‌دانه‌های طبیعی	kg	CA	۷۰۰/۰۰	۱۰۴۰/۷۱	۱۶۷۰/۰۰	۲۰۷/۸۰
درصد سرباره	kg	CS	۰/۰۰	۴۷/۲۱	۱۰۰/۰۰	۳۳/۴۹
سن عمل‌آوری	Day	d	۳/۰۰	۳۳/۸۲	۱۱۲/۰۰	۲۹/۱۱
مقاومت فشاری	MPa	F _c	۹/۳۷	۳۵/۳۹	۱۱۷/۱۶	۱۴/۱۴

نسبت آب به مواد پودری، یکی از مهم‌ترین پارامترهای تأثیرگذار بر مقاومت فشاری بتن می‌باشد. این نسبت فرایند، هیدراتاسیون و محصولات ناشی از آن که عامل اصلی روند کسب مقاومت بتن هستند را به شدت تحت تأثیر قرار می‌دهد [۲۷]. مطابق جدول ۱، حداقل و حداکثر میزان نسبت آب به سیمان کلیه داده‌ها به ترتیب برابر با ۰/۳ و ۰/۵۹ می‌باشد. مواد پودری پس از مخلوط‌شدن با آب به‌عنوان چسب عمل می‌کنند و سنگدانه‌ها را در کنار هم نگه خواهند داشت. این مواد باعث انسجام و یکپارچگی ساختار بتن می‌شوند. چگونگی و میزان واکنش‌پذیری این مواد بر فرایند گیرش و در نتیجه روند کسب مقاومت بسیار تأثیرگذار است [۲۸]. مواد پودری شامل سیمان یا سایر مواد مانند دوده سیلیس، متاکاولین و ... می‌باشد که به‌عنوان جایگزین بخشی از سیمان استفاده شده‌اند. در این مجموعه داده‌ها همه بتن‌ها مقدار مواد پودری کمتر از ۵۷۲/۲۸ کیلوگرم بر مترمکعب دارند.

نوع، جنس، شکل، بافت سطحی، سختی، دانسیته و کانی‌شناسی سنگدانه‌های مصرفی بر مقاومت فشاری بتن تأثیرگذار است. استفاده از سنگدانه‌های نامناسب باعث افت شدید مقاومت بتن خواهد شد [۲۹].

با توجه به این که هدف این تحقیق، بررسی مقاومت فشاری بتن‌های حاوی سرباره مس می‌باشد، درصد سرباره مصرفی نیز به‌عنوان یکی از پارامترهای ورودی در نظر گرفته شده است. در مجموعه داده‌های جمع‌آوری‌شده، جایگزینی سرباره مس با گام‌های ۱۰ درصدی در نظر گرفته شده و بیشترین حجم جایگزینی سنگدانه‌های طبیعی با سرباره مس، ۱۰۰ درصد بوده است.


شایان ذکر است که بتن‌های حاوی سرباره مس به علت تأخیر در گیرش ناشی از استفاده از سرباره مس، مقاومت اولیه کمتری در مقایسه با بتن‌های معمولی دارند و نیاز به زمان عمل‌آوری بیشتری دارند. بنابراین، در این تحقیق، سن عمل‌آوری نیز به‌عنوان یکی از پارامترهای ورودی مدل در نظر گرفته شد.

مقاومت فشاری بتن، مهم‌ترین ویژگی بتن سخت‌شده است و سایر ویژگی‌های مقاومتی و دوامی به صورت مستقیم یا غیرمستقیم با آن رابطه دارند [۳۰]. مقاومت فشاری بتن اغلب با نمونه‌های مکعبی با ابعاد ۱۰۰×۱۰۰، ۱۵۰×۱۵۰، ۲۰۰×۲۰۰ میلی‌متر و نمونه‌های استوانه‌ای ۱۰۰×۲۰۰ و ۱۵۰×۳۰۰ میلی‌متر اندازه‌گیری شده است. برای کلیه نمونه‌های استفاده شده در مجموعه داده‌ها، مقاومت فشاری نمونه بر اساس ضرایب مربوطه به مقاومت معادل نمونه استوانه ۱۵۰×۳۰۰ میلی‌متر تبدیل شده است.


در شکل ۱ هیستوگرام نحوه توزیع هر یک از پارامترها به همراه نمودار برازش نرمال داده‌ها نشان داده شده است. شایان ذکر است که ۷۰ درصد مجموعه داده‌ها با انتخاب به‌صورت تصادفی، برای داده‌های مرحله آموزش (یادگیری مدل‌ها) در نظر گرفته شد. همچنین، ۳۰ درصد باقیمانده (داده‌های تست) برای سنجش و مقایسه دقت و قابلیت تعمیم-پذیری مدل‌ها در نظر گرفته شد. برای ارائه یک مدل توانمند باید اثر تنوع و پراکندگی متغیرهای ورودی بر پارامتر هدف را نیز به‌حداقل رساند. با استفاده از داده‌های استاندارد و همچنین نرمال‌سازی داده‌ها، علاوه بر بهبود کارایی مدل، می‌توان میزان خطای تخمین پارامتر هدف را نیز کاهش داد. شایان ذکر است که نرمال‌سازی داده‌ها موجب بهبود دقت مدل‌های مورد استفاده در این تحقیق شد. برای این منظور، در هر دو مدل ANFIS و GP، داده‌ها در بازه ۱- تا ۱ نرمال‌ایز شدند:

$$X_n = 2 \frac{X - X_{min}}{X_{max} - X_{min}} - 1 \quad (1)$$


که در این جا X_{min} و X_{max} به ترتیب بیان گر حداقل و حداکثر مقدار متغیر ورودی X بوده و X_n نیز بیان گر متغیر نرمالایز شده می باشد.




مواد پودری




نسبت آب به مواد پودری




درشت دانه های طبیعی




ریزدانه های طبیعی



سن عمل آوری



درصد سرباره



مقاومت فشاری

شکل ۱. نمودار هیستوگرام داده‌های آزمایشگاهی.

مدلسازی

سیستم استنتاج تطبیقی فازی - عصبی (ANFIS)

تئوری سیستم فازی را اولین بار پروفسور لطفی‌زاده ارائه کرد. مهم‌ترین جنبه منطق فازی، توانایی بیان و توصیف عدم قطعیت یک نوع پارامتری یا ساختاری است. همچنین ابزار جدیدی برای حل مسائلی است که تئوری احتمال هیچ راهی برای آن ندارد. سیستم منطق فازی یک نگاهت غیرخطی بین ورودی و خروجی ایجاد می‌کند. به عبارت دیگر، ورودی را با استفاده از مجموعه‌ای از قوانین پردازش می‌کند و آن را به خروجی تبدیل می‌کند. برای هر ورودی یا خروجی می‌توان یک تابع عضویت تعریف کرد. توابع عضویت توابعی هستند که مقدار عضویت (بین ۰ و ۱) هر نقطه در فضای ورودی را ترسیم می‌کنند [۳۱].

سیستم فازی مورد استفاده در این مطالعه، سیستم ممدانی است. این سیستم می‌تواند به‌طور گسترده در سیستم‌های پشتیبان تصمیم مورد استفاده قرار گیرد و به‌صورت چند ورودی و چند خروجی یا چند ورودی و تک خروجی نیز اجرا شود [۳۲].

مدل ANFIS با کمک یک پایگاه داده ورودی و خروجی، آموزش داده شد و سپس با ایجاد یک سیستم فازی (FIS) امکان تخمین متغیر هدف را فراهم می‌کند [۳۳]. به دلیل چنین ساختاری، مدل‌های عصبی فازی شفافیت ویژه‌ای در تعبیر و تحلیل پاسخ‌ها دارد و نسبت به مدل‌های کاملاً بسته مانند شبکه‌های عصبی، راه‌حل‌های قانع‌کننده‌تری را ارائه می‌دهند. برای یک مدل فازی تاکاگی سوگنو درجه اول با دو متغیر ورودی x و y و یک خروجی f روابط اساسی مدل با دو قانون «اگر آن‌گاه» به‌صورت زیر بیان می‌گردد [۳۴]:

قانون ۱: اگر $(x \in A_1)$ و $(y \in B_1)$ آنگاه $(f_1 = p_1x + q_1y + r_1)$

قانون ۲: اگر $(x \in A_2)$ و $(y \in B_2)$ آنگاه $(f_2 = p_2x + q_2y + r_2)$

که در آن، f_1 و f_2 به ترتیب توابع خروجی قوانین ۱ و ۲ هستند.

شکل ۲ معماری مدل ANFIS را نشان می‌دهد. در مدل ANFIS از پنج لایه با توابع گره استفاده شد.

