



Original Research

E-ISSN: 2538-4430

ISSN: 2382-9796

## Comparison of Estimated Performance of Soft Computing in Predicting Compressive Strength of Recycled Concrete

Seyed Reza Salim Bahrami <sup>1\*</sup>

<sup>1</sup> PhD, Department of Civil Engineering, Semnan University, Semnan, Iran.

### ARTICLE INFO

**Received:** 07.07.2021

**Revised:** 09.28.2021

**Accepted:** 11.30.2021

**Keyword:**

Support machining

Recycled aggregate concrete

K-fold cross validation

Compressive strength

Multiple linear regression

**\*Corresponding Author:**

Seyed Reza Salimbahrami

**Email:**

[salimbahrami@semnan.ac.ir](mailto:salimbahrami@semnan.ac.ir)

### ABSTRACT

Construction waste is one of the most important environmental concerns in the world. Iran is not an exception to this concern and more than 20 million tons of construction waste is produced annually in Tehran alone. To overcome this, researchers suggest recycling concrete and reusing it for construction and non-construction purposes. The aim of this paper was to predict the compressive strength of 28-day concrete with recycled aggregate using support vector machines (SVM) and multiple linear regression (MLR). Training and experimental data were developed for the development of the SVM model using 124 existing datasets from 11 published references. In the modeling process, an optimal network is considered to have the lowest mean square error and the highest correlation coefficient. Therefore, to evaluate the efficiency of the proposed model, the method of backup vector machines was compared with the method of multiple linear regression using the k-fold cross validation method. The results of comparing two 28-day compressive strength prediction tools including support vector machines and multiple linear regression using k-fold cross validation technique showed that support vector machines performed better compared to multiple linear regression method. Therefore, the support vector machine method can be mentioned as an effective method for predicting the 28-day compressive strength of recycled concrete.



## EXTENDED ABSTRACT

### Introduction

Our country has suitable mines for the preparation of raw materials for making concrete, the full use and reliance of which on distant targets is dangerous and harmful. Therefore, the researchers proposed a solution to this problem and the optimal use of recycled materials and construction debris called recycled aggregate concrete. Recycling waste from building demolition as recycled aggregate in concrete production can be a good solution to this problem.

The main purpose of this study was to establish a correlation between the input data based on a database derived from the results of valid experiments in the field of 28-day compressive strength for recycled and natural concrete samples and by modeling using support fragmentation machines and multiple linear regression. The weight of the materials used in the mixing plan of recycled and natural concrete and the target data (28-day compressive strength of concrete with recycled and natural aggregate) were established and the 28-day compressive strength predicted in proportion to the weight of input materials.

### Methodology

To teach the algorithm, experimental data performed in the field of concrete with recycled aggregate was used. According to these studies, mixing schemes tested by researchers was used. Therefore, in this study, a total of 124 laboratory samples were introduced, 99 samples (80%) were used to train and build the model and 25 samples (20%) were used to test and validate the results. Training and test data selection method included the range of all sets. The weight of materials used in the mixing plan included natural and recycled coarse aggregates, natural and recycled fine aggregates, cement, water and additives of super-lubricant type as input parameters to the neural network and its output was 28-day compressive strength of concrete. The statistical specifications and limits of changes in input and output parameters to the proposed models in soft calculations are presented in Table 2.

**Table 2. Statistical specifications and limits of changes in input and output parameters**

	Gravel	Sand	Recycled Gravel	Recycled sand	Cement	Water	additives	28-day compressive strength
	(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(MPa)
Mean	781.15	521.54	380.30	31.29	374.51	186.31	0.865	42.88
Max	1514	898	1126.8	668	449	271	4.9	60
Min	0	0	0	0	300	140	0	17.76
Standard standard deviation	407.19	249.14	354.57	110.83	44.53	23.92	1.46	8.9

### Results and discussion

The k-fold cross validation method was used to accurately calculate the efficiency of the proposed models in the training and testing stages.

Therefore, to more accurately evaluate the performance of a model, first the data set was divided into training and test subsets, and then the prediction model was created with the

training data set and its accuracy evaluated with the test data set.

Accordingly, the laboratory data set was divided into five approximately equal parts and based on this method, in each implementation, four parts of the five parts of the data were used to train the network and the remaining one was used to test the network. For each of the five parts performed, the average parameters related to network performance in the training and testing stages were calculated separately. In order to evaluate the accuracy and efficiency of the proposed model in correct prediction, the average evaluation criteria of R, MSE and MAE was obtained according to the relations 4 to 6, respectively, and compared with each other. The model with the highest R and the lowest MSE and MAE was the optimal and generalizable model.

The correlation coefficient (R) shows the degree of closeness of the predicted values and the actual values, and the value of this coefficient varies from -1 to +1, and the closer this value is to one, the greater the indication of the proper performance of the model or experimental relationship. If the absolute value of the correlation coefficient is greater than 0.8, there is a strong correlation between the two data sets.

## Conclusions

In this research, using methods based on soft calculations and having a sufficient number of laboratory data while taking into account the error and uncertainty in the data without time and cost, the amount of compressive strength for different uses of concrete with recycled aggregate was predicted. Therefore, in this study, laboratory results of 124 samples of natural and recycled concrete were used for training and testing in the proposed soft calculation methods. In the modeling process, the lowest mean square error and having the highest correlation coefficient simultaneously was considered an optimal network. The results showed that a high correlation coefficient was present in the 28-day compressive strength test outputs obtained from the backup machining, so this method was able to predict the 28-day compressive strength to the desired level.

Moreover, the error rate of the optimized model of the backup machining algorithm in this paper with this number of tested concrete samples was 20%. According to the available statistical information from the research results, 95 cases had errors less than 5%, 17 cases had errors between 5 to 10% and 9 cases had errors between 10 and 20%. Thus, in total, 98% of the results were predicted by the error backup machines method and less than 20% with laboratory samples. Therefore, it can be stated that the use of the optimal SVM model introduced in this study is a good method of predicting the 28-day compressive strength of natural and recycled concrete.

On the other hand, comparison of two 28-day compressive strength prediction tools including backup vector machines and multiple linear regression using k-fold cross validation technique showed that backup vector machines performed better than multiple linear regression method. Therefore, the support vector machine method can be mentioned as an effective method for predicting the 28-day compressive strength of recycled concrete.



# مقایسه عملکرد تخمینی محاسبات نرم در پیش‌بینی مقاومت فشاری بتن بازیافتی

سید رضا سلیم بهرامی<sup>\*۱</sup>

۱- دکتری، گروه مهندسی عمران، دانشگاه سمنان، سمنان، ایران.

## چکیده

## اطلاعات مقاله

از زیاله‌های ساختمانی به‌عنوان یکی از مهم‌ترین نگرانی‌های زیست‌محیطی در جهان می‌توان نام برد. این نگرانی در ایران نیز مستثنا نبوده و سالانه بیش از ۲۰ میلیون تن مواد زائد ساختمانی در تهران تولید می‌شود. برای برون‌رفت از این اتفاق، محققان بازیافت بتن و استفاده مجدد آن در مصارف ساختمانی و غیرساختمانی را پیشنهاد می‌دهند. این مقاله با هدف پیش‌بینی مقاومت فشاری بتن ۲۸ روزه با سنگ‌دانه بازیافتی با استفاده از روش ماشین‌های برداری پشتیبان (SVM) و رگرسیون خطی چندگانه (MLR) انجام‌شده است. داده‌های آموزش و آزمایش برای توسعه مدل SVM با استفاده از ۱۲۴ مجموعه داده موجود از ۱۱ مرجع منتشرشده، تهیه شده است. در فرایند مدل‌سازی، شبکه‌ای بهینه محسوب می‌شود که هم‌زمان با داشتن بالاترین ضریب همبستگی، کمترین میانگین مربعات خطا را نیز دارا باشد؛ از این رو ارزیابی کارایی مدل پیشنهادی، روش ماشین‌های برداری پشتیبان را با روش رگرسیون خطی چندگانه با استفاده از روش k-fold cross validation مقایسه شد. نتایج مقایسه دو ابزار پیش‌بینی نشان داد که ماشین‌های برداری پشتیبان از عملکرد مطلوب‌تری به نسبت روش رگرسیون خطی چندگانه برخوردار است. به همین دلیل می‌توان از روش ماشین‌های برداری پشتیبان به‌عنوان یک روش مؤثر برای پیش‌بینی مقاومت فشاری ۲۸ روزه بتن بازیافتی نام برد.

دریافت مقاله: ۱۴۰۰/۰۴/۱۶

بازنگری مقاله: ۱۴۰۰/۰۷/۰۶

پذیرش مقاله: ۱۴۰۰/۰۹/۰۹

## کلید واژگان:

ماشین برداری پشتیبان

بتن با سنگ‌دانه بازیافتی

k-fold cross validation

مقاومت فشاری

رگرسیون خطی چندگانه

\*نویسنده مسئول: سید رضا سلیم بهرامی

پست الکترونیکی:

salimbahrami@semnan.ac.ir



## مقدمه

کشور ما معادن مناسبی برای تهیه مصالح اولیه ساخت بتن دارد که استفاده تمام و تکیه بر آن در هدف‌های دور، خطرآفرین و زیان‌آور خواهد بود؛ بنابراین محققان راهکاری برای حل این موضوع و استفاده بهینه از مصالح بازیافتی و نخاله‌های ساختمانی با عنوان بتن با سنگ‌دانه بازیافتی ارائه کردند. بازیافت مواد زائد حاصل از تخریب ساختمان به‌عنوان سنگ‌دانه بازیافتی در تولید بتن می‌توان راه‌حل مناسبی برای حل این مشکل باشد [۱-۴].

