



## Research Paper

## Evaluation of Regression-Based Soft Computing Techniques for Estimating Energy Loss in Gabion Spillways

Reza Mobayen<sup>1</sup>, Mohammad Najafzadeh<sup>2\*</sup> and Kambiz Farrahi-Moghaddam<sup>3</sup>

<sup>1</sup>M.Sc. Student, Department of Water Engineering, Faculty of Civil and Surveying Engineering, Graduate University of Advanced Technology, Kerman, Iran

<sup>2</sup>Assoc. Professor, Department of Water Engineering, Faculty of Civil and Surveying Engineering, Graduate University of Advanced Technology, Kerman, Iran

<sup>3</sup>Assist. Professor, Department of Water Engineering, Faculty of Civil and Surveying Engineering, Graduate University of Advanced Technology, Kerman, Iran

### Article information

Received: February 10, 2022

Revised: July 26, 2022

Accepted: July 27, 2022

### Keywords:

Energy Loss

Regression

River Engineering

Spillway

\*Corresponding author:

[m.najafzadeh@kgut.ac.ir](mailto:m.najafzadeh@kgut.ac.ir)



### Abstract

Estimation of flow energy loss in gabion spillways can be effective in managing erosion downstream of structures, flood control, and riverbed stabilization. Therefore, in this research, using two soft computing models evolutionary polynomial regression (EPR) and multivariate adaptive regression spline (MARS), the amount of energy loss in these spillways was estimated. About 75% of the 74 laboratory data samples were used for training and the remaining 25% were used for testing the models. The dimensionless parameters of Froude number (Fr), spillway slope (S), gabion number (GN), and porosity (n) were used as input parameters. The results showed that the MARS model predicted the energy loss values by root mean square error (RMSE), mean absolute percentage error (MAPE), and correlation coefficient (CC) of 0.05, 0.017, and 0.99, respectively, which has better performance than the EPR model has. The results of the Taylor diagram also showed that the performance of MARS and EPR are satisfying, and their accuracy is very close to each other. The regression equation by the EPR model was more complex than the regression equation by the MARS model. According to the obtained results, the use of the two soft computing models in estimating energy loss in spillways is recommended.

© Authors, Published by **Environment and Water Engineering** journal. This is an open-access article distributed under the CC BY (license <http://creativecommons.org/licenses/by/4.0/>).



### Introduction

In order to pass the flow of water and control and regulate the flow rate, hydraulic structures called spillways are used. Also, the use of materials such as stone and gravel due to their properties such as high density, surface roughness, and porosity, which increase the stability of the

structure, energy loss, and drainage, are suitable for the construction of spillways. Among the hydraulic structures made with these materials, gabion weirs are very practical, which, of course, are also used in other cases such as small dams, diversion dams, and protective structures in rivers and docks. Step weirs have always been



considered for their ability to depreciate energy. Most of the research on stepped weirs has been on weirs with a smooth and often concrete surface, and weirs made with gabions have been investigated less. The general studies on gabion spillways have been experimental. In the last decade, the use of optimization methods in artificial intelligence has become popular. But these methods have rarely been used in investigations related to gabion spillway. Therefore, in this research, two soft computing models, multivariate adaptive regression splines (MARS) and evolutionary polynomial regression (EPR) have been used to estimate the energy loss in gabion spillways. Investigating the performance of artificial intelligence methods to find the maximum specific energy passing through the gabion spillway and the effect of the geometric and hydraulic parameters of the gabion spillway on energy loss are the main goals of current research. Finally, according to the results and error evaluation criteria, the most suitable model was selected from the two types of models used.

### Material and Methods

In this research, in order to predict energy loss in gabion spillways using soft computing models, dimensional analysis was done by Buckingham theorem at first. Next, Froude number ( $Fr$ ), spillway slope ( $S$ ), gabion number ( $GN$ ), and porosity ( $n$ ) parameters were selected as dimensionless parameters. Two soft computing models EPR and MARS were chosen to estimate the amount of energy loss in gabion spillways. About 75% of the experimental data obtained by Khatibi et al. (2014) were used for training the models and 25% of the rest were used for testing the models. Finally, to obtain the calculation error of each model, the root means square error (RMSE), mean absolute percentage error (MAPE), and correlation coefficient (CC) were used.

### Results

Fig. 1 shows the experimental values against the predicted values of the models. As it is shown, RMSE and CC in MARS and EPR models have the lowest and highest values among the models, respectively. Due to the small number of test data compared to the training data, it is normal that the error values of the test part are higher than that of the training part. The data dispersion for both parts is similar. In none of the models, the

positions of the points are outside the lines  $y=0.75x$  and  $y=1.25x$ , which shows that the estimated and observed values are close to each other and around the  $y=x$ . The scatter plots and existing error evaluation criteria showed that the results of MARS (Fig. 1 a) and EPR (Fig. 1 b) models indicated relatively the same performance.




Fig. 1 Values of observational and predicted energy loss in testing stage: a) MARS model, b) EPR model

Fig. 2 shows the predicted and observed data for the total data. First of all, it is clear that all the models have correctly recognized the trend of changes in the values of  $1/1-K$ . The MARS model has always estimated the values within the limit of 0.6 to -1 less or more than the actual state that happened in a particular data sample. In most of the data samples, the difference between the observed and estimated values by this model was very small and in the range of 0.1 and -0.1. In the EPR model, the estimated values were similar to the MARS model. The highest amount of error was made with a difference between -0.5 and 1. This difference in other models is opposite to MARS model. The mean value of error (MSE) and standard deviation (St.D) given by MARS model are 0.0034 and 0.2, respectively, while it

is slightly different from the EPR model. In the EPR model, the MSE and St.D values are equal to 0.03 and 0.17, respectively, which shows that

the EPR model performed slightly better than MARS in estimating the energy loss.