– **لایه اول:** این لایه، لایه فازی‌شدن می‌باشد. در این لایه، متغیرهای ورودی با اتخاذ توابع عضویت به مقادیر عضویت تبدیل می‌شوند. هر گره، یک گره تطبیقی با تابع زیر است:

$$O_{1,i} = \mu_{A_i}(x) \quad \text{برای } i=1,2 \quad (2)$$

$$O_{1,i} = \mu_{Bi}(x) \quad i=3,4 \text{ برای} \quad (3)$$

که در آن x متغیر ورودی به گره i ، $O_{1,i}$ درجه عضویت مجموعه فازی، A_i یک برچسب زبانی مرتبط (مجموعه فازی): کوچک، بزرگ) است. تابع عضویت $\mu_{Ai}(x)$ به صورت زیر تعریف می‌شود:

$$\mu_{Ai}(x) = \frac{1}{1 + \left(\frac{x - c_i}{a_i}\right)^{2b_i}} \quad (4)$$

– **لایه دوم:** این لایه، لایه پایه قانون است. هر گره در این لایه یک گره ثابت است که با ضرب سیگنال‌های دریافتی به صورت زیر محاسبه می‌شود:

$$O_{2,i} = w_i = \mu_{Ai}(x) \mu_{Bi}(x) \quad i=1,2 \text{ برای} \quad (5)$$

– **لایه سوم:** خروجی این لایه نرمالیزه شده لایه قبلی است و به صورت رابطه زیر ارائه می‌گردد:

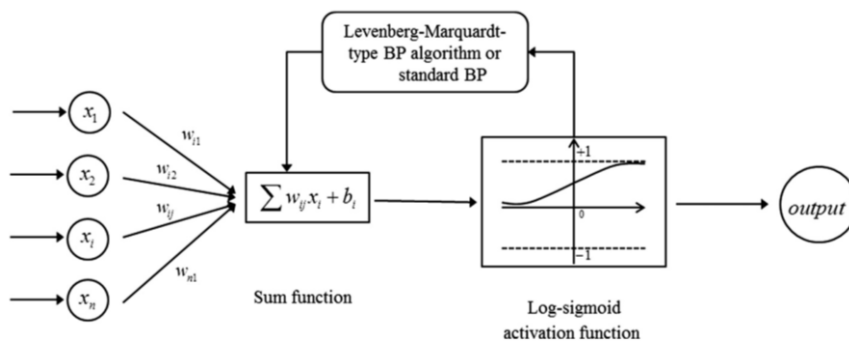
$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1,2 \text{ برای} \quad (6)$$

– **لایه چهارم:** لایه فازی سازی است. هر گره در این لایه یک گره تطبیقی است و تابعی مطابق تابع زیر را دارد:

$$O_{4,i} = \bar{w}_i(p_i x + q_i y + r_i) \quad i=1,2 \text{ برای} \quad (7)$$

– **لایه پنجم:** این لایه، لایه خروجی است که خروجی نهایی را به عنوان مجموع تمام سیگنال‌های دریافتی محاسبه می‌کند:

$$O_{5,i} = \sum \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad i=1,2 \text{ برای} \quad (8)$$



شکل ۲. ساختار روش ANFIS [۳۴].

در شبکه فازی از الگوریتم خوشه‌بندی فازی (FCM) استفاده می‌شود که عملکرد آن در نرم‌افزار متلب با نام genfis3 معرفی شده است. تعداد خوشه‌ها، نوع توابع عضویت متغیرهای ورودی و خروجی مدل و تعداد تکرارها تأثیر قابل توجهی بر دقت مدل ANFIS دارد. در این تحقیق، تعداد خوشه‌ها در مدل ANFIS برابر با ۲۵، تابع عضویت خطی برای متغیرهای ورودی و نیز تابع گوسی برای متغیر خروجی در نظر گرفته شد. تعداد تکرار مدل ANFIS نیز برابر با ۲۰۰ در نظر گرفته شد. شایان ذکر است که با تنظیم دقیق سایر پارامترها (مقادیر وزن، بایاس شبکه و همچنین پارامترهای توابع عضویت متغیرها) می‌توان عملکرد مدل را بهبود بخشید. علی‌رغم کارایی روش‌های بهینه‌سازی محلی، باید توجه داشت که ممکن است نتایج این روش‌ها برای مسائل پیچیده و با ابعاد بالا، دارای دقت مناسب نباشد. برخی از عوامل که باعث ضعف الگوریتم‌های بهینه‌ساز محلی مبتنی بر گرادینان در تنظیم پارامترهای مدل یادگیری ماشین می‌شوند عبارتند از: پیچیدگی محاسبه گرادینان، حساسیت به نرخ یادگیری، عدم همگرایی و نوسانات گرادینان، گیرافتادن در نقاط بهینه محلی، حساسیت به مقیاس ویژگی‌ها. برای رفع این مشکل می‌توان از یک الگوریتم قدرتمند جستجوی سراسری استفاده کرد [۳۴-۳۶]. در این تحقیق، از الگوریتم ازدحام ذرات (PSO)^۱ برای تنظیم پارامترهای مدل ANFIS استفاده شد [۳۴، ۳۷].

برنامه‌ریزی ژنتیک (GP)

روش برنامه‌ریزی ژنتیک را می‌توان برگرفته از شاخه‌های یادگیری ماشین، داده‌کاوی و هوش مصنوعی دانست. مهم‌ترین ویژگی برنامه‌ریزی ژنتیک در مقایسه با انواع شبکه‌های عصبی مصنوعی این است که این روش قادر به ارائه یک رابطه متمایز برای بیان رابطه بین خروجی و متغیرهای ورودی مدل می‌باشد. تفاوت اصلی برنامه‌ریزی ژنتیک با الگوریتم ژنتیک در نحوه پردازش و نمایش جواب‌ها است. در الگوریتم ژنتیک هر متغیر معادل یک ژن است که به‌صورت دودویی کدگذاری شده است و با کنار هم قراردادن این ژن‌ها، رشته دودویی یا کروموزوم تشکیل می‌شود. بنابراین، هر پاسخ با یک رشته یا کروموزوم در الگوریتم ژنتیک نمایش داده می‌شود و هر رشته از اعداد به‌عنوان یک جواب در نظر گرفته می‌شود. در صورتی که در GP، متغیرها ساختارهای برنامه‌ریزی هستند و خروجی مدل نیز میزان توانایی برنامه در رسیدن به اهدافش می‌باشد؛ با اعمال تغییرات جزئی در عملگرهای الگوریتم ژنتیک همانند جهش، بازتولید و ارزیابی توابع می‌توان از آن در برنامه‌ریزی ژنتیک نیز استفاده کرد. راه‌حل‌ها در GP، برنامه‌های کامپیوتری هستند که به‌عنوان ساختار درختی نشان داده می‌شوند. به‌طوری که درختان طول ثابتی ندارند و هر عضو از جمعیت GP بر اساس درخت، شامل سلسله‌مراتبی همانند توابع و پایانه‌ها می‌باشد.

در برنامه‌ریزی ژنتیک ابتدا بلوک‌های موجود، شامل متغیرهای ورودی، هدف و نیز تابع ارتباط‌دهنده آن‌ها تعریف می‌شوند. سپس، ساختار مناسب و ضرایب آن به الگو اختصاص داده می‌شود. انتخاب ورودی مناسب یکی از مهم‌ترین مواردی است که باید در این روش مورد توجه قرار گیرد. این روش شامل یک معادله ارتباط‌دهنده بین متغیرهای ورودی و خروجی است بنابراین قادر به انتخاب خودکار متغیرهای مناسب الگو و حذف متغیرهای غیرمرتبط می‌باشد. این ویژگی سبب کاهش ابعاد متغیرهای ورودی خواهد شد. در کاربردهای مهندسی به‌طور وسیعی در الگوسازی مسائل مربوط به تعیین ساختار پدیده‌ها از این روش استفاده می‌شود [۱۷]. مراحل روش GP در قالب یک فلوچارت در شکل ۳ نشان داده شده است.

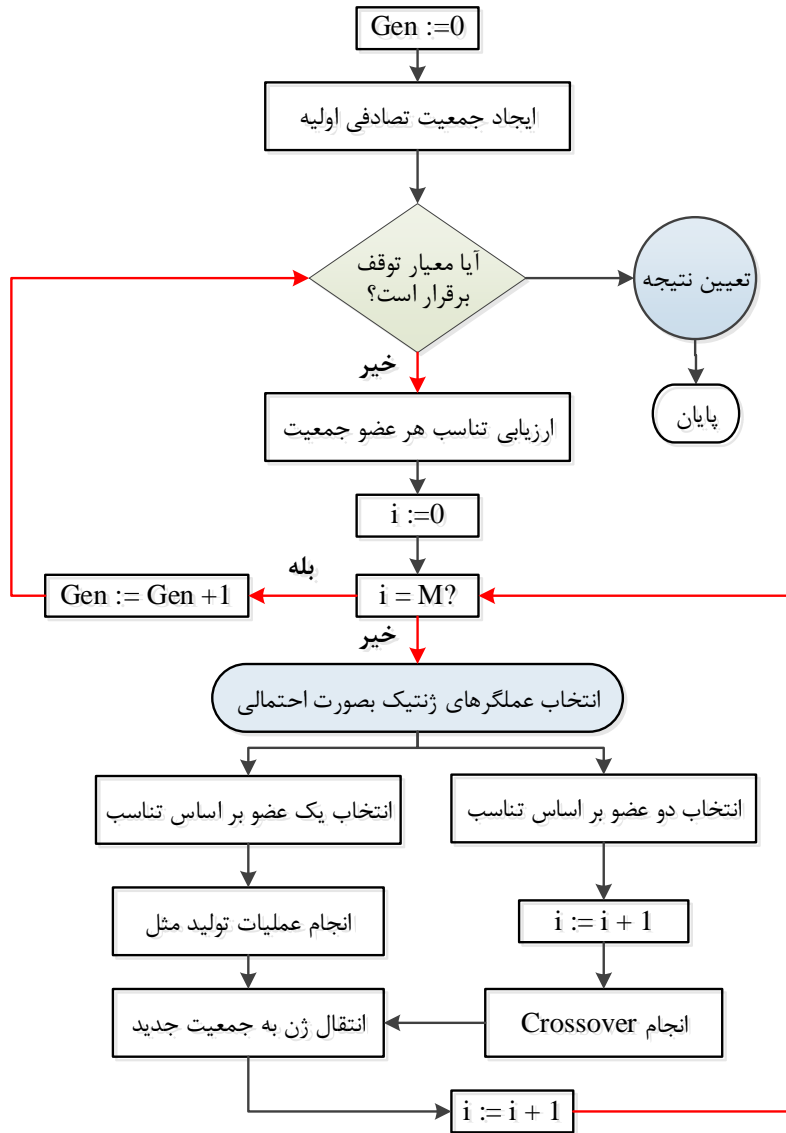
انتخاب مقادیر بهینه برای پارامترهای مدل GP هم بر دقت و هم بر امکان یافتن و ارائه جواب ساده تأثیرگذار است. پارامترهای مهم این روش شامل اندازه جمعیت، تعداد نسل، عملگرها و توابع ریاضی بین ژن‌ها، سرعت جهش و وارونگی و همچنین بازه ضرایب ثابت تصادفی هستند. در این تحقیق، مقادیر بهینه برای پارامترهای این مدل با روش سعی و

¹ Particle Swarm Optimization (PSO)

خطا تعیین شده و مقدار بهینه پارامترها مطابق جدول ۲ در نظر گرفته شده است. شایان ذکر است که ورودی‌ها و خروجی مدل GP با ورودی‌ها و خروجی مدل ANFIS یکسان می‌باشد. همچنین، نحوه انتخاب و تعداد داده‌های آموزش و آزمایش برای هر دو روش یکسان است.