نتایج تحقیقات مقیمی و همکاران [۵] در سال ۲۰۱۱ و چوی<sup>۱</sup> و همکاران [۶] در سال ۲۰۱۲ نشان داد که سنگ‌دانه بازیافتی بتنی به‌مراتب کیفیت مکانیکی و دوام کمتری نسبت به سنگ‌دانه طبیعی دارد. همچنین مطالعات عقیلی لطف و رضائیان‌پور [۷] در سال ۲۰۱۸ نشان داد که جایگزینی سنگ‌دانه طبیعی با سنگ‌دانه بازیافتی بتنی منجر به افت مقاومت‌های مکانیکی و همچنین افزایش درصد جذب آب بتن می‌شود. در مجموع ماسه بازیافتی بتنی تأثیر منفی بیشتری بر رفتار مکانیکی بتن با سنگ‌دانه بازیافتی نسبت به شن بازیافتی بتنی دارد [۸].

نتایج وگی<sup>۲</sup> و همکاران [۹] در سال ۲۰۱۳ نشان داد که مقدار کاهش یا افزایش مقاومت بتن با سنگ‌دانه‌های بازیافتی بسته به نسبت آب به سیمان، جنس و شرایط رطوبتی سنگ‌دانه‌ها و درصد جایگزینی سنگ‌دانه‌های بازیافتی وابسته است. آکاش<sup>۳</sup> و همکاران [۱۰] نیز با بررسی مشخصات مکانیکی بتن با سنگ‌دانه بازیافتی دریافت که در نسبت‌های پایین آب به سیمان، مقاومت بتن بازیافتی نسبت به بتن معمولی کاهش می‌یابد.

در سال‌های اخیر، پژوهشگران با به‌کارگیری روش‌های مختلف جهت پیش‌بینی و ارزیابی مشخصات سنگ‌دانه‌های بازیافتی با استفاده از ماشین‌های یادگیری بر پایه اطلاعات برآمدند. یکی از این روش‌ها، روش شبکه عصبی مصنوعی می‌باشد که به‌صورت فزاینده در حال گسترش است. چوپرا<sup>۴</sup> و همکاران [۱۱] با انجام آنالیز رگرسیون به ایجاد ارتباط بین مشخصات سنگ‌دانه درشت‌دانه بازیافتی و مقاومت فشاری مرتبط براساس ۲۰ مجموعه داده پرداختند. نادرپور و همکاران [۱۲] در سال ۲۰۱۸ به کمک شبکه عصبی مصنوعی توانستند پیش‌بینی مناسبی از مقاومت فشاری بتن با سنگ‌دانه بازیافتی با استفاده از ورودی‌هایی نظیر نسبت آب به سیمان، جذب آب، سنگ‌دانه درشت‌دانه طبیعی و بازیافتی، سنگ‌دانه ریزدانه و نسبت آب به کل مصالح ارائه نمایند. دوآن<sup>۵</sup> و همکاران [۱۳] نیز با استفاده از ۱۴ پارامتر ورودی و با استفاده از ۱۶۸ داده، یک مدل شبکه عصبی مصنوعی را پیشنهاد دادند. دنگ<sup>۶</sup> و همکاران [۱۴] نیز با استفاده از تئوری یادگیری عمیق و به کمک شبکه‌های عصبی حلقوی به‌پیش‌بینی مقاومت فشاری پرداختند. همچنین لیانگ<sup>۷</sup> و همکاران [۱۵] مقاومت فشاری بتن بازیافتی در معرض چرخه خشک-مرطوب را مورد بررسی قرار داده و با استفاده از مدل شبکه عصبی پس انتشار<sup>۸</sup> به تخمین مقاومت فشاری بتن بازیافتی در معرض چرخه خشک-مرطوب پرداختند.

از سوی دیگر روش ماشین برداری پشتیبان به‌عنوان روش جدید در حال گسترش است. از ویژگی‌های این روش می‌توان به قدرت حل مسائل برای داده‌های با ابعاد بالا، توانایی رگرسیون غیرخطی با استفاده از توابع کرنل و همچنین گیر نیفتادن در ماکزیمم‌های محلی اشاره کرد. نادرپور و همکاران [۱۶] به پیش‌بینی ظرفیت برش پانچ دال‌های بتنی مسلح شده با FRP به کمک ماشین بردار پشتیبان پرداختند. نتایج آنان حاکی از عملکرد مناسب روش ماشین بردار

<sup>1</sup> Choi

<sup>2</sup> Wagih

<sup>3</sup> Rao akash

<sup>4</sup> Chopra

<sup>5</sup> Duan

<sup>6</sup> Deng

<sup>7</sup> Liang

<sup>8</sup> Back propagation artificial neural networks (BP-ANNs)

پشتیبان است. کیان<sup>۱</sup> و همکاران [۱۷] در سال ۲۰۱۹ و جلال<sup>۲</sup> و همکاران [۱۸] در سال ۲۰۱۹ و غنی‌زاده و همکاران [۱۹] در سال ۲۰۱۸ با بررسی عملکرد ماشین بردار پشتیبان به نسبت شبکه عصبی مصنوعی به ترتیب در زمینه پیش‌بینی مشخصات فشاری بتن محیط دریایی، بتن کامپوزیت و بتن پلاستیکی بنتونیتی به این نتیجه دست یافتند که روش یادشده نسبت به روش شبکه عصبی مصنوعی از عملکرد بهتری برخوردار است. از سوی دیگر نتایج محققان از کارایی بالای روش ماشین‌های برداری پشتیبان برای پیش‌بینی خواص بتن سخت شده از جمله مقاومت فشاری، مقاومت کششی و مدول الاستیسیته اشاره دارد [۲۰-۲۴].

هدف اصلی این پژوهش آن است که براساس یک پایگاه داده برگرفته از نتایج آزمایش‌های معتبر در زمینه مقاومت فشاری ۲۸ روزه برای نمونه‌های بتن بازیافتی و طبیعی و به کمک مدل‌سازی با استفاده از روش‌های ماشین‌های برداری پشتیبان و رگرسیون خطی چندگانه، ارتباطی بین داده‌های ورودی (وزن مصالح مورد استفاده در طرح اختلاط بتن بازیافتی و طبیعی) و داده هدف (مقاومت فشاری ۲۸ روزه بتن با سنگ‌دانه بازیافتی و طبیعی) برقرار کند و مقاومت فشاری ۲۸ روزه را متناسب با وزن مصالح ورودی پیش‌بینی گردد.

### الگوریتم ماشین‌های بردار پشتیبان

ماشین بردار پشتیبان (SVM) به‌عنوان روش یادگیری ماشین توسط کورتز و واپنیک در سال ۱۹۹۵ معرفی شد [۲۵]. این روش از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی از جمله شبکه‌های عصبی پرسپترون نشان داده است. شبکه‌های SVM برخلاف اغلب انواع شبکه‌های عصبی به جای اینکه خطای مدل‌سازی یا طبقه‌بندی را کاهش دهند، ریسک عملیاتی را به‌عنوان تابع هدف در نظر می‌گیرند و مقدار بهینه آن را محاسبه می‌کنند. همچنین این روش عملکرد خوبی در مسائل شناسایی الگو دارد. همچنین توانایی آن در عملکرد بهتر بر مبنای نمونه‌های آموزشی محدود، آن را در مسائل محاسباتی، روشی ایده‌آل ساخته است؛ یعنی در جاهایی که تولید داده مشکل یا هزینه‌بر است عملکرد خوبی دارد، یکی از این مسائل محاسباتی تعیین مقاومت فشاری در بتن بازیافتی است. یکی از ویژگی‌های منحصر به فرد ماشین‌های بردار پشتیبان، معماری واحد آن است در این روش برخلاف شبکه‌های عصبی مفاهیمی مانند لایه و تابع انتقال، یا تعداد نرون وجود ندارد و تعداد پارامترهای بهینه‌سازی برای یک مسئله خاص به مراتب کمتر است. از طرف دیگر به علت ساختار ماشین‌های بردار پشتیبان قابلیت تعمیم‌پذیری آن در مواجهه با داده‌های کم مطلوب است.