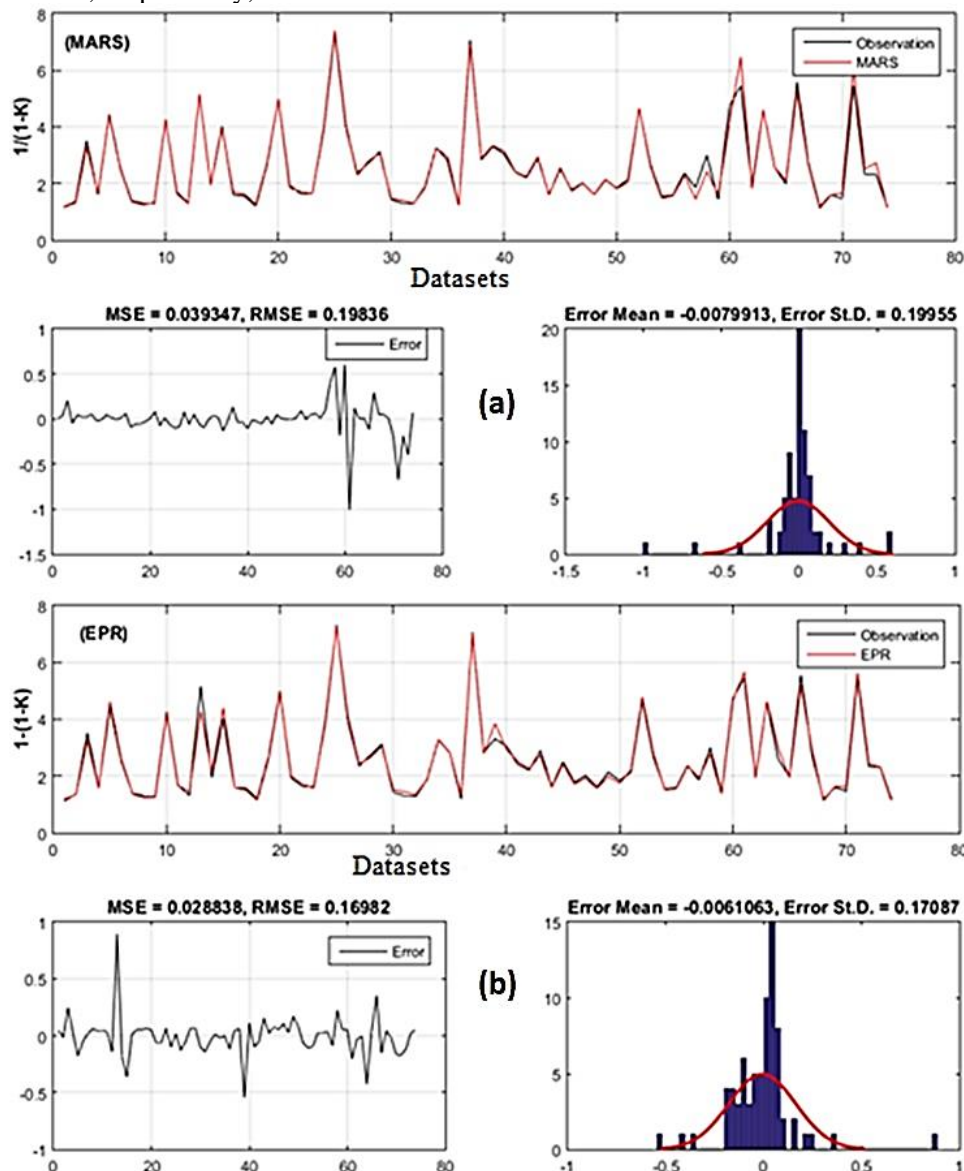


Fig. 2 Values of observational and predicted energy loss by soft computing models for whole datasets in training and testing stages: a) MARS model, b) EPR model

### Conclusions

1. MARS model was the most suitable model for predicting energy loss in the gabion spillway. In this model, the values of RMSE, CC, MAPE, and SI for the test data were 0.054, 0.99, 0.017, and 0.04, respectively.

2. Relation given by EPR had the most complex expression compared to MARS and ANN.

3. The prediction accuracy of MARS and EPR models was better than GEP and ANN models reported by Khatibi et al. (2014).


4. In the Taylor chart, the highest correlation coefficient was for the MARS model, which was equal to 0.99. Also, the lowest RMSE value was for the MARS model, which was about 0.056 in the training data.

### Data Availability

The data of this research is available in the following paper: DOI: <https://doi.org/10.1007/s11269-014-0545-y>

### Conflicts of interest

The authors of this paper declared no conflict of interest regarding the authorship or publication of this article.



ISSN: 2476-3683

محیط زیست و مهندسی آب

Homepage: [www.jewe.ir](http://www.jewe.ir)

مقاله پژوهشی

## ارزیابی مدل‌های محاسبات نرم مبتنی بر روابط رگرسیونی جهت تخمین افت انرژی در سرریزهای گابیونی

رضا مبین<sup>۱</sup>، محمد نجف‌زاده<sup>۲\*</sup> و کامبیز فرهی مقدم<sup>۳</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده مهندسی عمران و نقشه‌برداری، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفت، کرمان، ایران  
<sup>۲</sup> دانشیار، گروه مهندسی آب، دانشکده مهندسی عمران و نقشه‌برداری، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفت، کرمان، ایران  
<sup>۳</sup> استادیار، گروه مهندسی آب، دانشکده مهندسی عمران و نقشه‌برداری، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفت، کرمان، ایران

### چکیده

### اطلاعات مقاله

تاریخ دریافت: [۱۴۰۰/۱۱/۲۱]

تاریخ بازنگری: [۱۴۰۱/۰۶/۰۴]

تاریخ پذیرش: [۱۴۰۱/۰۶/۰۵]

### واژه‌های کلیدی:

افت انرژی

رگرسیون

سرریز

مهندسی رودخانه

### \*نویسنده مسئول:

[m.najafzadeh@kgut.ac.ir](mailto:m.najafzadeh@kgut.ac.ir)



برآورد میزان افت انرژی جریان در سرریزهای گابیونی می‌تواند در کنترل فرسایش پایین‌دست سازه، مهار سیلاب و تثبیت بستر رودخانه مؤثر باشد. از این رو در این پژوهش با استفاده از مدل رگرسیونی چندجمله‌ای تکاملی (EPR) و رگرسیون چند متغیره تطبیقی اسپلاین (MARS) به تخمین مقدار افت انرژی در این سرریزها پرداخته شد. از ۷۴ نمونه داده آزمایشگاهی حدود ۷۵٪ برای آموزش و ۲۵٪ باقیمانده برای آزمایش مدل‌ها استفاده شد. پارامترهای بی‌بعد عدد فرود (Fr)، شیب سرریز (S)، شماره گابیون (GN) و تخلخل (n) به‌عنوان پارامترهای ورودی استفاده شد. نتایج نشان داد مدل MARS مقادیر تخمین افت انرژی را با حداقل مربعات میانگین خطا (RMSE)، میانگین درصد قدر مطلق خطا (MAPE) و ضریب همبستگی (CC) به ترتیب برابر ۰/۰۵۴، ۰/۰۱۷ و ۰/۹۹ پیش‌بینی می‌نماید که از دقت بهتری نسبت به مدل EPR برخوردار است. نتایج دیاگرام تیلور نیز نشان داد که عملکرد MARS و EPR مناسب است و دقت بسیار نزدیک به هم دارند. معادله رگرسیونی استخراجی از مدل EPR از پیچیدگی زیادی نسبت به معادله رگرسیونی استخراجی از مدل MARS برخوردار بود. با توجه به نتایج کسب‌شده استفاده از مدل‌های مذکور در تخمین افت انرژی در سرریزها توصیه می‌شود.

### ۱- مقدمه

جهت عبور جریان آب و کنترل و تنظیم میزان دبی، از سازه‌های هیدرولیکی تحت عنوان سرریز<sup>۱</sup> استفاده می‌شود



بودن، سازگاری با محیط‌زیست و انعطاف‌پذیری، این نوع از سازه‌ها اهمیت خاصی می‌یابند (Vashisth 2017). از طرفی به دلیل قابلیت عبور جریان آب از درون سازه، در این نوع از سرریزها افزایش ضریب دبی و افزایش اتلاف انرژی نسبت به سازه صلب وجود خواهد داشت که خود سبب افزایش کارایی سرریز می‌شود. سرریز گابیونی به دلیل مصالح به‌کاررفته در آن سازه‌های اقتصادی است و خود سبب کاهش هزینه در احداث حوضچه آرامش پایین‌دست آن می‌شود. از این‌رو پیش‌بینی مقدار افت انرژی در این نوع سرریزها ضروری به نظر می‌رسد. (Fathi-Moghaddam et al. 2018) به‌منظور شبیه‌سازی عددی جریان بر روی سرریزهای گابیونی با سطح مقطع مثلث و دوزنقه با شیب جانبی متفاوت در شرایط جریان آزاد و بررسی پارامترهای هیدرولیکی در اطراف آن‌ها، در ابتدا یک سری مطالعات آزمایشگاهی انجام دادند. در مرحله بعد، پس از صحت‌سنجی مدل عددی با استفاده از مشاهدات آزمایشگاهی به دست آمده، ۲۵۶ مدل مختلف عددی مورد مطالعه قرار گرفت. نتایج ایشان حکایت از آن داشت که کاهش متوسط قطر ذرات منجر به کاهش ۲۷٪ ضریب دبی و کاهش ۳۴٪ دبی جریان و کاهش ۸٪ اتلاف انرژی جریان در مدل‌ها می‌شود. همچنین آن‌ها به این نتیجه رسیدند که شیب پایین‌دست سرریز لبه تیز پهن گابیونی تأثیر قابل‌توجهی روی عملکرد سرریز گابیونی دارد.