جدول ۲. پارامترهای در نظر گرفته شده برای مدل برنامه‌ریزی ژنتیک.

تعداد جمعیت	۲۰۰۰
تعداد نسل و تعداد ژن	۱۵۰ و ۵
عملگرها و توابع ریاضی بین ژن‌ها	\sqrt{x} ، x^3 ، \ln ، exp ، x^2 ، $+$ ، $-$ ، $*$ ، $/$
سرعت جهش و وارونگی	۰/۱۴ و ۰/۸۴
بازه ضرایب ثابت تصادفی	۱۰- الی ۱۰



شکل ۳. نمودار فرایند مدل برنامه‌ریزی ژنتیک.

ارزیابی دقت مدل‌ها

در این تحقیق، برای مقایسه دقت پیش‌بینی مدل‌های ANFIS و GP از شاخص‌های آماری مختلف (مطابق جدول ۳) شامل ریشه دوم میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، ضریب همبستگی (R^2) و انحراف معیار (SD) استفاده شد. برای یک مدل بهینه، مقدار R^2 به یک نزدیک است و سایر پارامترها به سمت صفر میل می‌کنند.

جدول ۳. شاخص‌های آماری استفاده‌شده برای مقایسه روش‌های تخمین.

ردیف	نام	مخفف	معادله
۱	ریشه دوم میانگین مربعات خطا	RMSE	$RMSE = \sqrt{\frac{\sum_1^N (R_{Pre} - R_{Exp})^2}{N}}$
۲	میانگین قدر مطلق خطا	MAE	$MAE = \frac{\sum_1^N R_{Pre} - R_{Exp} }{N}$
۳	ضریب همبستگی	R^2	$R^2 = \frac{[\sum_1^N (R_{Pre} - \bar{R}_{Pre})(R_{Exp} - \bar{R}_{Exp})]^2}{\sum_1^N (R_{Pre} - \bar{R}_{Pre})^2 \sum_1^N (R_{Exp} - \bar{R}_{Exp})^2}$
۴	انحراف معیار	SD	$SD = \sqrt{\frac{\sum_1^N \left(\frac{R_{Pre}}{R_{Exp}} - \frac{\bar{R}_{Pre}}{\bar{R}_{Exp}} \right)^2}{N - 1}}$

در جدول ۳، N ، R_{Pre} ، R_{Exp} ، \bar{R}_{Pre} و \bar{R}_{Exp} به ترتیب تعداد نمونه‌ها، پارامتر خروجی پیش‌بینی‌شده، پارامتر خروجی تجربی، میانگین پارامتر خروجی پیش‌بینی‌شده و میانگین پارامتر خروجی تجربی است.

نتایج و بحث

در این بخش، ابتدا رابطه پیشنهادی برگرفته از مدل GP برای تخمین مقاومت فشاری بتن حاوی سرباره مس ارائه می‌گردد. سپس، نتایج مدل‌های با کار گرفته‌شده (GP، ANFIS و مدل ترکیبی ANFIS-PSO) برای تخمین مقاومت فشاری بتن سبز حاوی سرباره مس ارائه می‌شود. برای مقایسه دقت و قابلیت تعمیم‌پذیری روش‌ها از شاخص‌های آماری مختلف (جدول ۳) استفاده شده است. در نهایت میزان اهمیت متغیرهای ورودی با مطالعه پارامتری و انجام تحلیل حساسیت بررسی می‌شود.

رابطه پیشنهادی برای تخمین مقاومت فشاری بتن سبز حاوی سرباره مس

در این بخش رابطه پیشنهادی مدل GP برای تخمین مقاومت فشاری بتن سبز حاوی ریزدانه‌ها و درشت‌دانه‌های سرباره مس ارائه شده است. مطابق جدول ۱، کلیه متغیرهای ورودی شامل نسبت آب به مواد پودری (W/P)، مواد پودری (P)، ریزدانه‌های طبیعی (FA)، درشت‌دانه‌های طبیعی (CA)، درصد سرباره (CS)، سن عمل‌آوری (d) در مدل GP در نظر گرفته شد. رابطه ۹، فرمول پیشنهادی مدل GP برای تخمین مقاومت فشاری بتن سبز حاوی سرباره مس را نشان می‌دهد.

$$\begin{aligned}
 F_c = & 0.2817(P) + 0.1409 FA + \left[\frac{(2.787 P + 1.394 FA \times 1.394 d) \times 10^{15}}{1.441 \times 10^{17} (CA^3) + \frac{1.441 \times 10^{17} (W/P)}{FA}} \right] \\
 & + e^{\frac{W/P}{FA}} \left(CS^3 + \frac{(W/P)}{FA} \right) \times 0.01014 e^{\frac{W/B}{FA}} \left(P^3 + \frac{CA}{FA} \right) \\
 & \times 0.01942 - e^{(-d)} (P^3 - d + 0.0571) \times 0.1072 + 0.1409 CA^6 \\
 & + 0.3523
 \end{aligned} \quad (9)$$

رابطه ۹ یک رابطه کاربر پسند است که بدون استفاده از رایانه قابل استفاده می‌باشد. مقاومت فشاری نمونه‌های استفاده‌شده در این مطالعه با استفاده از این رابطه محاسبه شده است و نتایج آنها در بخش‌های بعدی ارائه می‌گردد.

شایان ذکر است که ارائه مدل با دقت بالاتر نیز توسط روش GP برای تخمین مقاومت فشاری بتن سبز حاوی سرباره مس امکان‌پذیر است اما این روابط طولانی‌تر و پیچیده‌تر است و گاهی انجام محاسبات لازم برای تخمین مقاومت فشاری بدون استفاده از رایانه را نیز دشوار می‌سازد.


مقایسه عملکرد مدل‌های مورد مطالعه

برای مقایسه جامع دقت مدل‌های GP، ANFIS و ANFIS-PSO، شاخص‌های آماری برای نمونه‌های مرحله آموزش و آزمایش به‌صورت جداگانه محاسبه شده و در جدول ۴ ارائه شده است. بررسی شاخص‌های آماری نشان می‌دهد که هر دو مدل ANFIS و GP دقت مناسبی برای تخمین مقاومت فشاری بتن‌های حاوی ریزدانه‌ها و درشت‌دانه‌های سرباره مس دارند. با این حال، مقایسه شاخص‌های عملکردی دو روش در مرحله آموزش و آزمایش نشان می‌دهد که مدل ANFIS در تمامی شاخص‌ها نتایج بهتری نسبت به مدل GP ارائه کرده است. برای نمونه‌های آزمایش، مقدار RMSE، MAE و SD مدل GP تقریباً ۲/۶۰، ۱/۶۱، ۱/۵۷ و ۱/۶۷ برابر مقادیر متناظر برای مدل ANFIS می‌باشد. شایان ذکر است که این اختلاف در نسبت شاخص‌های آماری مدل GP به مدل ANFIS نمونه‌های آموزش بیشتر می‌باشد. ضریب همبستگی برای مدل ANFIS در مرحله آموزش برابر با $R_{test}^2 = 0/939$ و این مقدار برای مدل GP برابر با $R_{test}^2 = 0/875$ می‌باشد. بنابراین می‌توان نتیجه گرفت که مدل ANFIS دارای دقت و قابلیت تعمیم‌پذیری بیشتری در مقایسه با مدل GP (برای این داده‌ها) می‌باشد. مقایسه نتایج مدل ANFIS با مدل ترکیبی ANFIS-PSO نشان می‌دهد که تنظیم پارامترهای بهینه مدل ANFIS با الگوریتم بهینه‌ساز PSO، دقت و عملکرد مدل را هم در مرحله آموزش و هم در مرحله آزمایش بهبود داده است؛ شاخص‌های آماری RMSE، MAE و SD مدل ANFIS-PSO برای نمونه‌های آزمایش، به ترتیب ۰/۵، ۰/۶ و ۳۳ درصد نسبت به روش ANFIS کاهش یافته است. در حالی که مقدار ضریب همبستگی مدل ANFIS از مقدار ۰/۹۳۹ تا اندازه ۰/۹۶۱ برای R_{test}^2 مدل بهینه‌شده افزایش یافته است.