ماشین‌های بردار پشتیبان، الگوریتم‌های بسیار قدرتمندی در دسته‌بندی و تفکیک داده‌ها هستند به‌خصوص زمانی که با سایر روش‌های یادگیری ماشین مانند روش جنگل تصادفی تلفیق شوند. برای ساخت مدل ماشین بردار پشتیبان تنظیم پارامترهای C و  $\epsilon$  بر عهده کاربر است. پارامتر C می‌تواند مقادیری بین بازه صفر تا بی‌نهایت را داشته باشد. نقش آن تعادل بین کمینه کردن ریسک تجربی و بیشینه کردن قابلیت تعمیم‌دهی است. با این پارامتر چگونگی اثرگذاری اصل کمینه کردن ریسک ساختاری نمایان می‌شود [۲۶]. وقتی به این پارامتر مقادیر بزرگی داده می‌شود، SVM اجازه وقوع خطا به داده‌های آموزش را نمی‌دهد و یک مدل پیچیده خواهد شد. به همین دلیل قابلیت تعمیم‌دهی کاهش می‌یابد. از طرفی اگر به این پارامتر، مقادیر کوچکی داده شود، ماشین بردارهای پشتیبان نسبت به وقوع خطا بر داده‌های آموزش حساسیت کمتری نشان می‌دهد. پارامتر  $\epsilon$  نیز می‌تواند مقادیر بین صفر تا بی‌نهایت را داشته باشد. با افزایش  $\epsilon$  تعداد بردارهای پشتیبان کاهش پیدا می‌کند که مطلوب است اما افزایش  $\epsilon$  برای رسیدن به این هدف نادرست است؛ زیرا باعث افزایش خطا بین مقادیر خروجی مدل و خروجی مطلوب می‌شود. از طرفی مقادیر بسیار کوچک  $\epsilon$  باعث افزایش

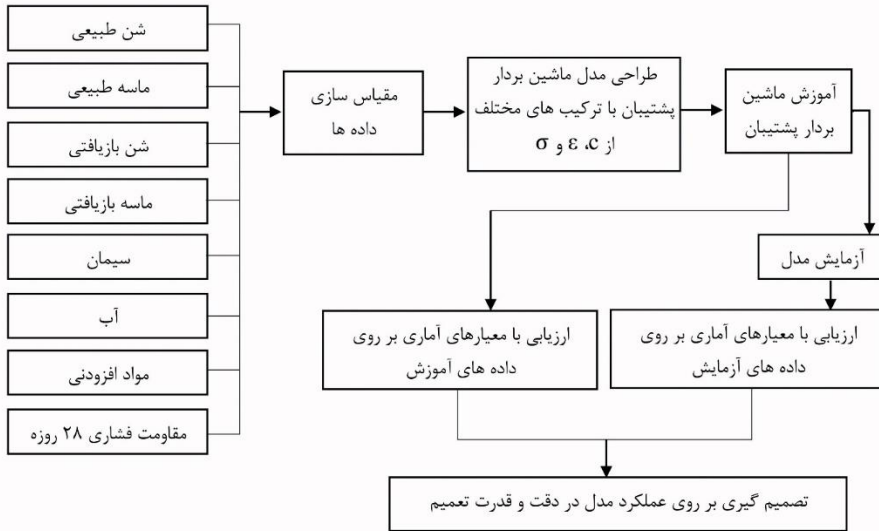
<sup>1</sup> Qian

<sup>2</sup> Jalal

<sup>3</sup> Support Vector Machine (SVM)

تعداد بردارهای پشتیبان می‌شود و احتمال خطر بیش آموزش شدن را افزایش می‌دهد [۲۷].  $RBF^1$  به‌عنوان تابع kernel توانسته عملکرد بهتری در مدل‌سازی الگوریتم ماشین‌های برداری پشتیبان از خود نشان دهد. شکل ۱ روند اجرای مدل بهینه ماشین برداری پشتیبان ارائه شده است.

مقادیر  $c$ ،  $\varepsilon$  و بقیه پارامترهای kernel مطابق جدول ۱ به‌صورت سعی و خطا به‌دست آمد. همچنین نتایج عملکرد مدل بهینه ساخته‌شده بر داده‌های آموزش و آزمایش با استفاده از شاخص‌های آماری ضریب همبستگی (R) و MSE در جدول ۱ نشان داده شده است.



شکل ۱. روند اجرای ماشین برداری پشتیبان

جدول ۱. مشخصات مدل بهینه SVM

نوع داده	C	$\varepsilon$	$\sigma$	تعداد بردارهای پشتیبان	R	MSE
آموزش	۱۰۰۰	۰/۰۰۸	۱	۴۸	۰/۹۷۶۴	۰/۰۰۱۶۹۱
آزمون					۰/۹۷۴	۰/۰۰۱۸۳۴

### رگرسیون خطی چندگانه

$$Y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_{p-1} + \varepsilon_i \quad i = 1, 2, \dots, n \quad (1)$$

در رابطه ۱،  $Y_i$  مقدار پیش‌بینی شده متغیر وابسته  $X_1$  تا  $X_{p-1}$ ، متغیرهای پیش‌بینی کننده مستقل  $\beta_0$ ، مقدار  $Y$  در زمانی است که کل متغیرهای مستقل ( $X_1$  تا  $X_{p-1}$ ) برابر صفر باشند،  $\beta_1$  تا  $\beta_p$  ضریب رگرسیون تخمینی و  $\varepsilon$  خطای مدل رگرسیونی را نشان می‌دهد.

<sup>1</sup> Radial Basis Function

رابطه ۱ را می‌توان به فرم ماتریسی زیر نیز تعریف کرد:

$$Y_{n \times 1} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} \quad X_{n \times p} = \begin{bmatrix} 1 & X_{11} & X_{12} & \cdots & X_{1,p-1} \\ 1 & X_{21} & X_{22} & \cdots & X_{2,p-1} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & X_{n1} & X_{n2} & \cdots & X_{n,p-1} \end{bmatrix} \quad (2)$$

ماتریس  $X$  مقادیر مشاهده شده  $p-1$  متغیر را برای  $n$  نفر نشان می‌دهد. بردار  $Y$  نیز مقادیر مشاهده شده متغیر وابسته برای نمونه‌ای به حجم  $n$  می‌باشد. در یک مدل رگرسیونی  $\beta_1$ ها پارامترهای مدل می‌باشد و به کمک روش‌های مختلفی مانند روش حداقل مربعات و روش درست‌نمایی بیشینه برآورد می‌شوند.  $\epsilon_i$ ها نیز جملات خطا نامیده می‌شوند و دارای توزیع طبیعی با میانگین صفر و واریانس  $\sigma^2$  هستند.

فرایندی که با آن بتوان مناسب‌ترین مدل رگرسیون را هم از لحاظ دقت کافی و هم از لحاظ حداقل تعداد متغیرهای مستقل یافت، روش انجام رگرسیون می‌باشد. برای یافتن مناسب‌ترین مدل رگرسیون خطی چندگانه، روش‌های متعددی وجود دارد که چهار نوع از مهم‌ترین آنها شامل روش ورودی<sup>۱</sup>، روش پیش‌رو<sup>۲</sup>، روش پس‌رو<sup>۳</sup> و روش گام به گام<sup>۴</sup> است. در روش ورودی تنها مدل رگرسیون یک گام دارد و در آن گام ورود همان متغیرهای پیشنهادی محقق در معادله رگرسیون مدنظر است. در این روش، هدف، یافتن مدل نهایی نیست بلکه محقق می‌خواهد وجود یک رابطه بین متغیرها را که طبق یک فرضیه مطرح شده است تأیید یا رد کند؛ بنابراین این روش برای مطالعات تأییدی به کار می‌رود. روش پیش‌رو به این ترتیب طراحی شده است که ابتدا یک متغیر مستقل وارد معادله می‌شود. این متغیر باید بیشترین همبستگی را با متغیر وابسته داشته باشد. آن‌گاه در مراحل بعد نیز هر بار تنها یک متغیر مستقل که همبستگی زیادی با متغیر وابسته دارد، به معادله اضافه می‌شود. این کار تا آنجا ادامه می‌یابد که متغیر مستقلی که بر متغیر وابسته تأثیر دارد، باقی نماند.

روش پس‌رو، عکس روش پیش‌رو است؛ یعنی در این روش ابتدا همه متغیرهای مستقل پیشنهادی محقق در معادله در نظر گرفته می‌شوند و از یک معادله رگرسیون خطی چندگانه بهره‌برداری می‌شود. آن‌گاه برای دست یافتن به مدل مناسب، متغیرهایی که ضرورت ندارند یکی‌یکی از مدل کنار گذاشته می‌شوند. این کار تا زمانی ادامه می‌یابد که متغیر مستقل غیرمهمی برای خروج از مدل باقی نماند. در روش گام به گام به این ترتیب که در این روش ابتدا یک متغیر مستقل (متغیری که همبستگی زیادی با متغیر وابسته دارد) وارد مدل می‌شود و ضرورت آن برای باقی ماندن در مدل بررسی می‌شود. سپس متغیر دوم وارد می‌شود و ضرورت حذف آن نیز بررسی می‌گردد. این کار تا آنجا ادامه می‌یابد که هیچ متغیر مستقلی شرط ورود به مدل و خروج از آن را نداشته باشد. به‌طور کلی برای برآورد پارامترهای مدل رگرسیون خطی چندگانه باید از روش ماتریسی استفاده کرد که این روش‌ها را معمولاً با نرم‌افزار انجام می‌دهند و پارامترها را برآورد می‌کنند.

<sup>1</sup> Enter

<sup>2</sup> Forward

<sup>3</sup> Backward

<sup>4</sup> Stepwise



## داده‌های مورد استفاده

برای آموزش الگوریتم از اطلاعات آزمایش‌های انجام‌شده در حوزه بتن با سنگ‌دانه بازیافتی استفاده شده است. طبق این مطالعات از طرح‌های اختلاط مورد آزمایش بار<sup>۱</sup> و همکاران [۲۸]، یانگ<sup>۲</sup> و همکاران [۲۹]، اتربریا<sup>۳</sup> و همکاران [۳۰]، ایوانجلیستا و د بریتو<sup>۴</sup> [۳۱]، والریا کورینالدسی<sup>۵</sup> [۳۲]، فونسکا<sup>۶</sup> و همکاران [۳۳]، کو و پون<sup>۷</sup> [۳۴]، پون و همکاران [۳۵]، گومز سوپرون<sup>۸</sup> [۳۶]، خطیب [۳۷] و فان<sup>۹</sup> و همکاران [۳۸] استفاده شده است؛ از این رو در این تحقیق در مجموع ۱۲۴ نمونه آزمایشگاهی معرفی شده، تعداد ۹۹ نمونه (۸۰ درصد) برای آموزش و ساخت مدل و ۲۵ نمونه (۲۰ درصد) برای آزمایش و صحت‌سنجی نتایج استفاده شده است. نحوه انتخاب داده‌های آموزش و آزمایش به‌گونه‌ای است که محدوده تمامی مجموعه‌ها را شامل شود. وزن مصالح مورد استفاده در طرح اختلاط شامل سنگ‌دانه درشت‌دانه طبیعی و بازیافتی، سنگ‌دانه ریزدانه طبیعی و بازیافتی، سیمان، آب و مواد افزودنی از نوع فوق‌روان‌کننده به‌عنوان پارامترهای ورودی به شبکه عصبی می‌باشد و خروجی آن مقاومت فشاری ۲۸ روزه بتن است. در ادامه مشخصات آماری و حدود تغییرات پارامترهای ورودی و خروجی به مدل‌های پیشنهادی در محاسبات نرم در جدول ۲ و همچنین مشخصات پارامترهای ورودی و خروجی نتایج آزمایشگاهی در پیوست الف ارائه شده است.