از طرفی اخیراً استفاده از مدل‌هایی که علیرغم داشتن دقت کافی برای پیش‌بینی، نیازمند کمترین اطلاعات ورودی به سیستم باشند بسیار مورد توجه محققان قرار گرفته است (Milan et al. 2021). با توجه به مدل‌های مختلف و تنوع مدل‌های یادگیری ماشین<sup>۷</sup> استفاده از آن‌ها و ارزیابی مدل‌ها در زمینه‌های مختلف و پیشنهاد مدل مناسب در هر زمینه ضروری به نظر می‌رسد. مدل‌های یادگیری ماشین ابزارهایی مناسب برای پیش‌بینی‌های مختلف مانند پیش‌بینی افت انرژی در سرریزها هستند. این مدل‌ها از آنجایی که نیاز به اطلاعات اساسی یک سیستم ندارند، با کمترین اطلاعات موجود از هر سیستم قادر به پیش‌بینی مناسب در زمینه‌های مختلف هستند و به همین دلیل بسیار مورد توجه محققان قرار گرفته‌اند (Kayhomayoon et al. 2021). از دیگر مزیت‌های این مدل‌ها نسبت به سایر مدل‌ها مانند مدل‌های عددی و آزمایشگاهی می‌توان به هزینه کم، کاهش زمان اجرا

(Mehri et al. 2019). همچنین استفاده از مصالحی نظیر سنگ و سنگریزه به دلیل خواصی همچون دانسیته بالا، زبری سطح و تخلخل که باعث افزایش پایداری سازه، استهلاک انرژی و زهکشی می‌شوند، برای ساخت سرریزها مناسب می‌باشند (Salmasi et al. 2011). از جمله سازه‌های آبی ساخته‌شده با این مصالح می‌توان به سرریزهای توری-سنگی یا گابیونی<sup>۲</sup> اشاره کرد. گابیون‌ها در موارد دیگر نظیر سدهای کوچک، بندهای انحرافی و سازه‌های حفاظتی در رودخانه‌ها و اسکله‌ها نیز کاربرد دارند (Mahjobi and Kashefipour 2019). سازه‌های گابیونی یا توری سنگی از دو مصالح اصلی سنگ و توره‌های فلزی تشکیل شده‌اند. پایداری سازه سنگ و خاک با الیاف از گذشته‌های دور تاکنون رواج داشته و امروزه سازه‌های گابیونی به‌نوعی تکامل‌یافته همین سازه‌ها هستند. با توجه به اینکه در ایران فراوانی مصالح سنگی، مسائل مربوط به آب‌وخاک و نیاز به ایجاد تأسیسات درخور به چشم می‌خورد، سازه‌های گابیونی برای اقلیم ایران بسیار مناسب هستند.

سرریزهای ساخته‌شده با گابیون در هندسه‌های مختلفی همچون شیب‌دار، قائم و پلکانی اجرا می‌شوند (Khatibi et al. 2014). سرریزهای پلکانی-گابیونی به دلیل دارا بودن پله و تخلخل در طول سرریز که سبب افزایش قابلیت استهلاک انرژی می‌شوند، کاربرد بیشتری دارند (Fathi-Moghaddam et al. 2018). در مطالعه‌ای دیگر نشان داده شد که پلکان گابیونی قائم<sup>۳</sup> نسبت به پلکان‌های مایل<sup>۴</sup>، همپوشانی شده<sup>۵</sup> و حوضچه‌ای<sup>۶</sup>، انرژی بیشتری را مستهلک می‌کند (Reeve et al. 2019).

به‌طور کلی، پارامترهای هندسی سرریزهای پلکانی-گابیونی شامل، ارتفاع سرریز، تعداد پله‌ها، شیب سرریز، عرض سرریز و تخلخل سنگ‌های درون توری هستند. پارامترهای هیدرولیکی این سرریزها شامل: دبی جریان، عمق آب در پنجه سرریز قبل از پرش هیدرولیکی، عمق آب روی پله‌ها و استهلاک انرژی هستند. گرچه اکثر سرریزهای ساخته‌شده به‌صورت صلب و غالباً بتنی می‌باشند ولی با توجه به مزایای سرریزهای ساخته‌شده با گابیون، نظیر پایداری، اقتصادی

<sup>1</sup> Weir

<sup>2</sup> Gabion Weir

<sup>3</sup> Normal Step

<sup>4</sup> Inclined Step

<sup>5</sup> Overlap Step

<sup>6</sup> Pooled Step

<sup>7</sup> Machine Learning

مدل MARS از دقت مناسب‌تری نسبت به نتایج سایر مدل‌ها برخوردار بودند.

به‌طور کلی، سرریزهای پلکانی به جهت توانایی در مستهلک کردن انرژی همواره مورد توجه بوده‌اند. بیش‌ترین پژوهش در خصوص سرریزهای پلکانی بر روی سرریز با سطح صاف و غالباً بتنی بوده و سرریزهای ساخته‌شده با گابیون، کمتر مورد بررسی واقع شده‌اند. مروری بر مطالعات صورت گرفته بر روی سرریزهای گابیونی نشان می‌دهد که عموم پژوهش‌ها روی این سازه‌ها به‌صورت آزمایشگاهی بوده است. در دهه اخیر استفاده از روش‌های بهینه‌سازی در هوش مصنوعی رواج یافته و محدودیت‌های زمانی و اقتصادی موجود در روش‌های آزمایشگاهی را تا حدود زیادی جبران نموده است. اما استفاده از این روش‌ها در پژوهش‌های مربوط به سرریز گابیونی به‌ندرت صورت گرفته است. از این رو در این پژوهش سعی شده است برای تخمین افت انرژی در سرریزهای گابیونی از دو مدل هوش مصنوعی MARS و EPR استفاده شود. بررسی عملکرد روش‌های هوش مصنوعی جهت یافتن حداکثر انرژی مخصوص عبوری از سرریز گابیونی و تأثیر پارامترهای هندسی و هیدرولیکی سرریز گابیونی در استهلاک انرژی از اهداف این پژوهش بودند. شایان ذکر است که نوآوری و وجه تمایز اصلی پژوهش حاضر نسبت به سایر پژوهش‌ها مشابه در این زمینه، استفاده از دو مدل مذکور است. در نهایت با توجه به نتایج و معیارهای ارزیابی خطا، مناسب‌ترین مدل از بین دو نوع مدل مورد استفاده، انتخاب گردید.

## ۲- مواد و روش‌ها

### ۲-۱- آنالیز ابعادی

در پیش‌بینی پارامترهای هیدرولیکی مانند اتلاف انرژی در سرریزهای گابیونی به‌وسیله مدل‌های یادگیری ماشین می‌بایستی آنالیز ابعادی پارامترها بررسی شود. رابطه‌های (۱) و (۲) به ترتیب نحوه محاسبه بار انرژی بالادست ( $E_0$ ) و بار انرژی پایین‌دست ( $E_1$ ) را نشان می‌دهند (Khatibi et al. 2014).

$$E_0 = H_w + y_0 + \frac{V_0^2}{2g} = H_w + y_0 + \frac{q^2}{2g(H_w + y_0)^2} \quad (1)$$

$$E_1 = y_1 + \frac{V_1^2}{2g} = y_1 + \frac{q^2}{2g(y_1)^2} \quad (2)$$

که  $g$  شتاب ناشی از گرانش و  $H_w$  ارتفاع کل گابیون-سرریز هستند. این ارتفاع با یک نقطه سنج پس از نصب سرریز در