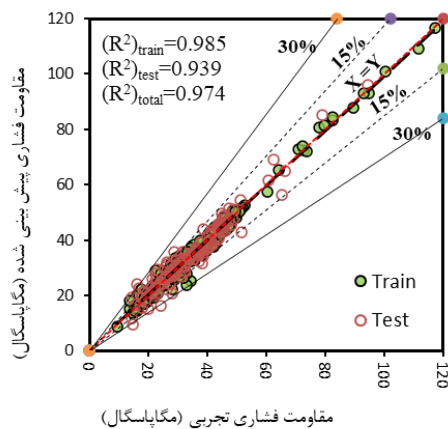
با در نظر گرفتن شاخص‌های آماری می‌توان نتیجه گرفت که مدل ANFIS عملکرد بهتری نسبت به مدل GP برای تخمین مقاومت فشاری بتن‌های حاوی ریزدانه‌ها و درشت‌دانه‌های سرباره مس داشته است. با این وجود، باید دقت کرد ارائه یک رابطه کاربرپسند از مدل ANFIS کار دشواری است و نتایج این مدل اغلب به‌صورت شبکه بسته استفاده می‌شود. توانایی ارائه رابطه با دقت مناسب برای تخمین مقاومت فشاری این بتن‌ها یکی از مزیت‌های مدل GP می‌باشد که می‌تواند رضایت کاربر را جلب کند.

جدول ۴. مقایسه مدل‌های مورد بررسی.

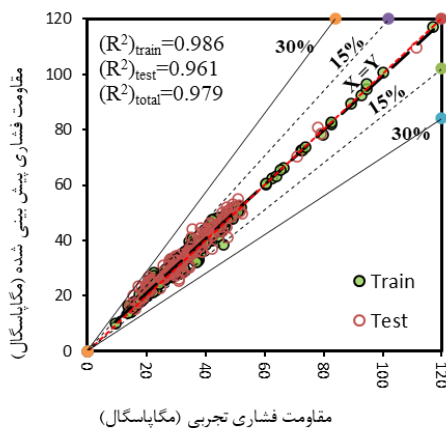
مدل	نمونه‌های آموزش				نمونه‌های آزمایش			
	SD	MAE	RMSE	R ²	SD	MAE	RMSE	R ²
ANFIS	۰/۹۸۵	۱/۷۹	۱/۲۸	۰/۰۶	۰/۹۳۹	۲/۴۰	۳/۱۳	۰/۱۲
GP	۰/۹۰۳	۴/۳۹	۳/۹۱	۰/۱۶	۰/۸۷۵	۳/۷۹	۵/۰۴	۰/۲۰
ANFIS-PSO	۰/۹۸۶	۱/۷۹	۱/۱۲	۰/۰۶	۰/۹۶۱	۲/۳۹	۲/۹۵	۰/۰۹



GP



ANFIS



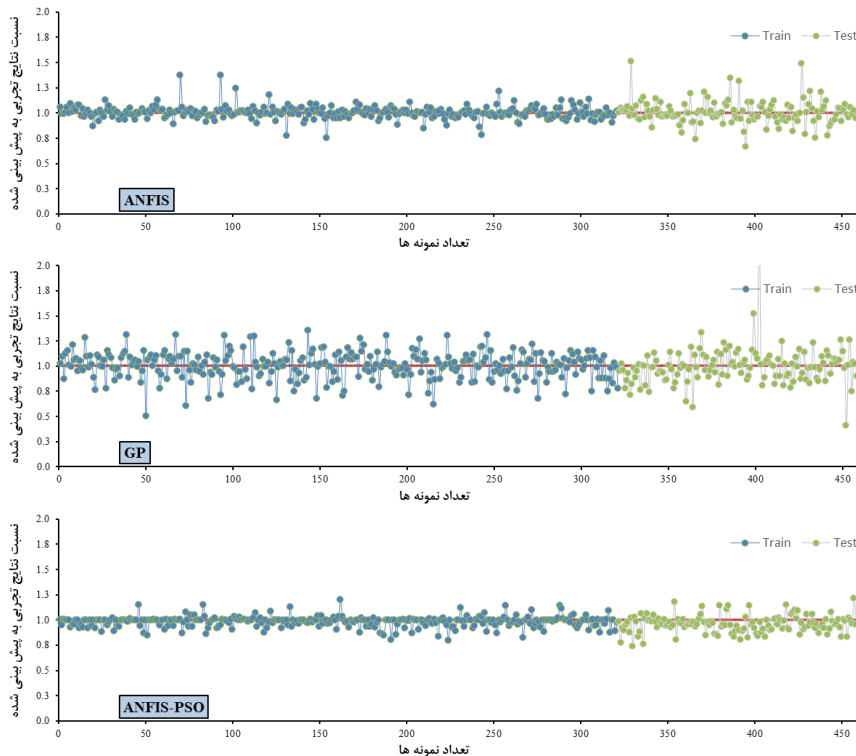
ANFIS-PSO

شکل ۴. نمودار نتایج آزمایشگاهی در مقابل نتایج پیش‌بینی شده با مدل‌ها.

در شکل ۴، نتایج مقاومت فشاری تخمین زده شده توسط مدل‌های مورد بررسی در مقابل نتایج واقعی نمایش داده شده است. برای مقایسه بهتر، نتایج داده‌های آموزش و آزمایش به صورت مجزا نشان داده شده و مقدار ضریب همبستگی داده‌های آزمایشگاهی و پیش‌بینی شده نیز در این شکل ارائه شده است. میزان ضریب همبستگی مدل GP برای نمونه‌های آموزش و آزمایش قابل قبول است و به ترتیب برابر با ۰/۹۰ و ۰/۸۷ می‌باشد. با این حال، شکل ۴ نشان می‌دهد که مدل GP دارای پراکندگی و خطای بیشتری در مقایسه با مدل ANFIS می‌باشد. مقایسه شاخص عملکردی انحراف معیار (SD) در روش در جدول ۴ هم در مرحله آموزش و هم در مرحله آزمایش، این امر را تأیید می‌کند.

شکل ۴ حاکی از همبستگی مناسب بین نتایج پیش‌بینی شده با مدل ANFIS و نتایج آزمایشگاهی است؛ مقدار ضریب R^2 برابر با ۰/۹۸۵ برای نمونه‌های آموزش و ۰/۹۳۹ برای نمونه‌های آزمایش است که بیان‌گر دقت مناسب این مدل در تخمین پارامتر هدف می‌باشد. با این وجود، مدل ترکیبی ANFIS-PSO با الگوریتم بهینه‌ساز ازدحام ذرات، ضریب همبستگی مدل را ۲/۳۴ درصد (برای نمونه‌های آزمایش) افزایش داده است. مقایسه نتایج دو روش در شکل

۴ و جدول ۴ نشان می‌دهد که استفاده از الگوریتم بهینه‌ساز در مدل ANFIS، علاوه بر افزایش دقت و قابلیت تعمیم‌پذیری، انحراف معیار نتایج این مدل را از مقدار ۰/۱۲ تا اندازه ۰/۰۹ برای داده‌های آزمایش نیز کاهش داده است، در حالی که قدرت یادگیری و آموزش شبکه تقریباً ثابت باقی مانده است. این نتایج در حالت کلی نشان‌دهنده توانمندی مدل‌های ترکیبی هوشمند مبتنی بر جستجوی سراسری برای تنظیم پارامترهای شبکه و افزایش دقت و عملکرد مدل تخمینی می‌باشد.



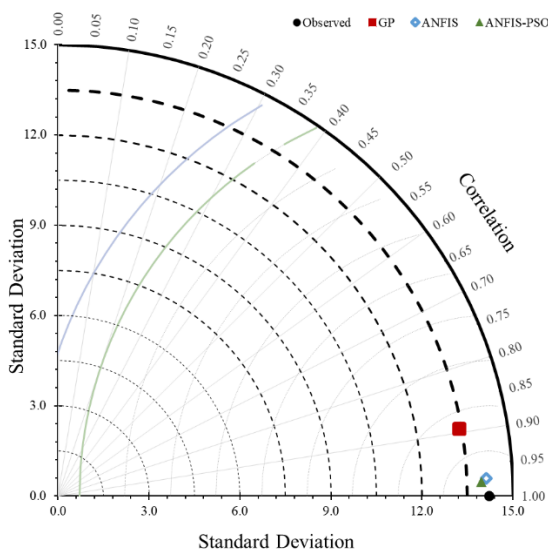
شکل ۵. نسبت نتایج آزمایشگاهی به نتایج پیش‌بینی شده توسط مدل‌ها.

در شکل ۵ نسبت مقاومت آزمایشگاهی به مقاومت پیش‌بینی شده برای نمونه‌های آموزش و آزمایش به صورت جداگانه نشان داده شده است. مطابق شکل ۵ مشاهده می‌شود نسبت نتایج تجربی به نتایج پیش‌بینی شده برای مدل ANFIS در بازه ۰/۶۶ تا ۱/۵۱ قرار دارد و این نسبت برای مدل GP در بازه ۰/۴۱ تا ۲/۴۶ قرار می‌گیرد اما بهینه‌سازی مدل ANFIS باعث کاهش پراکندگی پاسخ تخمین‌زده شده و دامنه این نسبت بین ۰/۷۴ و ۱/۲۲ محدودتر شده است.