جدول ۲. مشخصات آماری و حدود تغییرات پارامترهای ورودی و خروجی

مقاومت فشاری ۲۸ روزه	مواد افزودنی	آب	سیمان	ماسه بازیافتی	شن بازیافتی	ماسه طبیعی	شن طبیعی
(MPa)	(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(kg)
۴۲/۸۸	۰/۸۶۵	۱۸۶/۳۱	۳۷۴/۵۱	۳۱/۲۹	۳۸۰/۳۰	۵۲۱/۵۴	۷۸۱/۱۵
۶۰	۴/۹	۲۷۱	۴۴۹	۶۶۸	۱۱۲۶/۸	۸۹۸	۱۵۱۴
۱۷/۷۶	۰	۱۴۰	۳۰۰	۰	۰	۰	۰
۸/۹	۱/۴۶	۲۳/۹۲	۴۴/۵۳	۱۱۰/۸۳	۳۵۴/۵۷	۲۴۹/۱۴	۴۰۷/۱۹

به‌منظور کاستن تأثیرات شاخصه‌های ناخواسته در نتایج آزمایشگاهی، تمامی پارامترهای ورودی و هدف قبل از آموزش در ماشین یادگیری، نرمال‌سازی و مقیاس‌سازی می‌شوند [۳۹]. مرحله مقیاس‌سازی به این دلیل مهم است که تابع تبدیل تنها مقادیر بین ۰ تا ۱ را شناسایی می‌کند و برای مقیاس‌سازی داده‌ها از کمترین و بیشترین مقدار ۰/۱ تا ۰/۹ استفاده می‌شود. توابع مقیاس‌سازی برای داده‌های ورودی و هدف از رابطه ۳ استفاده شده است [۴۰].


$$d_{\text{scaled}} = (0.9 - 0.1) \times \left[ \frac{d - d_{\min}}{d_{\max} - d_{\min}} \right] + 0.1 \quad (3)$$

<sup>1</sup> Barra<sup>2</sup> Yang<sup>3</sup> Etxeberria<sup>4</sup> Evangelista and de Brito<sup>5</sup> Valeria Corinaldesi<sup>6</sup> Fonseca<sup>7</sup> Kou and Poon<sup>8</sup> Go'mez-Soberon<sup>9</sup> Fan

که در رابطه ۲،  $d$  پارامتر ورودی و خروجی است.

### ارزیابی روش‌های پیشنهادی

برای محاسبه دقیق کارایی مدل‌های پیشنهادی در مراحل آموزش و آزمون از روش  $k$ -fold cross validation استفاده شده است [۴۱]؛ از این رو برای ارزیابی دقیق‌تر کارایی یک مدل، ابتدا مجموعه داده به زیرمجموعه‌های آموزش و آزمون تقسیم می‌شود و سپس مدل پیش‌بینی با مجموعه داده آموزش ایجاد و دقت آن با مجموعه داده آزمون ارزیابی مطابق شکل ۲ می‌گردد.



شکل ۲. روند اجرای روش  $k$ -fold cross validation

بر این اساس، مجموعه داده‌های آزمایشگاهی به پنج قسمت تقریباً مساوی تقسیم می‌شوند و بر اساس این روش، در هر اجرا، چهار قسمت از پنج قسمت از داده‌ها برای آموزش شبکه و یک قسمت باقیمانده برای آزمون شبکه استفاده گردید. این عمل برای هر پنج قسمت انجام‌شده، میانگین پارامترهای مربوط به کارایی شبکه در مراحل آموزش و آزمون به‌طور جداگانه محاسبه گردید. به‌منظور بررسی دقت و کارایی مدل پیشنهادی در پیش‌بینی صحیح، باید میانگین معیارهای ارزیابی  $R$ ،  $MSE$  و  $MAE$  به‌ترتیب مطابق رابطه‌های ۴ تا ۶ به‌دست آورد و با یکدیگر مقایسه کرد. آن مدلی که بیشترین  $R$  و کمترین  $MSE$  و  $MAE$  را دارا باشد به‌عنوان مدل بهینه و تعمیم‌پذیر می‌توان نام برد. ضریب همبستگی ( $R$ ) میزان نزدیکی مقادیر پیش‌بینی‌شده و مقادیر واقعی را نشان می‌دهد و مقدار این ضریب از -۱ تا +۱ متغیر است و هرچه این مقدار به یک نزدیک‌تر باشد، نشان‌دهنده عملکرد مناسب مدل یا رابطه تجربی است. در صورتی که مقدار قدر مطلق ضریب همبستگی، بزرگ‌تر از  $0/8$  باشد، همبستگی قوی میان دو مجموعه داده وجود دارد [۴۲]. رابطه ۴ بیانگر ضریب همبستگی ( $R$ ) می‌باشد.

$$R = \frac{\sum_{i=1}^n t_i o_i - n \bar{t} \bar{o}}{\sqrt{\sum_{i=1}^n (t_i - \bar{t})^2 \sum_{i=1}^n (o_i - \bar{o})^2}} \quad (۴)$$

در رابطه ۴،  $O_i$  مقدار خروجی مدل برای  $i$ -امین داده،  $t_i$  مقدار واقعی برای  $i$ -امین خروجی،  $\bar{O}$  میانگین خروجی‌های مدل،  $\bar{t}$  میانگین مقادیر واقعی،  $n$  تعداد کل نمونه‌ها است.

$MSE$  نیز به‌عنوان میانگین مربعات خطاها که از اختلاف مقدار پیش‌بین شده توسط مدل یا رابطه موجود با مقدار واقعی مطابق رابطه ۵ به‌دست می‌آید. مقدار  $MSE$  از صفر تا بی‌نهایت متغیر می‌باشد و هرچه مقدار آن به صفر نزدیک‌تر باشد، نشانگر عملکرد مناسب مدل است.

$$MSE = \frac{1}{n} \sum_{i=1}^n (o_i - t_i)^2 \quad (۵)$$


MAE معرف میانگین قدرمطلق خطاها که از اختلاف مقدار پیش‌بینی شده توسط مدل یا رابطه موجود با مقدار واقعی مطابق رابطه ۶ به‌دست می‌آید. مقدار MAE از صفر تا بی‌نهایت متغیر می‌باشد و هرچه مقدار آن به صفر نزدیک‌تر باشد، نشانگر عملکرد مناسب مدل است.

$$MAE = \frac{1}{n} \sum_{i=1}^n |o_i - t_i| \quad (۶)$$

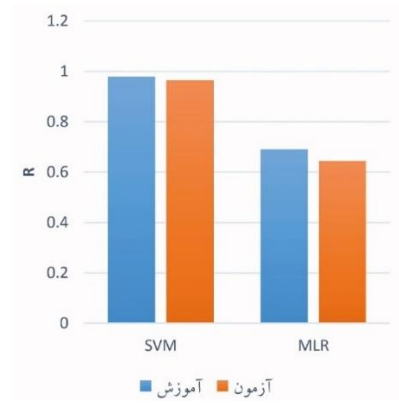
جدول ۳ مقادیر معیارهای ارزیابی کارایی دو مدل پیش‌بینی در مرحله آموزش و آزمون را نشان می‌دهد. همچنین مقایسه میانگین مقادیر ارزیابی کارایی در دو مرحله آموزش و آزمون در شکل ۳ نشان داده شده است.