و قابلیت کالیبره کردن مدل‌ها اشاره کرد (Moghaddam et al. 2019; Chen et al. 2021). با وجود تعدد این مدل‌ها و توانایی خاص هر کدام از آن‌ها، کمتر تحقیقی در این زمینه صورت گرفته است. (Khatibi et al. 2014) با استفاده از معادلات رگرسیونی چندگانه<sup>۱</sup> بر اساس نظریه آنالیز ابعادی، شبکه‌های عصبی مصنوعی (ANN)<sup>۲</sup> و برنامه‌نویسی بیان ژنتیک<sup>۳</sup> روابطی برای اندازه‌گیری مقدار تلفات انرژی در سرریزهای گابیونی پلکانی ارائه دادند. آن‌ها برای آزمودن مدل‌های کامپیوتری از داده‌های اندازه‌گیری شده‌ی شش مدل سرریز گابیونی پلکانی واقع بر یک فلووم افقی آزمایشگاهی با دبی‌های مختلف، شیب‌های افقی و قائم و ذرات گابیونی با تخلخل ۳۸، ۴۰ و ۴۲٪ استفاده نمودند. در نهایت ایشان به این نتیجه رسیدند که از میان مدل‌های محاسباتی، روش ANN نتایج مطلوب‌تری به دست می‌دهد. (Sattar et al. 2019) از روش هوش مصنوعی جهت پیش‌بینی راندمان هوادهی سرریزهای پلکانی برای سه مدل جریان استفاده کردند. برطبق نتایج به دست آمده در مطالعه ایشان، مدل با RMSE بالای ۹۰٪ نسبت به معادلات رگرسیونی رضایت‌بخش‌تر بود. همچنین نتایج حاکی از آن بود که تعداد پله، شیب، عدد رینولدز و نسبت عمق جریان بحرانی به ارتفاع پله مهم‌ترین متغیرهایی هستند که کمترین مقدار را برای ضریب Mallow (مؤثرترین متغیر بر راندمان هوادهی سرریز) به دست می‌دهند. در سال‌های اخیر، مدل‌هایی نظیر رگرسیون چند جمله‌تکاملی (EPR)<sup>۴</sup> و رگرسیون چند متغیره تطبیقی اسپلاین (MARS)<sup>۵</sup> با توانایی پیش‌بینی بالا در زمینه‌های مختلف، مورد توجه قرار گرفته‌اند. این مدل‌ها توسط محققان مختلفی مورد ارزیابی قرار گرفته‌اند. در این زمینه می‌توان به پژوهش‌های (Jamei et al. 2021) در تخمین چگالی نانو سیالات هیبریدی، پژوهش‌های (Ghorbani and Eslami 2021) در پتانسیل روان‌گرایی<sup>۶</sup> خاک‌های شنی و پژوهش‌های (Rezaie-Balf 2019) در پیش‌بینی عمق آبشستگی اشاره کرد. بر اساس نتایج به دست آمده از تمامی پژوهش‌ها، هر دو مدل توانایی خوبی در پیش‌بینی‌های سری زمانی و مکانی دارند. همچنین در اغلب این مطالعات نتایج به‌دست‌آمده از

<sup>1</sup> Multiple Adaptive Regression Splines

<sup>2</sup> Artificial Neural Network

<sup>3</sup> Gene Expression Programming

<sup>4</sup> Evolutionary Polynomial Regression

<sup>5</sup> Multivariate Adaptive Regression Splines

<sup>6</sup> Liquefaction Potential

## ۲-۲- داده‌های مورد استفاده

در این پژوهش از ۷۴ مجموعه داده آزمایشگاهی جمع‌آوری شده توسط Khatibi et al. (2014) استفاده شد. در جدول (۱) به بررسی خصوصیات برخی پارامترهای آماری این داده‌ها پرداخته شده است. مطابق جدول (۱) حدود ۱۰ پارامتر بی‌بعد و با بعد وجود دارد. بر اساس روابط (۱) تا (۴)، پارامترهای با بعد در حقیقت مهم‌ترین پارامترهای تأثیرگذار در محاسبه اتلاف انرژی هستند. همچنین پارامترهای بی‌بعد با استفاده از قضیه  $\Pi$ -باکینگهام توسط Khatibi et al. (2014) به دست آمده‌اند، که در مطالعه حاضر نیز مورد استفاده قرار گرفتند. همچنین محدوده مقادیر هر یک از آن‌ها به همراه میانگین، کم‌ترین مقدار، بیش‌ترین مقدار و انحراف معیار آن‌ها در جدول (۱) بیان شده است. به عنوان نمونه پارامتر  $q$  که بیانگر دبی تخلیه در واحد عرض است در محدوده ۰/۱۵ تا ۰/۱۳۳ قرار دارد که میانگین و انحراف معیار آن به ترتیب برابر ۰/۰۶۰ و ۰/۰۳۱ است. عدد رینولدز نیز در محدوده ۱۵۰۰۰ تا ۱۳۰۰۰۰ قرار دارد که میانگین آن برابر ۵۹۳۳۷ است. محدوده مجموعه انرژی در بالادست سرریز برابر ۰/۳۱ تا ۰/۴۸ قرار دارد که میانگین و انحراف معیار آن به ترتیب برابر ۰/۳۸ و ۰/۰۴ است. محدوده سایر پارامترهای اندازه‌گیری شده در جدول (۱) قابل مشاهده است.

جدول ۱- خلاصه پارامترهای آماری متغیرهای با بعد و بی‌بعد استفاده شده

Table 1 Summary of statistical parameters of dimensional and dimensionless variables

Parameter	Unit	Standard deviation	Maximum	Minimum	Average
$q$	m <sup>2</sup> /s	0.031	0.133	0.015	0.06
$y_1$	m	0.009	0.057	0.013	0.029
$y_2$	m	0.054	0.237	0.016	0.133
$V_1$	m/s	0.50	2.92	0.94	1.91
$E_0$	m	0.04	0.48	0.31	0.38
$E_1$	m	0.099	0.40	0.065	0.22
$GN$	-	0.016	0.067	0.001	0.017
$l/(1-K)$	-	1.41	7.3	1.18	2.62
$Fr_1$	-	0.69	5.5	2.13	3.6
$Re_1$	-	31352	130000	15000	59337

## ۲-۳- مدل رگرسیون چند متغیره تکاملی

روش EPR در سال ۲۰۰۶ توسط (Giustolosi and Savic 2006) ارائه شد. این روش بر مبنای روش‌های داده‌کاوی

فلوم اندازه‌گیری شده است.  $V_0$  و  $y_0$  به ترتیب بیانگر عمق جریان و سرعت متوسط در بالادست سرریز هستند. همچنین عمق جریان،  $V_1$  سرعت متوسط جریان در پنجه سرریز و  $q$  دبی در واحد عرض فلوم است.  $y_1$  با استفاده از عمق مزدوج ( $y_2$ ) و با داشتن عدد فرود پس از پرش هیدرولیکی ( $Fr_2$ ) قابل محاسبه است. به طور کلی، اتلاف انرژی به متغیرهای هیدرولیکی و هندسی زیادی بستگی دارد که به صورت رابطه (۳) قابل بیان است.

$$\Delta E = f(q, n, l, H_w, h, g, \rho, \mu) \quad (3)$$

که،  $l$  طول پله و  $h$  ارتفاع پله است.  $\rho$  وزن مخصوص آب،  $\mu$  لزجت دینامیکی آب و  $n$  تخلخل است. متغیرهای اساسی که در هیدرولیک سرریزهای گابیونی مهم هستند، پارامترهای هندسی شامل: ارتفاع کل گابیون-سرریز ( $H_w$ )، طول هر پله ( $l$ )، ارتفاع هر پله ( $h$ )، شیب سرریز ( $S$ )، اندازه سنگ پر شده در گابیون ( $d_{50}$ )؛ و پارامترهای هیدرولیکی مانند: دبی در واحد عرض ( $q$ )، انرژی در بالادست سرریز ( $E_0$ )، انرژی در پایین‌دست سرریز ( $E_1$ )، و تخلخل مواد ( $n$ ) هستند. با استفاده از قضیه  $\Pi$ -باکینگهام، اتلاف انرژی نسبی را می‌توان به صورت رابطه (۴) بیان کرد (Khatibi et al. 2014).

$$\frac{\Delta E}{E_0} = f(q^2/gH_w^3, h/l, n, Re_1, Fr_1) \quad (4)$$

با تعریف اتلاف انرژی نسبی  $K = \frac{E_0 - E_1}{H_w}$ ، رابطه (۴) را می‌توان به صورت رابطه (۵) نیز بیان کرد.

$$\frac{1}{1-K} = f(GN, S, n, Re_1, Fr_1) \quad (5)$$

که،  $GN = q^2/gH_w^3$  عدد گابیون و  $S = h/l$  می‌باشد.  $Fr_1$  و  $Re_1$  نیز به ترتیب اعداد فرود و رینولدز در بالادست سرریز هستند. که در آن  $v$  ویسکوزیته سینماتیک آب در دمای  $20^\circ C$  است. سرعت متوسط جریان در هر مقطع برابر  $V = q/y$  است. میانگین محدوده پارامتر  $Re$  مربوط به جریان آشفته کامل است. با توجه به اینکه عدد رینولدز محدوده مربوط به رژیم جریان (آشفته، انتقالی و آرام) را نشان می‌دهد. از آنجا که در کلیه آزمایش‌های مورد بررسی رژیم جریان آشفته حاکم است پس در این حالت پارامتر  $Re$  اثر معناداری روی افت انرژی در سرریزهای گابیونی ندارد. لذا می‌توان در مدل‌سازی با استفاده از مدل‌های هوش مصنوعی، پارامتر  $Re$  را حذف نمود.