نمودار تیلور

نمودار تیلور با ترکیب سه شاخص عملکردی RMSE، انحراف معیار استاندارد و همچنین ضریب همبستگی امکان مقایسه مدل‌های مختلف یادگیری ماشین با تطبیق مقادیر پیش‌بینی شده با اندازه‌گیری‌های واقعی را نشان دهد [۳۸]. در شکل ۶، نمودار تیلور برای کل نمونه‌ها با استفاده از سه معیار انحراف استاندارد، ضریب همبستگی و مقدار RMSE

رسم شده است. شکل ۶ نشان می‌دهد که مدل ANFIS و ANFIS-PSO نسبت به رابطه ارائه شده با استفاده از روش GP به نقطه مشاهده (آزمایشگاهی) نزدیک‌تر است و این نشان می‌دهد دو روش دارای عملکرد بهتری برای تخمین مقاومت فشاری بتن حاوی ضایعات سرپاره مس می‌باشد. با کمی دقت در نمودار تیلور مشاهده می‌شود که نقطه مربوط به نتیجه روش ANFIS-PSO نسبت به روش ANFIS کمی به نقطه Observed نزدیک‌تر است که نشان‌دهنده دقت بالاتر مدل ترکیبی بهینه برای تخمین مقاومت فشاری بتن حاوی سرپاره مس می‌باشد.



شکل ۶. نمودار تیلور روش‌های ANFIS و GP.

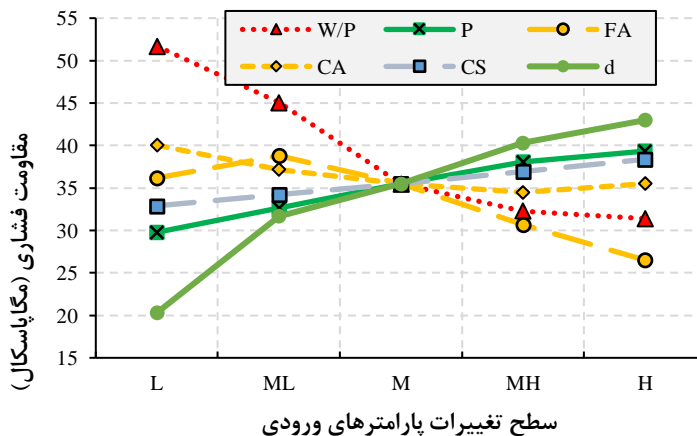
تحلیل حساسیت

برای بررسی اهمیت/تأثیر نسبی متغیرهای ورودی بر مقدار مقاومت فشاری بتن‌های حاوی سرپاره مس از روش پیشنهادی نیک بین و همکاران [۳۹]، استفاده شده است. بدین منظور از رابطه پیشنهادی (۹) توسط مدل GP برای تحلیل حساسیت استفاده شده است. در بررسی حساسیت، همه پارامترهای ورودی در نقطه میانگین آن‌ها ثابت در نظر گرفته شده است و تنها پارامتر موردنظر از مقدار L الی H تغییر می‌کند؛ L و H به ترتیب کمترین و بیشترین مقدار مشاهده شده برای کمیت موردنظر در بانک داده‌ها می‌باشد. در جدول ۵ مرزهای L، ML، M، MH و H برای کلیه پارامترهای ورودی ارائه شده است. L، M و H به ترتیب کمترین، میانگین و بیشترین مقدار پارامتر موردنظر هستند اما ML متوسط بین مقدار L و M و MH متوسط بین M و H است.

جدول ۵. مقادیر متناظر با پارامترهای ورودی.

دامنه	W/P	P	FA	CA	CS	d
L	۰/۳۰	۲۵/۰۰	۳۴/۰۰	۷۰/۰۰	۰/۰۰	۳/۰۰
ML	۰/۳۷	۳۳/۰۷۸	۵۶/۰۶۸	۸۷/۱۳۶	۲۳/۶۱	۱۸/۴۱
M	۰/۴۵	۴۱/۰۵۶	۷۸/۱۳۶	۱۰۴/۰۷۱	۴۷/۲۱	۳۳/۸۲
MH	۰/۵۲	۴۹/۱۹۲	۹۶/۱۱۸	۱۳۵/۳۶	۷۳/۶۱	۷۲/۹۱
H	۰/۵۹	۵۷/۲۲۸	۱۱۵/۳۰۰	۱۶۷/۰۰	۱۰۰/۰۰	۱۱۲/۰۰

شکل ۷ نتایج تحلیل حساسیت متغیرهای ورودی با استفاده از روش پیشنهادی مدل GP را نشان می‌دهد. بدین منظور در هر تکرار، یکی از متغیرهای ورودی در بازه L و H متناظر با جدول ۵ تغییر داده شده و بقیه ورودی‌ها در نقطه میانگین ثابت در نظر گرفته شد. این مراحل برای کلیه ورودی‌ها شامل نسبت آب به مواد پودری (W/P)، مواد پودری (P)، ریزدانه‌های طبیعی (FA)، درشت‌دانه‌های طبیعی (CA)، درصد سرباره (CS)، سن عمل‌آوری (d) در مدل GP تکرار شد. بررسی نتایج ارائه‌شده در شکل ۷ نشان می‌دهد که سن عمل‌آوری و نسبت آب به مواد پودری به ترتیب دارای بیشترین اثر مثبت و منفی بر تغییرات مقاومت فشاری بتن حاوی سرباره مس هستند. هرچند که اثر نسب W/P تا رسیدن به مقدار میانگین بسیار شدیدتر است و برای مقادیر بیشتر از نقطه میانگین شدت تغییر مقاومت فشاری کاهش می‌یابد. با این وجود، باید دقت کرد که افزایش W/P باعث کاهش مقاومت فشاری می‌شود. عامل دیگر که می‌تواند مقاومت فشاری بتن‌های حاوی سرباره مس را تحت تأثیر قرار دهد سن عمل‌آوری است. زمانی که مقدار پارامتر d از کران پایین (L) به سمت کران بالا (H) حرکت می‌کند، مقاومت فشاری افزایش می‌یابد. زمانی که مقدار FA در محدوده M تا H قرار دارد مقدار مقاومت فشاری دچار افت مشهود می‌شود. همان‌طور که مشاهده می‌شود، درصد سرباره (CS) و مواد پودری (P) در تمامی کران خود تأثیر مثبت بر مقاومت فشاری بتن دارد و با افزایش مقادیر این پارامترها مقاومت فشاری بتن افزایش می‌یابد. همچنین، مصالح سنگی (FA و CA) دارای کمترین اثر بر دامنه تغییرات مقاومت فشاری بتن حاوی سرباره مس (به‌خصوص در محدوده نزدیک میانگین) در مقایسه با سایر متغیرهای ورودی هستند. افزایش مقدار FA در محدوده کم (L تا ML) و زیاد (بیشتر از M) به ترتیب موجب افزایش و کاهش خروجی مدل شده است.



شکل ۷. اثر پارامترهای ورودی بر مقاومت فشاری پیش‌بینی‌شده با مدل GP.

با جمع‌بندی نتایج این بخش می‌توان نتیجه گرفت که سن عمل‌آوری، مواد پودری و درصد سرباره مس به ترتیب دارای اثر مثبت بیشتر (در تمامی کران خود) و نسبت W/P نیز دارای بیشترین اثر منفی بر مقاومت فشاری بتن سبز بوده می‌باشد.

نتایج

افزایش مقدار تولید ضایعات سرباره مس از یک سو و مشکلات زیست محیطی ناشی از تهیه مصالح سنگی بتن از سوی دیگر باعث آسیب به طبیعت و نگرانی‌های حافظان محیط زیست شده است. از طرفی کاربرد این مواد ضایعاتی به‌عنوان جایگزین سنگدانه‌های طبیعی بتن رونق یافته و مستلزم تأیید علمی در محیط آزمایشگاه است. همچنین، انجام

مطالعات آزمایشگاهی نیز مستلزم زمان و هزینه زیاد است و به دلیل خطاهای اندازه‌گیری، کالیبره‌نبودن دستگاه‌ها، تسلط‌نداشتن یا خطاهای انسانی تکنیسین آزمایشگاه و سایر عوامل، همواره با عدم قطعیت‌های مختلفی همراه است. بنابراین، در سال‌های اخیر تمایل به استفاده از مدل‌های هوش مصنوعی برای پیش‌بینی و تخمین مشخصات بتن مورد توجه محققان قرار گرفته است. در این تحقیق، یک مجموعه داده قابل اطمینان حاوی ۴۵۸ نمونه آزمایشگاهی از مطالعات آزمایشگاهی در رابطه با مقاومت فشاری بتن سبز حاوی درشت‌دانه و ریزدانه‌های سرباره مس جمع‌آوری شد. در بانک داده استفاده‌شده اثر کلیه ورودی‌های تأثیرگذار شامل نسبت آب به مواد پودری (W/P)، مواد پودری (P)، ریزدانه‌های طبیعی (FA)، درشت‌دانه‌های طبیعی (CA)، درصد سرباره (CS) و همچنین سن عمل‌آوری (d) بر مقاومت فشاری بتن حاوی سرباره مس در نظر گرفته شده است. با بهره‌گیری از سیستم استنتاج عصبی- فازی ANFIS و همچنین مدل برنامه‌ریزی ژنتیک GP مدل‌های هوشمند پیشنهادی برای پیش‌بینی مقاومت فشاری بتن‌های حاوی ریزدانه و درشت‌دانه‌های سرباره مس توسعه داده شد. همچنین، از الگوریتم بهینه‌سازی ازدحام ذرات برای تنظیم پارامترها، افزایش دقت و بهبود عملکرد سیستم استنتاج فازی- عصبی استفاده شد. سپس، یک رابطه کارآمد بر مبنای مدل برنامه‌ریزی ژنتیک برای تخمین مقاومت فشاری بتن حاوی سرباره مس ارائه شد و اثر متغیرهای ورودی بر خروجی مدل با انجام تحلیل حساسیت بررسی شد. نتایج کلی این تحقیق به شرح زیر به دست آمد:

- هنگام استفاده از حجم‌های کم سرباره مس به علت سختی بالا و جذب آب کم این دانه‌های ضایعاتی، مقاومت فشاری بتن بهبود می‌یابد اما در حجم‌های بالای سرباره مس، آب آزاد بتن افزایش می‌یابد و پس از گذشت زمان باعث ایجاد حفره و خلل و فرج در ساختار بتن و در نتیجه افت مقاومت می‌شود.
- هر دو مدل مبتنی بر هوش مصنوعی به کار گرفته‌شده در این مطالعه تخمین قابل‌قبولی از مقاومت فشاری بتن سبز حاوی سرباره مس ارائه کرده‌اند. با این وجود، مدل ANFIS پارامتر مقاومت فشاری بتن را با ضریب همبستگی ۰/۹۴، میانگین قدر مطلق خطا برابر با ۰/۲۴۰، RMSE برابر با ۳/۱۳ و انحراف معیار ۰/۱۲ و دقیق‌تر از مدل برنامه‌ریزی ژنتیک (با $R^2 = ۰/۸۷۵$) پیش‌بینی کرده است. این نتایج بیانگر دقت و قدرت بالای مدل ANFIS در تخمین مقاومت فشاری بتن سبز حاوی سرباره مس می‌باشد.
- به کارگیری الگوریتم ازدحام ذرات برای تنظیم پارامترها و بهینه‌سازی مدل ANFIS قابلیت یادگیری (برای داده‌های آموزش) و قدرت تعمیم‌پذیری (با توجه به داده‌های آزمون) این مدل را بهبود داده و مقادیر خطا و انحراف معیار پاسخ را نیز کاهش داده است. در مجموع، مدل ترکیبی هوشمند ANFIS-PSO با ضریب همبستگی ۰/۹۶۱ بهترین عملکرد را در مقایسه با دو مدل ANFIS (با ۲/۳۴ درصد افزایش در ضریب همبستگی) و GP برای داده‌های مورد استفاده در این تحقیق داشته است.
- ضریب همبستگی مدل GP نسبت به مدل ANFIS حدود ۷ درصد کمتر می‌باشد، با این وجود مدل GP رابطه‌ای کاربرسندی برای تخمین مقاومت فشاری بتن‌های حاوی سرباره مس را بدون نیاز به مطالعات تکمیلی و هزینه اضافی ارائه داده است. رابطه پیشنهادی ارائه‌شده بر مبنای مدل GP، ضمن دقت و سادگی، امکان انجام تحلیل حساسیت و مطالعه پارامتری برای تعیین میزان اهمیت/تأثیر متغیرهای ورودی بر مقاومت فشاری بتن سبز حاوی سرباره مس را بدون انجام محاسبات پیچیده فراهم می‌سازد. نتایج محاسبه‌شده با این رابطه دارای همبستگی برابر با $R^2 = ۰/۸۷$ با نتایج تجربی می‌باشد و میزان انحراف معیار این نتایج نیز قابل قبول و کمتر از ۰/۲ است.
- نتایج تحلیل حساسیت با رابطه پیشنهادی ارائه‌شده در این تحقیق نشان داد که سن عمل‌آوری و مواد پودری به ترتیب دارای بیشترین اثر مثبت و نسبت آب به مواد پودری نیز بیشترین اثر منفی بر مقاومت فشاری بتن سبز را دارند. افزایش حجم ریزدانه‌ها نیز باعث افت شدید مقاومت فشاری این نوع بتن‌های سبز می‌شود.

– با استفاده از روش‌های هوشمند برای تنظیم پارامترهای مدل GP به همراه تکمیل و توسعه داده‌های آزمایشگاهی، ضمن کاهش میزان عدم قطعیت‌ها در مدل‌سازی، می‌توان رابطه دقیق‌تری برای تخمین مقاومت فشاری بتن سبز حاوی سرباره مس ارائه کرد. این موضوع می‌تواند به‌عنوان یکی از پیشنهادها برای مطالعات آینده مورد بررسی قرار گیرد.

References

- [1] Al-Jabri, K. S., Hisada, M., Al-Oraimi, S. K., & Al-Saidy, A. H. (2009). Copper slag as sand replacement for high performance concrete. *Cement and Concrete Composites*, 31(7), 483-488. <https://doi.org/10.1016/j.cemconcomp.2009.04.007>
- [2] Shi, C., Meyer, C., & Behnood, A. (2008). Utilization of copper slag in cement and concrete. *Resources, Conservation and Recycling*, 52(10), 1115-1120. <https://doi.org/10.1016/j.resconrec.2008.06.008>
- [3] Afshoon, I., Miri, M., & Mousavi, S. R. (2023). Using the Response Surface Method and Artificial Neural Network to Estimate the Compressive Strength of Environmentally Friendly Concretes Containing Fine Copper Slag Aggregates. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 47(6), 3415-3429. <https://doi.org/10.1007/s40996-023-01152-4>
- [4] Afshoon, I., Miri, M., & Mousavi, S. R. (2023). Evaluating the flexural behavior of green copper slag-contained steel fiber reinforced SCC beams with/without initial notches. *Construction and Building Materials*, 395, 132316. <https://doi.org/10.1016/j.conbuildmat.2023.132316>
- [5] Al-Jabri, K. S., Hisada, M., Al-Saidy, A. H., & Al-Oraimi, S. K. (2009). Performance of high strength concrete made with copper slag as a fine aggregate. *Construction and Building Materials*, 23(6), 2132-2140. <https://doi.org/10.1016/j.conbuildmat.2008.12.013>
- [6] Sharma, R., & Khan, R. A. (2017). Sustainable use of copper slag in self compacting concrete containing supplementary cementitious materials. *Journal of Cleaner Production*, 151, 179-192. <https://doi.org/10.1016/j.jclepro.2017.03.031>
- [7] Casagrande, C. A., Roque, J. S., Jochem, L. F., Correa, J. N., & Medeiros, A. (2023). Copper slag in cementitious composites: A systematic review. *Journal of Building Engineering*, 78, 107725. <https://doi.org/10.1016/j.jobbe.2023.107725>
- [8] Gupta, N., & Siddique, R. (2019). Strength and micro-structural properties of self-compacting concrete incorporating copper slag. *Construction and Building Materials*, 224, 894-908. <https://doi.org/10.1016/j.conbuildmat.2019.07.105>
- [9] Gupta, N., & Siddique, R. (2020). Durability characteristics of self-compacting concrete made with copper slag. *Construction and Building Materials*, 247(6), 118580. <https://doi.org/10.1016/j.conbuildmat.2020.118580>
- [10] Ambily, P. S., Umarani, C., Ravisankar, K., Prem, P. R., Bharatkumar, B. H., & Iyer, N. R. (2015). Studies on ultra high performance concrete incorporating copper slag as fine aggregate. *Construction and Building Materials*, 77, 233-240. <https://doi.org/10.1016/j.conbuildmat.2014.12.092>
- [11] Mousavi, S. R., Bahrpeyma, A., Afshoon, I., & Chakkoshi, M. (2024). Protecting the environment and natural resources using green Roller Compacted Concrete (RCC) containing fine and coarse recycled copper slag aggregates. *Process Safety and Environmental Protection*, 186, 664-678. <https://doi.org/10.1016/j.psep.2024.04.048>