جدول ۳. مقادیر معیارهای ارزیابی کارایی دو مدل پیش‌بینی در مرحله آموزش و آزمون


	SVM						MLR					
	آموزش			آزمون			آموزش			آزمون		
	R	MSE	MAE	R	MSE	MAE	R	MSE	MAE	R	MSE	MAE
گروه داده‌های ۱	۰/۹۸۱	۰/۰۰۱۷۳۲	۰/۰۰۳۷	۰/۹۷۹	۰/۰۰۱۹۹۲	۰/۰۰۴	۰/۶۹۲	۰/۰۰۳۵۲	۰/۰۰۵۳	۰/۷۳۴	۰/۰۰۴۵۲	۰/۰۰۶
گروه داده‌های ۲	۰/۹۷۸	۰/۰۰۱۷۷۲	۰/۰۰۳۸	۰/۹۶۴	۰/۰۰۱۸۳۲	۰/۰۰۳۸	۰/۶۲۴	۰/۰۰۳۷۵	۰/۰۰۵۵	۰/۵۹۳	۰/۰۰۳۹۳	۰/۰۰۵۶
گروه داده‌های ۳	۰/۹۷۳	۰/۰۰۱۶۹۲	۰/۰۰۳۷	۰/۹۶۷	۰/۰۰۱۷۵۶	۰/۰۰۳۷	۰/۷۲۶	۰/۰۰۴۸۱۴	۰/۰۰۶۲	۰/۵۸۳	۰/۰۰۳۷۶۱	۰/۰۰۵۵
گروه داده‌های ۴	۰/۹۸۲	۰/۰۰۱۶۴۵	۰/۰۰۳۶	۰/۹۷۳	۰/۰۰۱۶۷۳	۰/۰۰۳۶	۰/۷۱۹	۰/۰۰۴۳۰۱	۰/۰۰۵۸	۰/۶۲۸	۰/۰۰۳۵۲۱	۰/۰۰۵۳
گروه داده‌های ۵	۰/۹۷۶	۰/۰۰۱۶۱۲	۰/۰۰۳۶	۰/۹۴	۰/۰۰۱۶۹۸	۰/۰۰۳۷	۰/۶۹۳	۰/۰۰۴۹۶۲	۰/۰۰۶۳	۰/۶۸۲	۰/۰۰۳۴۱۹	۰/۰۰۵۲
میانگین	۰/۹۷۸۴	۰/۰۰۱۶۹	۰/۰۰۳۷	۰/۹۶۵	۰/۰۰۱۷۹	۰/۰۰۳۷	۰/۶۹	۰/۰۰۴۲۷۱	۰/۰۰۵۸	۰/۶۴۴	۰/۰۰۳۸۳	۰/۰۰۵۲



(ب)




(الف)



(ج)

شکل ۳. مقایسه میانگین مقادیر ارزیابی کارایی الف) ضریب همبستگی (R) ب) MSE ج) MAE در دو مرحله آموزش و آزمون

مطابق جدول ۳ و شکل ۳، در روش ماشین‌های بردار پشتیبان مقادیر R که نشان‌دهنده میزان خطای پیش‌بینی برای مقاومت فشاری است نسبت روش رگرسیون خطی چندگانه به عدد ۱ نزدیک‌تر است و این بدان معناست که روش ماشین بردار پشتیبان نسبت روش MLR از دقت بالاتری برخوردار است. از سوی دیگر مقایسه R، MSE و MAE روش هوش مصنوعی در مقابل روش رگرسیون خطی چندگانه، نشان از برتری هوش مصنوعی در محاسبات نرم دارد.



شکل ۴. نمودار مقایسه نتایج آزمایشگاهی با نتایج حاصل از ماشین برداری پشتیبان و رگرسیون خطی چندگانه

شکل ۴، نمودار مقایسه نتایج آزمایشگاهی با نتایج حاصله از ماشین برداری پشتیبان و رگرسیون خطی چندگانه را نشان می‌دهد. با توجه به مقایسه صورت گرفته، میزان خطای محاسبه شده برای ۹ نمونه در روش ماشین برداری پشتیبان و ۴۴ نمونه در روش رگرسیون خطی چندگانه بالای ۱۵ درصد بوده است که حاکی از میزان خطای بالای روش رگرسیون خطی چندگانه در مقابل روش ماشین‌های برداری پشتیبان در پیش‌بینی مقاومت فشاری ۲۸ روزه بتن بازیافتی را دارد.

## نتیجه‌گیری

در این پژوهش، با استفاده از روش‌های مبتنی بر محاسبات نرم و با داشتن تعداد کافی داده‌های آزمایشگاهی، ضمن لحاظ کردن خطا و عدم قطعیت موجود در داده‌ها می‌توان بدون صرف زمان و هزینه، میزان مقاومت فشاری را برای مصارف مختلف بتن با سنگ‌دانه بازیافتی پیش‌بینی کرد؛ از این رو در این پژوهش از نتایج آزمایشگاهی ۱۲۴ نمونه بتن طبیعی و بازیافتی به‌منظور آموزش و آزمون در روش‌های پیشنهادی محاسبات نرم استفاده شده است که نتایج به‌دست‌آمده از مدل‌سازی شبکه، حاکی از آن است که استفاده از این نوع شبکه‌ها برای پیش‌بینی میزان مقاومت فشاری ۲۸ روزه بتن مناسب است. در فرایند مدل‌سازی، شبکه‌ای بهینه محسوب می‌شود که هم‌زمان با داشتن بالاترین ضریب همبستگی، کمترین میانگین مربعات خطا را نیز دارا باشد. نتایج نشان می‌دهد که ضریب همبستگی بالایی در خروجی‌های آزمایش مقاومت فشاری ۲۸ روزه حاصل از ماشین برداری پشتیبان موجود است؛ بنابراین این روش می‌تواند قابلیت پیش‌بینی مقاومت فشاری ۲۸ روزه را در حد مطلوب و مناسب داشته باشد.

همچنین مقدار خطای مدل بهینه‌شده الگوریتم ماشین برداری پشتیبان در این مقاله با این تعداد نمونه بتن آزمایش شده ۲۰ درصد است. با توجه به اطلاعات آماری موجود حاصل از نتایج تحقیق، ۹۵ مورد خطای کمتر از ۵ درصد، ۱۷ مورد خطای بین ۵ تا ۱۰ درصد و ۹ مورد خطای بین ۱۰ تا ۲۰ درصد داشتند که در مجموع ۹۸ درصد از نتایج پیش‌بینی شده توسط روش ماشین‌های برداری پشتیبان خطایی کمتر از ۲۰ درصد با نمونه‌های آزمایشگاهی داشته‌اند؛ بنابراین می‌توان بیان کرد استفاده از مدل بهینه معرفی شده SVM در این پژوهش، راهگشای مناسبی برای پیش‌بینی مقاومت فشاری ۲۸ روزه بتن طبیعی و بازیافتی به شمار می‌رود. از سوی دیگر مقایسه دو ابزار پیش‌بینی مقاومت فشاری ۲۸ روزه شامل ماشین‌های برداری پشتیبان و رگرسیون خطی چندگانه با استفاده از تکنیک k-fold cross validation نشان داد که ماشین‌های برداری پشتیبان از عملکرد مطلوب‌تری به نسبت روش رگرسیون خطی چندگانه برخوردار هستند؛ از این رو می‌توان از روش ماشین‌های برداری پشتیبان به‌عنوان یک روش مؤثر برای پیش‌بینی مقاومت فشاری ۲۸ روزه بتن بازیافتی نام برد.

## References

- [1] De Brito, J., & Saikia, N. (2012). *Recycled aggregate in concrete: use of industrial, construction and demolition waste*. Springer Science & Business Media. <https://doi.org/10.1007/978-1-4471-4540-0>
- [2] Debieb, F., Courard, L., Kenai, S., & Degeimbre, R. (2009). Roller compacted concrete with contaminated recycled aggregates. *Construction and Building Materials*, 23(11), 3382-3387. <https://doi.org/10.1016/j.conbuildmat.2009.06.031>
- [3] Dilbas, H., Çakır, Ö., & Atış, C. D. (2019). Experimental investigation on properties of recycled aggregate concrete with optimized Ball Milling Method. *Construction and Building Materials*, 212, 716-726. <https://doi.org/10.1016/j.conbuildmat.2019.04.007>
- [4] Dimitriou, G., Savva, P., & Petrou, M. F. (2018). Enhancing mechanical and durability properties of recycled aggregate concrete. *Construction and Building Materials*, 158, 228-235. <https://doi.org/10.1016/j.conbuildmat.2017.09.137>

- [5] Moghimi, M., Shafigh, P., Berengian, J., & Nemati, K. (2010). Experimental Investigation of Effects of Microsilica and Superplasticizer on Some Mechanical Properties of Recycled Concrete Made of Crushed Concrete. *Civil Engineering (Faculty of Engineering)*, 21(2), 153-162. <https://www.sid.ir/fa/journal/ViewPaper.aspx?id=134394>
- [6] Choi, W.-C., & Yun, H.-D. (2012). Compressive behavior of reinforced concrete columns with recycled aggregate under uniaxial loading. *Engineering Structures*, 41, 285-293. <https://doi.org/10.1016/j.engstruct.2012.03.037>
- [7] Aghili, L. M., & Ramezani-pour, A. M. (2018). Investigation on the correlations between different physical and mechanical properties of concrete made with recycled concrete aggregate. *MODARES CIVIL ENGINEERING JOURNAL*, 18(3), 153-167. <https://www.sid.ir/en/Journal/ViewPaper.aspx?ID=710135>
- [8] Salimbahrami, S. R., Shakeri, R., & Habibi Hajikolae, B. (2021). Proposed Mix Design of Recycled Concrete Used in Urban Concrete Tables Using Neural Network. *Karafan Quarterly Scientific Journal*, 17(4), 209-230. <https://doi.org/10.48301/kssa.2021.128404>
- [9] Wagih, A. M., El-Karmoty, H. Z., Ebid, M., & Okba, S. H. (2013). Recycled construction and demolition concrete waste as aggregate for structural concrete. *HBRC Journal*, 9(3), 193-200. <https://doi.org/10.1016/j.hbrcj.2013.08.007>
- [10] Rao, A., Jha, K. N., & Misra, S. (2007). Use of aggregates from recycled construction and demolition waste in concrete. *Resources, Conservation and Recycling*, 50(1), 71-81. <https://doi.org/10.1016/j.resconrec.2006.05.010>
- [11] Chopra, P., Sharma, R. K., & Kumar, M. (2015). Artificial Neural Networks for the Prediction of Compressive Strength of Concrete. *International Journal of Applied Science and Engineering*, 13(3), 187-204. [https://doi.org/10.6703/IJASE.2015.13\(3\).187](https://doi.org/10.6703/IJASE.2015.13(3).187)
- [12] Naderpour, H., Rafiean, A. H., & Fakharian, P. (2018). Compressive strength prediction of environmentally friendly concrete using artificial neural networks. *Journal of Building Engineering*, 16, 213-219. <https://doi.org/10.1016/j.jobe.2018.01.007>
- [13] Duan, Z. H., Kou, S. C., & Poon, C. S. (2013). Prediction of compressive strength of recycled aggregate concrete using artificial neural networks. *Construction and Building Materials*, 40, 1200-1206. <https://doi.org/10.1016/j.conbuildmat.2012.04.063>
- [14] Deng, F., He, Y., Zhou, S., Yu, Y., Cheng, H., & Wu, X. (2018). Compressive strength prediction of recycled concrete based on deep learning. *Construction and Building Materials*, 175, 562-569. <https://doi.org/10.1016/j.conbuildmat.2018.04.169>
- [15] Liang, C., Qian, C., Chen, H., & Kang, W. (2018). Prediction of Compressive Strength of Concrete in Wet-Dry Environment by BP Artificial Neural Networks. *Advances in Materials Science and Engineering*, 2018, 1-11. <https://doi.org/10.1155/2018/6204942>
- [16] Naderpour, H., Noormohammadi, E., & Fakharian, P. (2017). Prediction of punching shear capacity of RC slabs using support vector machine. *Concrete Research*, 10(2), 95-107. <https://doi.org/10.22124/JCR.2017.2417>
- [17] Ling, H., Qian, C., Kang, W., Liang, C., & Chen, H. (2019). Combination of Support Vector Machine and K-Fold cross validation to predict compressive strength of concrete in marine environment. *Construction and Building Materials*, 206(3), 355-363. <https://doi.org/10.1016/j.conbuildmat.2019.02.071>
- [18] Jalal, M., Grasley, Z., Gurganus, C., & Bullard, J. W. (2020). RETRACTED: Experimental investigation and comparative machine-learning prediction of