<sup>1</sup>Relative Energy Dissipation

مشاهداتی است. بنابراین هر مدلی که *CoD* بیشتری داشته باشد، معرفی می‌گردد (Giustolosi and Savic 2006).

لازم به ذکر است که جهت توسعه مدل EPR به منظور تخمین درصد افت انرژی سرریزهای گابیونی، از نرم‌افزار EPR MOGA-XL که در محیط اکسل توسعه داده شده، استفاده شد. جهت اجرای مراحل آموزش و آزمایش در محیط برنامه، در ابتدا به تنظیم پارامترهای مورد نیاز برنامه پرداخته شد. این پارامترها شامل نوع روابط رگرسیونی (انواع توابع داخلی نظیر)، تعداد جملات جبری روابط، محدوده نماهای مورد استفاده در روابط ریاضی و ویژگی‌های الگوریتم وراثتی (نظیر تعداد جمعیت و تابع هدف) بودند. به روابط و نتایج بدست آمده از روش توضیح داده شده در بخش یافته‌ها و بحث بصورت مفصل پرداخته شده است.

#### ۲-۴- روش اسپیلاین رگرسیون تطبیقی چند متغیره

این روش در سال ۱۹۹۱ ارائه شد و یک روش رگرسیونی ناپارامتری است که برای مدسازی رگرسیونی انعطاف‌پذیر داده‌های با ابعاد بالا ارائه شده است (Friedman 1991). این روش قابلیت دارد که روابط غیرخطی پنهان در مجموعه داده‌ها را کشف نماید و بسیار سریع به جواب بهینه برسد (Zhang and Goh 2016). در روش MARS با داشتن متغیر وابسته و مجموعه‌ای از متغیرهای توضیحی مستقل، با استفاده از تبدیلات متغیرهای توضیحی رابطه غیرخطی متغیر وابسته با متغیرهای توضیحی آشکار می‌شود. همچنین بین متغیرهای توضیحی اثرات متقابل تعیین می‌شود و امکان تشخیص متغیرهای مؤثر از متغیرهای غیر مؤثر در مقدار متغیر وابسته به وجود می‌آید. بنابراین مدل کلی MARS را می‌توان به صورت رابطه (۸) بیان کرد (Friedman 1991):

$$f(x) = \beta_0 + \sum_{m=1}^M \beta_m h_m(x) \quad (8)$$

با شروع از  $h_0(x) = 1$ ، توابع پایه‌ای با شیوه‌ای تکرارشونده به مدل اضافه می‌شوند. برای هر  $h_m(x)$  دو انتخاب وجود دارد.

$$(x-t)_+ = \begin{cases} x-t & \text{if } x > t, \\ 0, & \text{otherwise,} \end{cases} \quad (9)$$

$$(t-x)_+ = \begin{cases} t-x & \text{if } t > x, \\ 0, & \text{otherwise,} \end{cases}$$

است که قادر است روابط چند متغیره بین پارامترهای یک سیستم را جستجو کند. اساس تابع عمومی به‌کاررفته در الگوریتم این روش، برنامه‌نویسی وراثتی است و شباهت‌هایی با الگوریتم وراثتی دارد. اما یک تفاوت اساسی بین این دو روش وجود دارد. در الگوریتم ژنتیک، برحسب مسئله داده‌شده، راه‌حل‌های پیشنهادی ارائه می‌شوند، اما در برنامه‌نویسی ژنتیک برنامه‌های کامپیوتری برای حل مسئله داده‌شده استنتاج می‌شوند. شکل عمومی معادله به کار گرفته‌شده این روش به صورت رابطه (۶) است.

$$y = \sum_{j=1}^m a_j Z_j + a_0 \quad (6)$$

که در آن  $y$  تخمین حداقل مربعات مقادیر هدف،  $a_j$  یک پارامتر قابل تنظیم برای جمله  $j$ ام،  $a_0$  یک بایاس انتخابی،  $m$  تعداد ترم‌های عبارت و  $Z_j$  یک متغیر تغییر شکل یافته است.  $j$  پیامد متغیرهای مستقل پیش‌گویی کننده ورودی است  $(x_1, x_2, \dots, x_n)$  که  $0$  تعداد متغیرهای مستقل پیش‌گویی کننده است. وجود بایاس باعث می‌شود دامنه فرایند آزمون و خطا در مرحله آموزش نیز گسترش یابد و با داشتن مقادیر اولیه تابع به‌عنوان بایاس، سطح عملکرد مدل‌های هوش مصنوعی افزایش می‌یابد. اساس روش رگرسیون چندجمله‌ای تکاملی جستجوی پویاست که از طریق مقایسه مرحله‌به‌مرحله رگرسیون‌ها به تکامل می‌رسد. جهت حل مسئله، رگرسیون مرحله‌ای با روش الگوریتم وراثتی بر روی معادله اصلی برنامه‌نویسی وراثتی قاعده‌ای انجام می‌شود. در این روش، یک جستجوی کلی برای توان ورودی‌ها و ترکیبات متغیرهای ورودی مطابق با تابع هزینه‌ای که کاربر تعیین می‌کند، انجام می‌شود. نسخه اولیه EPR بر اساس الگوریتم وراثتی تک منظوره استوار است. بدین صورت که یک مقدار حداکثر برای تعداد جملات  $m$  فرض می‌شود و در ادامه جستجوی روابط دارای یک تا  $m$  جمله به صورت متوالی انجام می‌شود. به منظور تسریع در عمل همگرایی به صورت اختیاری می‌توان نتایج به‌دست‌آمده در هر مرحله از جستجو را در جمعیت بعدی جستجو وارد کرد. برای ارزیابی برازش انتخاب عبارات تولیدشده از ضریب تعیین *CoD* استفاده می‌شود (رابطه ۷).

$$CoD = 1 - \frac{N-1}{N} \frac{\sum N(\hat{y} - y_{exp})^2}{\sum N(y_{exp} - avg(y_{exp}))^2} \quad (7)$$

که،  $N$ : تعداد گره‌ها،  $avg(y_{exp})$ : میانگین داده‌های مشاهداتی،  $\hat{y}$ : مقدار به‌دست‌آمده از مدل،  $y_{exp}$ : مقدار داده



## ۲-۵- معیارهای ارزیابی خطا برای مقایسه نتایج

### مدل‌ها

در پژوهش حاضر، از رابطه (۵) جهت مدل‌سازی مقادیر  $I/I$  استفاده می‌شود. بدین‌صورت که متغیرهای  $GN$ ،  $n$ ،  $Fr_1$  و  $S$  که از آنالیز ابعادی داده‌های آزمایشگاهی حاصل شدند به‌عنوان متغیرهای ورودی مدل‌های هوشمند EPR و MARS در نظر گرفته می‌شوند. بعد از انجام مراحل آموزش و آزمایش مدل‌های EPR و MARS، از چهار شاخص‌های آماری جهت ارزیابی عملکرد مدل‌ها استفاده می‌گردد. هر یک از این شاخص‌های آماری دارای رابطه متفاوتی جهت بیان خطای مقادیر مشاهداتی (آزمایشگاهی) و پیش‌بینی‌شده توسط مدل‌های هوش مصنوعی هستند. شاخص‌های آماری مورد استفاده در تحقیق حاضر عبارت از ضریب همبستگی<sup>۱</sup> (CC) (رابطه ۱۱)، حداقل مربعات میانگین خطا (RMSE) (رابطه ۱۲)، میانگین درصد قدر مطلق خطا (MAPE) (رابطه ۱۳)، شاخص پراکندگی (SI) (رابطه ۱۴) بود. روابط هر کدام در ادامه ارائه شده است.