- [12] Sheikh, E., Mousavi, S. R., & Afshoon, I. (2022). Producing green Roller Compacted Concrete (RCC) using fine copper slag aggregates. *Journal of Cleaner Production*, 368(1), 133005. <https://doi.org/10.1016/j.jclepro.2022.133005>
- [13] Sharifi, Y., Afshoon, I., Asad-Abadi, S., & Aslani, F. (2020). Environmental protection by using waste copper slag as a coarse aggregate in self-compacting concrete. *Journal of Environmental Management*, 271(5), 111013. <https://doi.org/10.1016/j.jenvman.2020.111013>
- [14] Orešković, M., Santos, J., Mladenović, G., & Rajaković-Ognjanović, V. (2023). The feasibility of using copper slag in asphalt mixtures for base and surface layers based on laboratory results. *Construction and Building Materials*, 384, 131285. <https://doi.org/10.1016/j.conbuildmat.2023.131285>
- [15] Ahani, G. (2022). Optimization of Coefficients of FRP-confined Concrete Columns Compressive Strength Estimation Models using Whale Algorithm. *Quarterly Scientific Journal of National University of Skills*, 19(3), 433-459. <https://doi.org/10.48301/ksa.2022.329031.2003>
- [16] Salimbahrami, S. R. (2021). Prediction of compressive strength of concrete with rubber fibers using artificial neural networks. *Quarterly Scientific Journal of National University of Skills*, 18(1), 81-98. <https://doi.org/10.48301/kssa.2021.131038>
- [17] Silva, S. (2007). *Gplab-a genetic programming toolbox for matlab*. Evolutionary and Complex Systems Group. <https://mech.fsv.cvut.cz/~leps/teaching/mmo/data/gplab.manual.3.pdf>
- [18] Ferreira, C. (2001). Gene expression programming: a new adaptive algorithm for solving problems. *Complex Systems*, 13(2), 87-129. <https://doi.org/10.48550/arXiv.cs/0102027>
- [19] Ashour, A. F., Alvarez, L. F., & Toropov, V. V. (2003). Empirical modelling of shear strength of RC deep beams by genetic programming. *Computers & Structures*, 81(5), 331-338. [https://doi.org/10.1016/S0045-7949\(02\)00437-6](https://doi.org/10.1016/S0045-7949(02)00437-6)
- [20] Chopra, P., Sharma, R. K., & Kumar, M. (2016). Prediction of Compressive Strength of Concrete Using Artificial Neural Network and Genetic Programming. *Advances in Materials Science and Engineering*, 2016(1), 7648467. <https://doi.org/10.1155/2016/7648467>
- [21] Fakharian, P., Naderpour, H., Haddad, A., Rafiean, A. H., & Eidgahee, D. R. (2018). A proposed model for compressive strength prediction of FRP-confined rectangular column in terms of Genetic expression Programming (GEP). *Concrete Research*, 11(1), 5-18. <https://doi.org/10.22124/JCR.2018.7162.1191>
- [22] Kumar, M., & TN, D. S. (2023). Genetic programming based compressive strength prediction model for green concrete. *Materials Today: Proceedings*. <https://doi.org/10.1016/j.matpr.2023.03.024>
- [23] Rezvani Sharif, M., & Sadri Tabaei Zavareh, S. M. R. (2020). Numerical analysis of the shear strength of circular reinforced concrete columns subjected to cyclic lateral loads using linear genetic programming. *Engineering Computations*, 37(7), 2517-2537. <https://doi.org/10.1108/EC-10-2018-0453>
- [24] Toghroli, A., Mohammadhassani, M., Suhatri, M., Shariati, M., & Ibrahim, Z. (2014). Prediction of shear capacity of channel shear connectors using the ANFIS model. *Steel and Composite Structures* 17(5), 623-639. <https://doi.org/10.12989/scs.2014.17.5.623>
- [25] Sobhani, J., Najimi, M., Pourkhorshidi, A. R., & Parhizkar, T. (2010). Prediction of the compressive strength of no-slump concrete: A comparative study of regression, neural network and ANFIS models. *Construction and Building Materials*, 24(5), 709-718. <https://doi.org/10.1016/j.conbuildmat.2009.10.037>

- [26] Jamali, F., Mousavi, S. R., Peyma, A. B., & Moodi, Y. (2022). Prediction of compressive strength of fiber-reinforced polymers-confined cylindrical concrete using artificial intelligence methods. *Journal of Reinforced Plastics and Composites*, 41(17-18), 679-704. <https://doi.org/10.1177/07316844211068116>
- [27] Nematollahzade, M., Tajadini, A., Afshoon, I., & Aslani, F. (2020). Influence of different curing conditions and water to cement ratio on properties of self-compacting concretes. *Construction and Building Materials*, 237(8), 117570. <https://doi.org/10.1016/j.conbuildmat.2019.117570>
- [28] Ponikiewski, T., & Gołaszewski, J. (2014). The influence of high-calcium fly ash on the properties of fresh and hardened self-compacting concrete and high performance self-compacting concrete. *Journal of Cleaner Production*, 72, 212-221. <https://doi.org/10.1016/j.jclepro.2014.02.058>
- [29] Sambangi, A., & E, A. (2021). Fresh and mechanical properties of SCC with fly ash and copper slag as mineral admixtures. *Materials Today: Proceedings*, 45, 6687-6693. <https://doi.org/10.1016/j.matpr.2020.12.144>
- [30] Hameed, M. S., Sekar, A. S. S., & Saraswathy, V. (2012). Strength and Permeability Characteristics Study of Self-Compacting Concrete Using Crusher Rock Dust and Marble Sludge Powder. *Arabian Journal for Science and Engineering*, 37(3), 561-574. <https://doi.org/10.1007/s13369-012-0201-x>
- [31] Ashrafiyan, A., Hamzehkolaei, N. S., Dwijendra, N. K. A., & Yazdani, M. (2022). An Evolutionary Neuro-Fuzzy-Based Approach to Estimate the Compressive Strength of Eco-Friendly Concrete Containing Recycled Construction Wastes. *Buildings*, 12(8), 1280. <https://doi.org/10.3390/buildings12081280>
- [32] Köksal, F., Şahin, Y., Beycioğlu, A., Gencel, O., & Brostow, W. (2012). Estimation of fracture energy of high-strength steel fibre-reinforced concrete using rule-based Mamdani-type fuzzy inference system. *Science and Engineering of Composite Materials*, 19(4), 373-380. <https://doi.org/10.1515/secm-2012-0017>
- [33] Robati, F. N., & Iranmanesh, S. (2020). Inflation rate modeling: Adaptive neuro-fuzzy inference system approach and particle swarm optimization algorithm (ANFIS-PSO). *MethodsX*, 7(1), 101062. <https://doi.org/10.1016/j.mex.2020.101062>
- [34] Zhou, Q., Zhu, F., Yang, X., Wang, F., Chi, B., & Zhang, Z. (2017). Shear capacity estimation of fully grouted reinforced concrete masonry walls using neural network and adaptive neuro-fuzzy inference system models. *Construction and Building Materials*, 153, 937-947. <https://doi.org/10.1016/j.conbuildmat.2017.07.171>
- [35] Safaeian Hamzehkolaei, N., & MiarNaeimi, F. (2021). A new hybrid multi-level cross-entropy-based moth-flame optimization algorithm. *Soft Computing*, 25(22), 14245-14279. <https://doi.org/10.1007/s00500-021-06109-1>
- [36] Zhang, G., Hamzehkolaei, N. S., Rashnoozadeh, H., Band, S. S., & Mosavi, A. (2022). Reliability assessment of compressive and splitting tensile strength prediction of roller compacted concrete pavement: introducing MARS-GOA-MCS. *International Journal of Pavement Engineering*, 23(14), 5030-5047. <https://doi.org/10.1080/10298436.2021.1990920>
- [37] Safaeian Hamzehkolaei, N., & Kadkhoda, N. (2023). An efficient ranked Voronoi diagram-based hybrid method for reliability-based structural analysis and design optimization. *Soft Computing*, 27(19), 13889-13910. <https://doi.org/10.1007/s00500-023-08450-z>
- [38] Moodi, Y., Ghasemi, M., & Mousavi, S. R. (2022). Estimating the compressive strength of rectangular fiber reinforced polymer-confined columns using multilayer perceptron,

- radial basis function, and support vector regression methods. *Journal of Reinforced Plastics and Composites*, 41(3-4), 130-146. <https://doi.org/10.1177/07316844211050168>
- [39] M. Nikbin, I., Rahimi R, S., & Allahyari, H. (2017). A new empirical formula for prediction of fracture energy of concrete based on the artificial neural network. *Engineering Fracture Mechanics*, 186, 466-482. <https://doi.org/10.1016/j.engfracmech.2017.11.010>
- [40] Brindha, D., & Nagan, S. (2011). Durability studies on copper slag admixed concrete. *Asian Journal of Civil Engineering*, 12(5), 563-578. https://www.researchgate.net/publication/268438151_Durability_studies_on_copper_slag_admixed_concrete
- [41] Al-Jabri, K. S., Al-Saidy, A. H., & Taha, R. (2011). Effect of copper slag as a fine aggregate on the properties of cement mortars and concrete. *Construction and Building Materials*, 25(2), 933-938. <https://doi.org/10.1016/j.conbuildmat.2010.06.090>
- [42] Brindha, D., & Nagan, S. (2010). Utilization of copper slag as a partial replacement of fine aggregate in concrete. *International Journal of Earth Sciences and Engineering*, 3(4), 579-585. https://www.researchgate.net/publication/289349982_Utilization_of_copper_slag_as_a_partial_replacement_of_fine_aggregate_in_concrete
- [43] Alnuaimi, A. (2009). Use of copper slag as a replacement for fine aggregate in reinforced concrete slender columns. *WIT Transactions on Engineering Science*, 64, 125-133. <https://doi.org/10.2495/MC090121>
- [44] Chavan, R., & Kulkarni, D. (2013). Performance of copper slag on strength properties as partial replace of fine aggregate in concrete mix design. *International Journal of Advanced Engineering and Research Studies*, 2(4), 95-98.
- [45] Arivalagan, S. (2013). Experimental study on the flexural behavior of reinforced concrete beams as replacement of copper slag as fine aggregate. *Journal of civil engineering and Urbanism*, 3(4), 176-182. <https://www.semanticscholar.org/paper/Experimental-Study-on-the-Flexural-Behavior-of-as-Arivalagan/3973223a3ea1bf34c30a316771c0b460900b6564>
- [46] Madheswaran, C. K., Ambily, P. S., Dattatreya, J. K., & Rajamane, N. P. (2014). Studies on use of Copper Slag as Replacement Material for River Sand in Building Constructions. *Journal of The Institution of Engineers (India): Series A*, 95(3), 169-177. <https://doi.org/10.1007/s40030-014-0084-9>
- [47] Raj, R. R., & Pillai, E. P. (2014). A way to promote sustainable development in construction industry by utilizing copper slag in concrete. *Ecology Environment and Conservation*, 20, 181-186. https://www.researchgate.net/publication/287021545_A_way_to_promote_sustainable_development_in_construction_industry_by_utilizing_copper_slag_in_concrete
- [48] Lye, C-Q., Koh, S-K., Mangabhai, R., & Dhir, R. K. (2015). Use of copper slag and washed copper slag as sand in concrete: a state-of-the-art review. *Magazine of Concrete Research*, 67(12), 665-679. <https://doi.org/10.1680/macr.14.00214>
- [49] Reddy, K. B. P., Tanuja, K., & Naidu, N. V. D. (2016). Use of copper slag in concrete and cement mortar as replacement of sand. *International Research Journal of Engineering and Technology*, 3(9), 254-260. <https://www.irjet.net/archives/V3/i9/IRJET-V3I984.pdf>
- [50] Mavroulidou, M. (2017). Mechanical Properties and Durability of Concrete with Water Cooled Copper Slag Aggregate. *Waste and Biomass Valorization*, 8(5), 1841-1854. <https://doi.org/10.1007/s12649-016-9819-3>