- strength behavior of optimized recycled rubber concrete. *Construction and Building Materials*, 256(4), 119478. <https://doi.org/10.1016/j.conbuildmat.2020.119478>
- [19] Ghanizadeh, A. R., Abbaslou, H., Amlashi, A. T., & Alidoust, P. (2019). Modeling of bentonite/sepiolite plastic concrete compressive strength using artificial neural network and support vector machine. *Frontiers of Structural and Civil Engineering*, 13(1), 215-239. <https://doi.org/10.1007/s11709-018-0489-z>
- [20] Aiyer, B. G., Kim, D., Karingattikkal, N., Samui, P., & Rao, P. R. (2014). Prediction of compressive strength of self-compacting concrete using least square support vector machine and relevance vector machine. *KSCE Journal of Civil Engineering*, 18(6), 1753-1758. <https://doi.org/10.1007/s12205-014-0524-0>
- [21] Akande, K. O., Owolabi, T. O., Twaha, S., & Olatunji, S. O. (2014). Performance comparison of SVM and ANN in predicting compressive strength of concrete. *IOSR Journal of Computer Engineering*, 16(5), 88-94. <https://doi.org/10.9790/0661-16518894>
- [22] Gupta, S. (2007). Support vector machines based modelling of concrete strength. *World Academy of Science, Engineering and Technology*, 36(1), 305-311. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.360.1088&rep=rep1&type=pdf>
- [23] Yan, K., Xu, H., Shen, G., & Liu, P. (2013). Prediction of Splitting Tensile Strength from Cylinder Compressive Strength of Concrete by Support Vector Machine. *Advances in Materials Science and Engineering*, 2013(2), 1-13. <https://doi.org/10.1155/2013/597257>
- [24] Yazdi, J. S., Kalantary, F., & Yazdi, H. S. (2013). Prediction of Elastic Modulus of Concrete Using Support Vector Committee Method. *Journal of Materials in Civil Engineering*, 25(1), 9-20. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0000507](https://doi.org/10.1061/(ASCE)MT.1943-5533.0000507)
- [25] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- [26] Dibike, Y. B., Velickov, S., Solomatine, D., & Abbott, M. B. (2001). Model Induction with Support Vector Machines: Introduction and Applications. *Journal of Computing in Civil Engineering*, 15(3), 208-216. [https://doi.org/10.1061/\(ASCE\)0887-3801\(2001\)15:3\(208\)](https://doi.org/10.1061/(ASCE)0887-3801(2001)15:3(208))
- [27] Samui, P. (2008). Support vector machine applied to settlement of shallow foundations on cohesionless soils. *Computers and Geotechnics*, 35(3), 419-427. <https://doi.org/10.1016/j.compgeo.2007.06.014>
- [28] Ferreira, L., Brito, J. d., & Barra, M. (2011). Influence of the pre-saturation of recycled coarse concrete aggregates on concrete properties. *Magazine of Concrete Research*, 63(8), 617-627. <https://doi.org/10.1680/mac.2011.63.8.617>
- [29] Yang, K.-H., Chung, H.-S., & Ashour, A. F. (2008). Influence of Type and Replacement Level of Recycled Aggregates on Concrete Properties. *American Concrete Institute Materials Journal*, 105(3), 289-296. <https://bradscholars.brad.ac.uk/handle/10454/7768>
- [30] Etxeberria, M., Vázquez, E., Marí, A., & Barra, M. (2007). Influence of amount of recycled coarse aggregates and production process on properties of recycled aggregate concrete. *Cement and Concrete Research*, 37(5), 735-742. <https://doi.org/10.1016/j.cemconres.2007.02.002>
- [31] Evangelista, L., & de Brito, J. (2007). Mechanical behaviour of concrete made with fine recycled concrete aggregates. *Cement and Concrete Composites*, 29(5), 397-401. <https://doi.org/10.1016/j.cemconcomp.2006.12.004>

- [32] Corinaldesi, V. (2010). Mechanical and elastic behaviour of concretes made of recycled-concrete coarse aggregates. *Construction and Building Materials*, 24(9), 1616-1620. <https://doi.org/10.1016/j.conbuildmat.2010.02.031>
- [33] Fonseca, N., de Brito, J., & Evangelista, L. (2011). The influence of curing conditions on the mechanical performance of concrete made with recycled concrete waste. *Cement and Concrete Composites*, 33(6), 637-643. <https://doi.org/10.1016/j.cemconcomp.2011.04.002>
- [34] Kou, S.-C., & Poon, C.-S. (2008). Mechanical properties of 5-year-old concrete prepared with recycled aggregates obtained from three different sources. *Magazine of Concrete Research*, 60(1), 57-64. <https://doi.org/10.1680/mac.2007.00052>
- [35] Poon, C. S., Shui, Z. H., Lam, L., Fok, H., & Kou, S. C. (2004). Influence of moisture states of natural and recycled aggregates on the slump and compressive strength of concrete. *Cement and Concrete Research*, 34(1), 31-36. [https://doi.org/10.1016/S0008-8846\(03\)00186-8](https://doi.org/10.1016/S0008-8846(03)00186-8)
- [36] Gómez-Soberón, J. M. V. (2002). Porosity of recycled concrete with substitution of recycled concrete aggregate: An experimental study. *Cement and Concrete Research*, 32(8), 1301-1311. [https://doi.org/10.1016/S0008-8846\(02\)00795-0](https://doi.org/10.1016/S0008-8846(02)00795-0)
- [37] Khatib, J. M. (2005). Properties of concrete incorporating fine recycled aggregate. *Cement and Concrete Research*, 35(4), 763-769. <https://doi.org/10.1016/j.cemconres.2004.06.017>
- [38] Fan, C.-C., Huang, R., Hwang, H., & Chao, S.-J. (2016). Properties of concrete incorporating fine recycled aggregates from crushed concrete wastes. *Construction and Building Materials*, 112, 708-715. <https://doi.org/10.1016/j.conbuildmat.2016.02.154>
- [39] Jariwala, V. H., Patel, P. V., & Purohit, S. P. (2013). Strengthening of RC Beams Subjected to Combined Torsion and Bending with GFRP Composites. *Procedia Engineering*, 51(4), 282-289. <https://doi.org/10.1016/j.proeng.2013.01.038>
- [40] Salimbahrami, S. R. (2021). Prediction of compressive strength of concrete with rubber fibers using artificial neural networks. *Karafan Quarterly Scientific Journal*, 18(1), 81-98. <https://doi.org/10.48301/kssa.2021.131038>
- [41] Olson, D. L., & Delen, D. (2008). *Advanced data mining techniques*. Springer Science & Business Media. <https://link.springer.com/book/10.1007/978-3-540-76917-0>
- [42] Smith, M. (1993). *Neural Networks for Statistical Modeling* International Thomson Computer Press. <https://www.amazon.com/Neural-Networks-Statistical-Modeling-Murray/dp/1850328420>