$$CC = \frac{\sum_{i=1}^p (x_{i(O)} - \bar{x}_{(O)})(x_{i(E)} - \bar{x}_{(E)})}{\sqrt{\sum_{i=1}^p (x_{i(O)} - \bar{x}_{(O)})^2 \sum_{i=1}^p (x_{i(E)} - \bar{x}_{(E)})^2}} \quad (11)$$

$$RMSE = \left[ \frac{\sum_{i=1}^p (x_{i(E)} - x_{i(O)})^2}{p} \right]^{1/2} \quad (12)$$

$$MAPE = \frac{100}{p} \left[ \frac{\sum_{i=1}^p |x_{i(E)} - x_{i(O)}|}{x_{i(E)}} \right] \quad (13)$$

$$SI = \frac{\sqrt{(1/p) \sum_{i=1}^p ((x_{i(E)} - \bar{x}_{(E)}) - (x_{i(O)} - \bar{x}_{(O)}))^2}}{(1/p) \sum_{i=1}^p x_{i(O)}} \quad (14)$$

که،  $x_{i(o)}$ ،  $x_{i(e)}$ ،  $p$  بیانگر تعداد نمونه‌ها، مقدار افت انرژی تخمین زده‌شده و افت انرژی محاسبه‌شده است.  $\bar{x}_{(O)}$  و  $\bar{x}_{(E)}$  به ترتیب بیانگر میانگین افت انرژی در حالت محاسبه‌شده و تخمین زده‌شده می‌باشد. مقادیر RMSE، MAPE و SI هرچقدر به صفر نزدیک‌تر باشند نشان از عملکرد مناسب مدل‌ها می‌باشد (Milan et al. 2021). مقادیر CC نیز هرچقدر به یک نزدیک‌تر باشد، بیانگر همبستگی قوی بین دو پارامتر می‌باشد.

## ۳- یافته‌ها و بحث

در این قسمت، ابتدا به نتایج مدل هوش مصنوعی MARS پرداخته می‌شود. در پژوهش حاضر، جهت توسعه مدل MARS از مفهوم کلاسه‌بندی استفاده شد. با توجه به

که،  $x$  متغیر و مقدار ثابت  $t$  گره نامیده می‌شود. بر اساس هر متغیر، گره شناسایی‌شده ( $t$ ) متفاوت خواهد بود و ضریب ( $\beta_m$ ) در هر حالت بین  $h_m(x-t)$  و  $h_m(t-x)$  متغیر است. تعداد و مکان گره‌ها در روش MARS از طریق یک فرآیند گام‌به‌گام پیشرو - پس‌رو انجام می‌شود. در مرحله پیشرو، تعداد زیادی از گره‌ها تولید می‌شوند. در مرحله پس-رو گره‌هایی که در برازش کلی مشارکت کم‌تری داشته‌اند، حذف می‌شوند. مدل مارس بهینه در دو مرحله ساخته می‌شود. یک فرآیند انتخاب گام‌به‌گام پیشرو که با یک فرآیند بازگشتی دنبال می‌شود. انتخاب گام‌به‌گام پیشرو با استفاده از تابع پایه و یک مقدار ثابت آغاز می‌شود. در هر گام، از کلیه خطوط هر تابع پایه، فرآیند خطی انتخاب می‌شود که نواقص مدل برازش یافته را به حداقل می‌رساند. توابع پایه که حداقل ممکن را به مدل می‌دهند، دارای گام‌های حذفی هستند و سپس مدل بهینه انتخاب می‌شود. نقصان شاخص برازش استفاده‌شده به‌صورت رابطه (۱۰) تعریف می‌شود (Friedman 1991).

$$GCV(M) = \frac{1}{p} \sum_{i=1}^p (y_i - \hat{y})^2 / (1 - \frac{c(M)}{p})^2 \quad (10)$$

که،  $\hat{y}$  مقدار وابسته پیش‌بینی‌شده توسط مدل،  $p$  تعداد مشاهدات در سری داده‌هاست،  $M$  تعداد عبارات غیرثابت در مدل و  $C(M)$  تابع خطای مرکب است. هدف از  $C(M)$  جبران پیچیدگی مدل است، در این شرایط از برازش بیش‌ازحد جلوگیری می‌شود. تابع  $C(M)$  به‌صورت  $C(M) = M + cd$  تعریف می‌شود.  $c$  عامل خطای هزینه و  $d$  درجه آزادی مؤثر است. برای محاسبه اهمیت نسبی یک متغیر، تمام عباراتی را که دارای متغیرهای مورد سؤال هستند، حذف می‌شوند. سپس، مدل بار دیگر برازش داده می‌شود. هر متغیری که به هنگام حذف به کوچک شدن مدل کمک نماید، به‌عنوان مهم-ترین متغیر شناخته می‌شود. متغیرهایی که نمرات کمتری دریافت می‌کنند از اهمیت کمتری برخوردارند. این نمرات مطابق با نسبت کاهش برازش مدل تولیدشده است (Friedman 1991).

<sup>1</sup>Correlation Coefficient

اجرای ده مدل MARS میانگین‌گیری شد. هدف از آن، استخراج مدل نهایی و گزارش عملکرد مراحل آموزش و آزمایش بود. لذا در تحقیق حاضر، با استفاده از مدل MARS از ۱۶ توابع پایه (BF) برای پیش‌بینی افت جریان استفاده شد. در جدول (۲) ملاحظه می‌شود که توابع پایه حداکثر به صورت توابع چند جمله‌ای درجه دوم بیان شده‌اند. به بیان دیگر، به منظور جلوگیری از پیچیدگی ریاضی رابطه (۱۵) در مرحله توسعه مدل، تعداد درجات تعامل نهایی نیز دو در نظر گرفته شد. مقدار نهایی پارامتر GCV که در مرحله پسرو محاسبه شد برابر ۰/۰۵۷۱ به دست آمد. توابع پایه مدل پیشنهادی MARS در جدول (۲) ارائه شده است.

اهمیت کلاسه‌بندی در تحلیل‌های مهندسی، از ۱۰ کلاس متفاوت (۱۰ الگوی متفاوت) در مدل‌سازی عملکرد هیدرولیکی سرریزهای گابیونی استفاده شد. لذا، داده‌های آزمایشگاهی مورد استفاده به ۱۰ الگوی متفاوت تقسیم‌بندی شدند. مدل MARS برای هر یک از کلاس داده‌ها اجرا شد. اجرای مدل MARS در نرم‌افزار MATLAB2018b صورت گرفت. در هر بار اجرای مدل MARS، دو مرحله پیشرو و پسرو اجرا شد. در مرحله پیشرو در ابتدا تعداد توابع پایه جهت مدل‌سازی افت انرژی مشخص شدند. سپس، در مرحله پسرو، تعداد توابع پایه کاهش یافت. دلیل آن کاستن از پیچیدگی مدل استخراجی MARS و کاهش احتمال رخ داد پدیده بیش برآزش در طول مرحله آموزش بود. در نهایت از

جدول ۲- توابع پایه برای پیش‌بینی افت انرژی در سرریز گابیونی در مدل MARS  
Table 2 BF's of MARS model for predicting energy loss in gabion overflow

BF.no	Formulation of BF's	$\lambda_{no}$	Coefficients of BF's
BF1	$\max(0, 3.809 - Fr_1) \times \max(0, n - 0.4)$	$\lambda_1$	34.237
BF2	$\max(0, GN - 0.014)$	$\lambda_2$	-68.298
BF3	$\max(0, 0.014 - GN) \times \max(0, S - 0.5)$	$\lambda_3$	-166.68
BF4	$\max(0, Fr_1 - 3.809) \times \max(0, n - 0.4)$	$\lambda_4$	15.774
BF5	$\max(0, 3.043 - Fr_1) \times \max(0, n - 0.4)$	$\lambda_5$	-73.078
BF6	$\max(0, 3.043 - Fr_1) \times \max(0, 0.4 - n)$	$\lambda_6$	-47.914
BF7	$\max(0, 0.014 - GN) \times \max(0, Fr_1 - 3.043)$	$\lambda_7$	148.14
BF8	$\max(0, 0.014 - GN) \times \max(0, 3.043 - Fr_1)$	$\lambda_8$	-242.1
BF9	$\max(0, 0.008 - GN)$	$\lambda_9$	345.57
BF10	$\max(0, Fr_1 - 3.043) \times \max(0, S - 0.5)$	$\lambda_{10}$	-0.46902
BF11	$BF9 \times \max(0, n - 0.4)$	$\lambda_{11}$	-14157
BF12	$BF9 \times \max(0, 0.4 - n)$	$\lambda_{12}$	-4776.8
BF13	$\max(0, GN - 0.026)$	$\lambda_{13}$	58.968
BF14	$\max(0, Fr_1 - 3.043) \times \max(0, 0.008 - GN)$	$\lambda_{14}$	-240.41
BF15	$\max(0, 0.026 - GN) \times \max(0, Fr_1 - 3.483)$	$\lambda_{15}$	-65.363
BF16	$\max(0, 3.189 - Fr_1)$	$\lambda_{16}$	5.1082