- [51] Achudhan, Deepavarsa, Vandhana, & Khalida. (2018). Effect of Copper slag in Structural behaviour of Reinforced Concrete Beams. *Materials Today: Proceedings*, 5(2), 6878-6887. <https://doi.org/10.1016/J.MATPR.2017.11.349>
- [52] Prem, P. R., Verma, M., & Ambily, P. S. (2018). Sustainable cleaner production of concrete with high volume copper slag. *Journal of Cleaner Production*, 193(3), 43-58. <https://doi.org/10.1016/j.jclepro.2018.04.245>
- [53] Bhoi, A. M., Patil, Y. D., Patil, H. S., & Kadam, M. P. (2018). Feasibility Assessment of Incorporating Copper Slag as a Sand Substitute to Attain Sustainable Production Perspective in Concrete. *Advances in Materials Science and Engineering*, 2018(1), 6502890. <https://doi.org/10.1155/2018/6502890>
- [54] Elamaran, R., Srinivasan, K., & Vimala, S. (2019). Use of copper slag for partial replacement to fine aggregate in concrete. *International Journal of Recent Technology and Engineerin*, 7(5), 559-564. <https://www.ijrte.org/portfolio-item/E11990275S19/>
- [55] Abdar Esfahani, S. M. R., Zareei, S. A., Madhkhan, M., Ameri, F., Rashidiani, J., & Taheri, R. A. (2021). Mechanical and gamma-ray shielding properties and environmental benefits of concrete incorporating GGBFS and copper slag. *Journal of Building Engineering*, 33, 101615. <https://doi.org/10.1016/j.jobbe.2020.101615>
- [56] Ezhilarasan, G., Babu, E., Raj, S., & Esakkiraj, P. (2020). Experimental Study on Concrete by Replacing Fine Aggregate Partially with Copper Slag. *International Journal of Engineering Research and*, 9(5), 933-935. <https://doi.org/10.17577/IJERTV9IS050668>
- [57] Panda, S., Sarkar, P., & Davis, R. (2021). Abrasion resistance and slake durability of copper slag aggregate concrete. *Journal of Building Engineering*, 35, 101987. <https://doi.org/10.1016/j.jobbe.2020.101987>
- [58] SrinivasC., H., & Muralan, S. M. (2015). Study of the Properties of Concrete Containing Copper Slag as a Fine Aggregate. *International Journal of Engineering Research and Technology*, 4(2). <https://doi.org/10.17577/IJERTV4IS020022>
- [59] Lori, A. R., Hassani, A., & Sedghi, R. (2019). Investigating the mechanical and hydraulic characteristics of pervious concrete containing copper slag as coarse aggregate. *Construction and Building Materials*, 197, 130-142. <https://doi.org/10.1016/j.conbuildmat.2018.11.230>
- [60] Khanzadi, M., & Behnood, A. (2009). Mechanical properties of high-strength concrete incorporating copper slag as coarse aggregate. *Construction and Building Materials*, 23(6), 2183-2188. <https://doi.org/10.1016/j.conbuildmat.2008.12.005>

جدول پیوست.

F _c (MPa)	d (day)	CS (kg)	CA (kg)	FA (kg)	P (kg)	W/P	تعداد نمونه	مرجع	ردیف
۱۶/۲۶-۳۴/۸۰	۷-۲۸	۰-۵۰	۱۱۶۶/۸۰	۵۳۶/۲۳	۴۴۵/۳۳	۰/۴۳	۱۶	[۴۰]	۱
۲۲/۲۴-۳۷/۶۸	۷-۲۸	۰-۱۰۰	۱۱۲۸/۰۰	۷۲۱/۰۰	۴۱۶/۰۰	۰/۵۰	۱۶	[۴۱]	۲
۲۸/۰۹-۳۷/۳۴	۲۸	۰-۶۰	۱۲۷۸/۰۰	۵۶۷/۰۰	۳۴۰/۰۰	۰/۴۵	۴	[۴۲]	۳
۲۲/۵۳-۳۱/۱۳	۲۸	۰-۱۰۰	۱۱۳۶/۰۰	۷۱۲/۶۰	۳۸۴/۳۰	۰/۵۹	۶	[۴۳]	۴
۱۴/۶۳-۳۴/۴۱	۷-۲۸	۰-۱۰۰	۱۱۹۲/۴۲	۷۴۱/۳۹	۳۶۸/۴۲	۰/۵۲	۱۸	[۴۴]	۵
۱۶/۰۰-۳۸/۰۹	۲۸	۰-۱۰۰	۱۲۰۱/۷۶	۶۵۶/۷۰	۳۷۲/۰۰	۰/۴۵-۰/۴۹	۶	[۴۵]	۶
۱۳/۶۰-۳۴/۴۰	۷-۲۸	۰-۱۰۰	۹۶۰/۰۰	۸۳۷-۸۸۵	۳۴۶-۴۱۶	۰/۴۶-۰/۵۵	۲۰	[۴۶]	۷
۱۸/۹۷-۲۷/۰۵	۷-۲۸	۰-۱۰۰	۱۰۷۰/۰۰	۸۱۱-۱۱۵۳	۳۴۰/۰۰	۰/۵۰	۱۰	[۴۷]	۸
۲۸/۰۰-۵۱/۶۰	۲۸	۰-۶۸	۱۰۱-۱۶۷۰	۷۹۰-۱۰۶۵	۲۵۰-۴۰۰	۰/۴۵-۰/۵۶	۳	[۴۸]	۹
۲۲/۴۰-۴۷/۲۰	۷-۹۰	۰-۱۰۰	۱۰۴۱/۰۰	۶۹۴/۰۰	۱۷۳۵/۰۰	۰/۴۵	۳۵	[۴۹]	۱۰
۱۸/۸۸-۴۰/۱۶	۷-۲۸	۰-۱۰۰	۱۱۹۰/۰۰	۵۹۵/۰۰	۳۹۷-۴۰۳	۰/۴۵-۰/۵۵	۲۴	[۵۰]	۱۱
۹/۳۷-۴۲/۱۳	۷-۲۸	۰-۱۰۰	۱۲۵۴/۰۰	۶۵۶/۰۰	۴۴۸/۰۰	۰/۴۴	۱۸	[۵۱]	۱۲
۲۶/۱۸-۴۸/۸۲	۷-۵۶	۱۰۰	۱۰۳۰/۰۰	۹۵۱-۱۱۲۲	۲۹۸-۴۵۹	۰/۵۷	۹	[۵۲]	۱۳
۲۳/۸۴-۵۱/۹۰	۷-۱۱۲	۰-۱۰۰	۱۱۱۵-۱۱۸۵	۶۶۷-۸۷۳	۴۴۸/۰۰	۰-۳۶-۰/۴۴	۶۰	[۵۳]	۱۴
۱۷/۹۲-۳۸/۲۳	۷-۲۸	۰-۳۰	۱۴۶۵/۳۵	۶۶۹/۳۱	۵۷۲/۲۸	۰/۴۳	۱۲	[۵۴]	۱۵
۲۰/۴۰-۴۷/۹۰	۷-۹۰	۰-۱۰۰	۷۸۰/۰۰	۸۲۰/۰۰	۴۵۰/۰۰	۰/۳۵	۲۵	[۵۵]	۱۶
۱۸/۷۲-۳۵/۳۶	۷-۲۸	۰-۳۰	۱۱۸۰/۰۰	۶۴۷/۰۰	۴۵۳/۴۰	۰/۴۵	۸	[۵۶]	۱۷
۳۸/۵۶-۵۱/۳۵	۲۸-۹۱	۰-۱۰۰	۱۲۱۵	۶۰۸	۴۵۰	۰/۴۲	۱۸	[۵۷]	۱۸
۱۷/۳۳-۳۲/۸۹	۷-۲۸	۲۰-۱۰۰	۱۲۱۸/۳۱	۷۹۲-۹۵۶	۳۶۶/۶۷	۰/۴۵	۱۰	[۵۸]	۱۹
۲۴/۲۳-۳۹/۱۰	۷-۹۱	۰-۶۰	۱۰۵۵/۰۰	۹۷۳/۰۰	۲۸۴/۰۰	۰/۳۸	۲۱	[۱۲]	۲۰
۱۷/۹۹-۴۰/۹۲	۳-۹۱	۰-۱۰۰	۷۰۰/۰۰	۹۵۰/۰۰	۴۰۰/۰۰	۰/۴۸-۰/۵۱	۸۸	[۱۳]	۲۱
۱۱/۴۸-۱۵/۰۱	۲۸	۰-۱۰۰	۱۱۴/۰۰	۳۴۰/۰۰	۳۴۰/۰۰	۰/۳۰	۷	[۵۹]	۲۲
۴۶/۴۲-۱۱۴/۸۶	۳-۹۱	۰-۱۰۰	۱۰۳۰-۱۱۶۸	۶۱۵-۶۸۷	۴۷۳-۵۰۰	۰/۳-۰/۴	۲۴	[۶۰]	۲۳