## پیوست

الف) مشخصات پارامترهای ورودی و خروجی نتایج آزمایشگاهی

جدول الف ۱: مشخصات پارامترهای ورودی و خروجی نتایج آزمایشگاهی

ردیف	مرجع	شن طبیعی	ماسه طبیعی	شن بازمانده	ماسه بازمانده	سیمان	آب	افروزی	مقاومت فشاری ۲۸ روزه
		(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(MPa)
۱		۰	۶۶۰.۷	۱۱۰۶.۸	۰	۳۲۵	۱۷۸.۷	۲	۴۵
۲		۰	۶۱۳.۹	۱۱۰۹.۴	۰	۳۴۵	۱۸۹.۷	۲	۵۲
۳		۰	۵۸۶.۸	۱۱۲۶.۸	۰	۳۶۵	۱۸۶.۵	۲	۵۶
۴		۰	۵۸۶.۸	۱۱۲۶.۸	۰	۳۶۵	۱۸۶.۶	۲	۵۵
۵		۰	۶۶۰.۷	۱۱۰۶.۸	۰	۳۲۵	۱۷۸.۷	۰.۵۸	۴۰
۶		۱۲۰۶.۹	۷۱۰.۵	۰	۰	۳۲۵	۱۷۸.۷	۱.۲۸	۶۰
۷		۱۲۰.۷	۷۶۵.۱	۰	۰	۳۰۰	۱۶۵	۱.۴	۴۴
۸		۹۰۵.۲	۷۶۵.۱	۲۶۵.۷	۰	۳۰۰	۱۶۵	۱.۶۶	۴۲.۵
۹	اتریش و همکاران [۳۰]	۶۰۸.۹	۷۳۹	۵۳۶.۴	۰	۳۱۸	۱۶۵	۱.۹	۴۶
۱۰		۰	۶۸۳.۲	۱۱۲۳.۴	۰	۳۲۵	۱۶۲	۱.۹	۴۶
۱۱		۸۴۶.۵۲	۴۷۰.۸۷	۰	۰	۴۰۰	۱۸۴.۷۸۲۶۱	۰.۴۳۴۷۸	۴۳.۲۸
۱۲		۸۴۶.۵۲	۴۷۰.۸۷	۰	۰	۴۰۰	۱۸۴.۷۸۲۶۱	۰.۴۳۴۷۸	۴۳.۶۵
۱۳		۸۲۰.۸۷	۴۵۶.۵۲۲	۰	۰	۴۰۰	۲۰۴.۳۴۷۸۳	۰	۲۷.۹۱
۱۴		۸۲۰.۸۷	۴۵۶.۵۲۲	۰	۰	۴۰۰	۲۰۴.۳۴۷۸۳	۰	۲۷
۱۵		۴۲۳.۳۳	۰	۴۲۳.۳۳	۳۱۶	۴۰۰	۱۸۲	۰	۴۱.۲۸
۱۶		۴۲۳.۳۳	۰	۴۲۳.۳۳	۳۱۶	۴۰۰	۱۸۲	۰	۴۱.۳۷
۱۷		۴۱۰.۵	۰	۴۱۰.۵	۴۸۷	۴۰۰	۲۰۸	۰	۴۴.۳۹
۱۸		۴۱۰.۵	۰	۴۱۰.۵	۴۸۷	۴۰۰	۲۰۸	۰	۴۴.۹۵
۱۹		۸۴۶.۵۲	۴۷۰.۸۷	۰	۰	۴۰۰	۱۸۴.۷۸۲۶۱	۰	۳۳.۸۲

ردیف	مرجع	شن طبیعی	ماسه طبیعی	شن بازیافتی	ماسه بازیافتی	سیمان	آب	افزودنی	مقاومت فشاری ۲۸ روزه
		(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(MPa)
۲۰	ایوانجیستا و د بریتو [۳۱]	۱۱۸۸	۶۶۸	۰	۰	۳۸۰	۱۵۵.۸	۴.۹	۵۹.۳
۲۱		۱۱۸۲	۵۹۸	۰	۵۲	۳۸۰	۱۶۰.۶	۴.۹	۵۹
۲۲		۱۱۷۵	۵۲۹	۰	۱۰۳	۳۸۰	۱۶۵.۴	۴.۹	۵۷.۳
۲۳		۱۱۶۸	۴۶۰	۰	۱۵۴	۳۸۰	۱۷۰.۲	۴.۹	۵۷.۱
۲۴		۱۱۶۲	۳۲۷	۰	۲۵۴	۳۸۰	۱۷۵.۶	۴.۹	۵۸.۸
۲۵		۱۱۶۲	۰	۰	۵۰۹	۳۸۰	۱۸۰.۹	۴.۹	۵۴.۸
۲۶		۱۰۱۶	۷۳۰	۰	۰	۳۵۰	۱۷۵	۱.۶۸	۳۹.۵
۲۷		۷۱۱	۷۳۰	۲۹۷	۰	۳۵۰	۱۷۵	۱.۶۸	۳۶.۷
۲۸		۵۰۸	۷۳۰	۴۹۴	۰	۳۵۰	۱۷۵	۱.۶۸	۳۸
۲۹		۰	۷۳۰	۹۸۹	۰	۳۵۰	۱۷۵	۱.۶۸	۳۶
۳۰	یاتک و همکاران [۳۲]	۱۰۱۶	۵۱۱	۰	۲۰۰	۳۵۰	۱۷۵	۱.۶۸	۳۰.۴
۳۱		۱۰۱۶	۳۶۵	۰	۳۳۴	۳۵۰	۱۷۵	۱.۶۸	۲۹.۳
۳۲		۱۰۱۶	۷۳۰	۰	۶۶۸	۳۵۰	۱۷۵	۱.۶۸	۲۷
۳۳		۷۱۱	۷۳۰	۲۸۲	۰	۳۵۰	۱۷۵	۱.۶۸	۳۲
۳۴		۵۰۸	۷۳۰	۴۶۹	۰	۳۵۰	۱۷۵	۱.۶۸	۳۰.۴
۳۵		۰	۷۳۰	۹۳۸	۰	۳۵۰	۱۷۵	۱.۶۸	۲۹.۵
۳۶		۱۱۰۹	۷۳۲	۰	۰	۳۵۰	۱۴۰	۱.۲	۵۸.۶
۳۷		۱۰۹۶	۷۲۳	۰	۰	۳۴۰	۱۵۳	۱	۵۶.۱
۳۸		۱۰۸۴	۷۱۵	۰	۰	۳۳۰	۱۶۵	۰.۸	۵۱.۲
۳۹		۱۰۷۲	۷۰۸	۰	۰	۳۲۰	۱۷۶	۰.۶	۴۷.۱
۴۰	والریا کورینالدسی [۳۳]	۱۰۶۴	۷۰۲	۰	۰	۳۱۰	۱۸۶	۰.۴	۴۳.۹
۴۱		۵۵۶	۷۳۲	۵۱۹	۰	۳۵۰	۱۴۰	۱.۲	۴۳.۳
۴۲		۵۴۹	۷۲۳	۵۱۲	۰	۳۴۰	۱۵۳	۱	۳۹.۶
۴۳		۵۴۳	۷۱۵	۵۰۷	۰	۳۳۰	۱۶۵	۰.۸	۳۸.۱
۴۴		۵۳۷	۷۰۸	۵۰۲	۰	۳۲۰	۱۷۶	۰.۶	۳۴.۵

ردیف	مرجع	شن طبیعی	ماسه طبیعی	شن بازیافتی	ماسه بازیافتی	سیمان	آب	افزودنی	مقاومت فشاری ۲۸ روزه
		(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(MPa)
۴۵		۵۳۳	۷۰۲	۴۹۷	۰	۳۱۰	۱۸۶	۰.۴	۳۱.۶
۴۶		۵۵۳	۷۳۲	۵۲۳	۰	۳۵۰	۱۴۰	۱.۲	۴۶.۱
۴۷		۵۴۷	۷۲۳	۵۱۷	۰	۳۴۰	۱۵۳	۱	۴۵.۸
۴۸		۵۴۱	۷۱۵	۵۱۱	۰	۳۳۰	۱۶۵	۰.۸	۳۹.۹
۴۹		۵۳۵	۷۰۸	۵۰۶	۰	۳۲۰	۱۷۶	۰.۶	۳۶.۳
۵۰		۵۳۱	۷۰۲	۵۰۱	۰	۳۱۰	۱۸۶	۰.۴	۳۴.۷
۵۱		۱۵۱۴	۱۶۷	۰	۰	۴۴۶	۱۹۱.۶	۰	۵۱
۵۲		۱۵۱۴	۱۶۷	۰	۰	۴۴۶	۱۹۱.۶	۰	۵۱.۷
۵۳		۱۵۱۴	۱۶۷	۰	۰	۴۴۶	۱۹۱.۶	۰	۴۸.۸
۵۴		۱۵۱۴	۱۶۷	۰	۰	۴۴۶	۱۹۱.۶	۰	۵۰.۵
۵۵		۱۳۱۶.۴	۱۶۷	۱۸۵.۷	۰	۴۴۶	۱۹۱.۶	۰	۴۸.۸
۵۶		۱۳۱۶.۴	۱۶۷	۱۸۵.۷	۰	۴۴۶	۱۹۱.۶	۰	۵۰.۶
۵۷	فونسکا و همکاران [۳۳]	۱۳۱۶.۴	۱۶۷	۱۸۵.۷	۰	۴۴۶	۱۹۱.۶	۰	۴۸
۵۸		۱۳۱۶.۴	۱۶۷	۱۸۵.۷	۰	۴۴۶	۱۹۱.۶	۰	۵۰.۱
۵۹		۱۰۲۱.۴	۱۶۷	۴۶۴.۳	۰	۴۴۶	۱۹۴.۴	۰	۵۱.۳
۶۰		۱۰۲۱.۴	۱۶۷	۴۶۴.۳	۰	۴۴۶	۱۹۴.۴	۰	۵۰.۳
۶۱		۱۰۲۱.۴	۱۶۷	۴۶۴.۳	۰	۴۴۶	۱۹۴.۴	۰	۴۷.۷
۶۲		۱۰۲۱.۴	۱۶۷	۴۶۴.۳	۰	۴۴۶	۱۹۴.۴	۰	۴۸.۸
۶۳		۵۲۸.۶	۱۶۷	۹۲۸.۶	۰	۴۴۶	۱۹۸.۷	۰	۵۱.۲
۶۴		۵۲۸.۶	۱۶۷	۹۲۸.۶	۰	۴۴۶	۱۹۸.۷	۰	۴۹.۲
۶۵		۵۲۸.۶	۱۶۷	۹۲۸.۶	۰	۴۴۶	۱۹۸.۷	۰	۴۷.۲
۶۶		۵۲۸.۶	۱۶۷	۹۲۸.۶	۰	۴۴۶	۱۹۸.۷	۰	۵۰
۶۷	باراو همکاران [۳۸]	۱۰۵۴.۷	۶۶۷.۷۹	۰	۰	۳۷۸.۸۵	۱۸۹.۴۳	۰	۵۹
۶۸		۱۰۵۴.۷	۶۶۷.۷۹	۰	۰	۳۷۸.۸۵	۱۸۹.۴۳	۰	۵۸.۸
۶۹		۸۴۳.۷۶	۶۶۷.۷۹	۱۷۸.۳۸	۰	۳۷۸.۸۵	۱۸۹.۴۳	۰	۵۲.۸