همچنین ضرایب عبارات جبری و توان‌های (نماهای) پارامترهای ورودی ( $Fr_1$ ،  $n$ ،  $GN$  و  $S$ ) با انتخاب از میان‌نماهای ۰،  $\pm 0.5$ ،  $\pm 1$ ،  $\pm 1.5$  و  $\pm 2$  از طریق الگوریتم وراثتی بهینه شدند. در مرحله آموزش تعدادی روابط ریاضی توسط مدل EPR ایجاد گردید. سپس، رابطه‌ای که دارای کم‌ترین مقدار خطا (مجموع مربعات خطا برابر با ۰/۰۳۲) بود در واقع بهترین عملکرد را در تخمین افت انرژی سرریزهای گابیونی نشان داد. در پژوهش حاضر، رابطه (۱۶) با شش جمله ریاضی با ۸۶۴۰ تعداد نسل و تابع داخلی لگاریتم طبیعی حاصل گردید. همچنین در انتخاب تابع داخلی مدل ریاضی EPR، توابع مختلف نمایی (exp)، لگاریتم طبیعی (ln)، سکانت (sec) و تانژانت هائربولیک (tanh)، نمایی موجود می‌باشند. در پژوهش‌های پیشین مرتبط با

در نهایت معادله رگرسیونی حاصل از روش MARS به صوت رابطه (۱۵) است که در آن a عدد ثابت است.

$$1/(1 - K) = 2.44 + \sum_{i=1}^{16} \lambda_i \cdot BF_i \quad (15)$$

همان‌طور که در جدول (۲) ملاحظه می‌شود، رابطه (۱۷) شامل ۱۶ تابع پایه و ضریب وزنی می‌باشد. روابط رگرسیونی درجه دو توابع پایه نشان می‌دهند که کلیه پارامترهای بی‌بعد ( $Fr_1$ ،  $n$ ،  $GN$  و  $S$ ) در تخمین افت انرژی سرریز گابیونی نقش مهمی را ایفا می‌کنند. همچنین ضرایب وزنی در جدول (۲) با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات با ۷۰ تکرار در فرایند بهینه‌سازی و مجذور مربعات خطا برابر با ۰/۰۷۵۴ حاصل شدند.

بدون بعد حاصل از آنالیز ابعادی نقش مهمی را در تخمین افت انرژی ایفا می‌کنند. به‌عنوان مثال، اولین عبارت جبری که شامل توابع داخلی لگاریتمی طبیعی و تابع کسری می‌باشند، شامل کلیه پارامترهای بی‌بعد هستند.

$$\frac{1}{1-K} = 0.5087 \times \frac{1}{n^2 S^{0.5} Fr^2} \times \ln\left(\frac{n Fr^{0.5}}{Fr^{0.5} GN^{1.5}}\right) + 0.024838 \times \ln(n^2 + 4) + 0.14313 \times \frac{1}{n^{1.5} GN^{0.5} Fr^{0.5}} \times \ln\left(\frac{n^{1.5} Fr^{1.5}}{S^{0.5}}\right) + 0.44181 \times \frac{1}{S^{1.5}} \times \ln(n S^{0.5}) + 0.016672 \times \frac{n^{1.5}}{GN} \times \ln(S) + 2.7306 \times n^2 \times \ln\left(\frac{n^{1.5} GN^{0.5}}{Fr^2}\right) + 3.9577 \quad (16)$$

مطابق جدول (۳) معیارهای ارزیابی خطا در جدول مذکور مدل MARS عملکرد مناسب‌تری داشته است. در این مدل مقادیر RMSE، CC، MAPE و SI برای داده‌های آموزش به‌ترتیب برابر ۰/۰۵۴، ۰/۹۹، ۰/۰۱۷ و ۰/۰۴ به‌دست‌آمد. نتایج معیارهای ارزیابی خطا RMSE، CC، MAPE و SI برای داده‌های آموزش و برای مدل مذکور نیز به ترتیب برابر

مطابق جدول (۳) معیارهای ارزیابی خطا در جدول مذکور مدل MARS عملکرد مناسب‌تری داشته است. در این مدل مقادیر RMSE، CC، MAPE و SI برای داده‌های آموزش به‌ترتیب برابر ۰/۰۵۴، ۰/۹۹، ۰/۰۱۷ و ۰/۰۴ به‌دست‌آمد. نتایج معیارهای ارزیابی خطا RMSE، CC، MAPE و SI برای داده‌های آموزش و برای مدل مذکور نیز به ترتیب برابر


جدول ۳- نتایج معیارهای ارزیابی خطا برای مدل‌های مختلف در پیش‌بینی سرریز گابیونی

Table 3 Results of error evaluation criteria for different models in predicting gabion overflow energy loss

Model	CC		RMSE		MAPE		SI	
	Training	Testing	Training	Testing	Training	Testing	Training	Testing
MARS	0.99	0.97	0.054	0.14	0.017	0.072	0.04	0.36
EPR	0.99	0.99	0.11	0.06	0.031	0.034	0.099	0.16

شکل (۱) مقادیر آزمایشگاهی را در مقابل مقادیر پیش‌بینی شده مدل‌ها در بخش آزمایش نشان می‌دهد. همان‌طور که مشخص است RMSE و CC به‌ترتیب در مدل‌های MARS و EPR دارای کم‌ترین و بیش‌ترین مقدار در بین مدل‌هاست. به‌دلیل تعداد کم داده‌های آزمایش نسبت به داده‌های آموزش، طبیعی است که مقادیر خطا در این بخش بیشتر از بخش آموزش باشد. پراکندگی داده‌ها هم مشابه با حالت آموزش است. در هیچ‌یک از مدل‌ها موقعیت

نقاط در خارج از خط‌های  $y=1.25x$  و  $y=0.75x$  نگرفته‌اند. این امر نشان می‌دهد که مقادیر تخمینی و مشاهداتی نزدیک به هم و حول محور خط  $y=x$  هستند. باین‌حال پراکندگی نقاط و معیارهای ارزیابی خطای موجود نشان داد که نتایج مدل‌های MARS و EPR بسیار به هم نزدیک و از دقت قابل‌قبول‌تری نسبت به مدل MT برخوردار هستند.




شکل ۱- مقادیر افت انرژی مشاهداتی و پیش‌بینی شده در مرحله آزمایش: الف- مدل MARS، ب- مدل EPR

Fig 1. Values of observational and predicted energy loss in testing stage: a) MARS model, b) EPR model


برای تحلیل بیش‌تر مدل‌ها از نمودار ویولن<sup>۱</sup> استفاده گردید (شکل ۳). این نمودار که از ترکیب نمودارهای جعبه‌ای و چگالی به‌دست‌آمده است، اطلاعات مفیدتری از داده‌های تخمین زده‌شده توسط مدل‌ها و مقادیر مشاهداتی ارائه می‌دهد. شکل (۳) نمودار مذکور را برای خروجی مدل‌های مورد‌استفاده نشان می‌دهد. مطابق این نمودار مشخص است، میانه داده‌های مشاهداتی حدوداً ۲/۱ است که میانه مدل‌های مورد‌استفاده نیز تقریباً همین مقدار را نشان می‌دهد. این نمودار همچنین نشان می‌دهد که بیش‌تر داده‌های مشاهداتی در حول بازه ۱/۲ تا ۳/۵ قرار داد، و بیش‌ترین احتمال رخ دادن داده‌ها در این ناحیه هستند. نتایج نمودار مذکور نشان می‌دهد که دو مدل MARS و EPR دارای مقادیر میانی، حداکثر و حداقل داده‌های تخمینی بسیار شبیه به مقدار داده‌های مشاهداتی است. با این تفاسیر و مطابق نمودار ویولن می‌توان مدل‌های MARS و EPR را برای تخمین مقدار افت انرژی در سرریزهای گابیونی مناسب دانست.