ردیف	مرجع	شن طبیعی	ماسه طبیعی	شن بازیافتی	ماسه بازیافتی	سیمان	آب	افزودنی	مقاومت فشاری ۲۸ روزه
		(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(MPa)
۷۰		۸۴۳.۷۶	۶۶۷.۷۹	۱۷۸.۳۸	۰	۳۷۸.۸۵	۱۸۹.۴۳	۰	۵۲.۹
۷۱		۵۲۷.۳۵	۶۶۷.۷۹	۴۴۵.۹۵	۰	۳۷۸.۸۵	۱۸۹.۴۳	۰	۵۰.۴
۷۲		۵۲۷.۳۵	۶۶۷.۷۹	۴۴۵.۹۵	۰	۳۷۸.۸۵	۱۸۹.۴۳	۰	۴۹
۷۳		۰	۶۶۷.۷۹	۸۹۱.۸۹	۰	۳۷۸.۸۵	۱۸۹.۴۳	۰	۴۸
۷۴		۱۱۲۷	۶۹۰	۰	۰	۳۵۵	۱۹۵	۰	۴۳.۸
۷۵		۹۰۲	۶۹۰	۲۰۵	۰	۳۵۵	۱۹۵	۰	۴۱.۹
۷۶		۵۶۴	۶۹۰	۵۴۳	۰	۳۵۵	۱۹۵	۰	۴۱.۲
۷۷		۰	۶۹۰	۱۰۸۵	۰	۳۵۵	۱۹۵	۰	۴۱.۶
۷۸	گروپون [۳۴]	۹۰۲	۶۹۰	۱۹۳	۰	۳۵۵	۱۹۵	۰	۳۸.۲
۷۹		۵۶۴	۶۹۰	۵۲۰	۰	۳۵۵	۱۹۵	۰	۳۶.۴
۸۰		۰	۶۹۰	۱۰۳۸	۰	۳۵۵	۱۹۵	۰	۳۷.۸
۸۱		۹۰۲	۶۹۰	۱۹۹	۰	۳۵۵	۱۹۵	۰	۳۶.۵
۸۲		۵۶۴	۶۹۰	۵۳۴	۰	۳۵۵	۱۹۵	۰	۳۴.۳
۸۳		۰	۶۹۰	۱۰۶۸	۰	۳۵۵	۱۹۵	۰	۳۵.۶
۸۴		۱۰۸۶	۶۶۷	۰	۰	۳۵۳	۲۱۴	۰	۴۸.۳
۸۵		۱۰۸۰	۶۶۷	۰	۰	۳۵۳	۲۲۱	۰	۴۰.۲
۸۶		۱۰۹۳	۶۶۶	۰	۰	۳۵۳	۲۰۹	۰	۴۶
۸۷		۸۶۱	۶۶۰	۲۰۹	۰	۳۵۳	۲۱۷	۰	۴۴.۹
۸۸	پون و همکاران [۳۵]	۸۵۳	۶۶۱	۲۰۲	۰	۳۵۳	۲۳۰	۰	۴۳.۲
۸۹		۸۶۴	۶۶۱	۲۱۶	۰	۳۵۳	۲۰۶	۰	۴۳
۹۰		۵۲۷	۶۴۷	۵۱۳	۰	۳۵۳	۲۲۹	۰	۴۴.۷
۹۱		۵۲۴	۶۴۷	۴۹۶	۰	۳۵۳	۲۴۷	۰	۳۹.۷
۹۲		۵۳۱	۶۴۹	۵۳۱	۰	۳۵۳	۲۰۷	۰	۳۸.۱
۹۳		۰	۶۲۵	۹۹۳	۰	۳۵۳	۲۴۱	۰	۴۶.۸
۹۴		۰	۶۲۵	۹۵۹	۰	۳۵۳	۲۷۱	۰	۴۳.۳

ردیف	مرجع	شن طبیعی	ماسه طبیعی	شن بازیافتی	ماسه بازیافتی	سیمان	آب	افزودنی	مقاومت فشاری ۲۸ روز
		(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(MPa)
۹۵		۰	۶۲۵	۱۰۲۶	۰	۳۵۳	۲۰۹	۰	۳۹.۱
۹۶		۰	۶۶۲	۹۰۳	۰	۴۰۰	۲۰۷.۶	۰	۳۴.۵
۹۷	گرم سوزون [۳۶]	۳۸۳	۶۶۲	۵۷۳	۰	۴۰۰	۲۰۷.۶	۰	۳۵.۸
۹۸		۶۹۷	۶۶۲	۲۹۸	۰	۴۰۰	۲۰۷.۶	۰	۳۷
۹۹		۸۶۳	۶۶۲	۱۵۳	۰	۴۰۰	۲۰۷.۶	۰	۳۸.۱
۱۰۰		۱۰۱۴	۶۶۲	۰	۰	۴۰۰	۲۰۷.۶	۰	۳۹
۱۰۱		۱۰۲۵	۷۸۴	۰	۰	۳۸۰	۱۶۸	۰	۳۸.۴
۱۰۲		۱۲۹۸	۶۴۹	۰	۰	۳۲۵	۱۶۲	۰	۴۶.۷
۱۰۳		۱۲۸۸	۴۸۳	۱۶۱	۰	۳۲۲	۱۶۱	۰	۳۵.۳
۱۰۴		۱۲۷۷	۳۲۰	۳۲۰	۰	۳۲۰	۱۵۹	۰	۳۵.۲
۱۰۵	خطیب [۳۷]	۱۲۶۷	۱۵۸	۴۷۵	۰	۳۱۷	۱۵۸	۰	۳۵.۱
۱۰۶		۱۲۵۷	۰	۶۲۹	۰	۳۱۵	۱۵۷	۰	۳۰
۱۰۷		۱۲۷۵	۴۷۸	۱۵۹	۰	۳۱۹	۱۵۹	۰	۳۹.۲
۱۰۸		۱۲۵۳	۳۱۴	۳۱۴	۰	۳۱۴	۱۵۶	۰	۳۷.۷
۱۰۹		۱۲۳۲	۱۵۴	۴۶۲	۰	۳۰۸	۱۵۴	۰	۳۶.۱
۱۱۰		۱۲۱۱	۰	۶۰۶	۰	۳۰۳	۱۵۱	۰	۳۳.۲
۱۱۱		۸۹۸	۸۹۸	۰	۰	۴۴۹	۱۵۷	۴.۵	۵۶.۲۸
۱۱۲		۸۹۸	۶۷۳	۱۹۹	۰	۴۴۹	۱۵۷	۴.۵	۵۱.۴۴
۱۱۳		۸۹۸	۴۴۹	۳۹۷	۰	۴۴۹	۱۵۷	۴.۵	۴۷.۴۴
۱۱۴	فان و همکاران [۳۸]	۸۹۸	۰	۷۹۴	۰	۴۴۹	۱۵۷	۴.۵	۳۷.۷۷
۱۱۵		۸۹۸	۶۷۳	۲۰۳	۰	۴۴۹	۱۵۷	۴.۵	۵۲.۲۷
۱۱۶		۸۹۸	۴۴۹	۴۰۶	۰	۴۴۹	۱۵۷	۴.۵	۵۱.۳۴
۱۱۷		۸۹۸	۸۲۲	۸۱۳	۰	۴۴۹	۱۵۷	۴.۵	۴۹.۶۳
۱۱۸		۸۲۲	۸۲۲	۰	۰	۴۱۱	۲۲۶	۰	۳۴.۱
۱۱۹		۸۲۲	۶۱۶	۱۸۲	۰	۴۱۱	۲۲۶	۰	۲۸.۵۸

ردیف	مرجع	شن طبیعی	ماسه طبیعی	شن بازیافتی	ماسه بازیافتی	سیمان	آب	افزودنی	مقاومت فشاری ۲۸ روزه (MPa)
		(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	(kg)	
۱۲۰		۸۲۲	۴۱۱	۳۶۳	۰	۴۱۱	۲۲۶	۰	۲۴.۶
۱۲۱		۸۲۲	۰	۷۲۷	۰	۴۱۱	۲۲۶	۰	۱۷.۷۶
۱۲۲		۸۲۲	۶۱۶	۱۸۶	۰	۴۱۱	۲۲۶	۰	۳۱.۳۱
۱۲۳		۸۲۲	۴۱۱	۳۷۲	۰	۴۱۱	۲۲۶	۰	۲۹.۰۹
۱۲۴		۸۲۲	۰	۷۴۴	۰	۴۱۱	۲۲۶	۰	۲۷.۲۶