شکل (۴) داده‌های پیش‌بینی‌شده و مشاهداتی را برای کل داده‌ها نشان می‌دهد. در مرحله اول مشخص است که تمام مدل‌ها روند تغییرات مقادیر  $1/(1-K)$  را به‌درستی تشخیص داده‌اند. مدل MARS مقادیر را همواره در محدود ۰/۶ تا ۱- کم‌تر یا بیش‌تر از حالت واقعی تخمین زده است. این محدوده در یک نمونه داده خاص اتفاق افتاده است. در بیش‌تر نمونه داده‌ها نیز اختلاف بین مقادیر مشاهداتی و تخمین به‌وسیله این مدل بسیار کم و در محدوده ۰/۱ و ۰/۱- بوده است. در مدل EPR وضعیت مقادیر تخمینی نیز مشابه با مدل MARS بوده است. بیش‌ترین مقدار خطا با اختلاف بین ۰/۵- و ۱ صورت گرفته است. این اختلاف در مدل‌های دیگر نیز عکس با مدل MARS است. مقدار متوسط خطا (MSE) به‌همراه انحراف معیار (St.D) مدل MARS به‌ترتیب برابر ۰/۰۳۴ و ۰/۲ است. این مقدار در مدل EPR کمی متفاوت است. در این مدل مقادیر مذکور به‌ترتیب برابر ۰/۰۳ و ۰/۱۷ است. این امر نشان می‌دهد که در تخمین کل داده‌ها، مدل EPR کمی بهتر از MARS توسط دو معیار ارزیابی ذکرشده عمل کرده است.

با توجه به نتایج نمودار تیلور (شکل ۲) بیش‌ترین ضریب همبستگی برای مدل MARS بوده که با داده‌های مشاهداتی بیش‌تر از ۰/۹۹ است. مدل EPR نیز از همبستگی بالایی و در حدود ۰/۹۹ برخوردار بود. مقدار انحراف معیار (مقادیر محور X و Y) برای مدل MARS کمتر از مقدار مشاهداتی آن و نزدیک به ۰/۶۸ است. برای مدل EPR نیز انحراف معیار آن‌ها نزدیک به یکدیگر می‌باشند. نتایج دیاگرام تیلور همچنین نتایج معیارهای ارزیابی موجود در جدول (۳) را تأیید می‌کند.



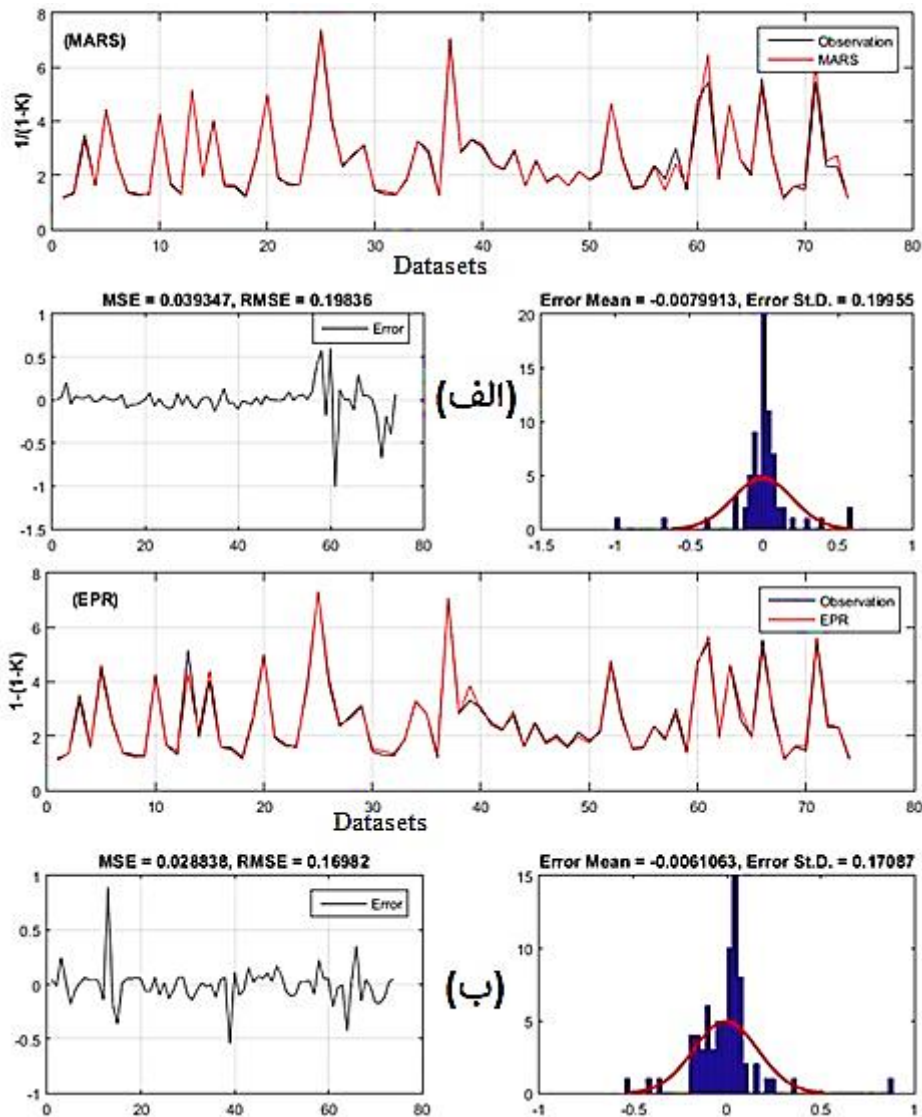
شکل ۲- دیاگرام تیلور  
Fig. 2 Taylor diagram



شکل ۳- نمودار ویولن برای مقایسه نتایج خروجی مدل‌های محاسبات نرم

Fig 3. Violin diagram to compare the output results of the soft computing models

<sup>1</sup> Violin Plot



شکل ۴- مقادیر افت انرژی مشاهده‌ای و پیش‌بینی‌شده توسط مدل‌های محاسبات نرم مورد استفاده برای کل داده‌های مراحل آموزش و آزمایش: الف- مدل MARS، و ب- مدل EPR

Fig. 4 Values of observational and predicted energy loss by soft computing models for whole datasets in training and testing stages: a) MARS model, b) EPR model

نزدیک به هم برخوردار بودند. بنابراین استفاده از مدل EPR و معادله رگرسیونی استخراجی از آن‌ها از دقت نسبتاً خوبی نسبت به معادلات رگرسیونی سایر مدل‌ها برخوردار است. اما عیب این مدل این است که معادله منتج آن طولانی و از پیچیدگی زیاد برخوردار است. بنابراین شاید بتوان به این نتیجه رسید که این مدل نسبت به بهبود دقت تخمین، عملکرد زیاد مناسبی نداشته است.

#### ۴- نتیجه‌گیری

سازه‌های توری سنگی و مهم‌ترین آن‌ها یعنی سرریزهای پلکانی گابیونی به لحاظ پایداری مناسب و استهلاک بالای انرژی آب، کاربرد گسترده‌ای در مهندسی هیدرولیک دارد.

در تخمین مقدار افت انرژی در سرریزهای گابیونی با استفاده از مدل‌های هوش مصنوعی پژوهش‌های بسیار محدودی انجام شده است. بنابراین در مقایسه با پژوهش‌ها Khatibi et al. (2014) در تخمین مقدار افت انرژی می‌توان چنین بیان کرد که دقت مدل EPR و MARS نزدیک یا بهتر از دقت نتایج ANN و GEP بوده است. این پژوهش همچنین تأیید کننده نتایج پژوهش‌های Barani and Sadeghi (2003) در استفاده از عملکرد شبکه عصبی مصنوعی برای تخمین افت انرژی در سرریزهای گابیونی بوده است. البته باید ذکر کرد که معادله رگرسیونی استخراجی از EPR به مراتب بسیار پیچیده‌تر از معادله رگرسیونی پژوهش‌های Khatibi et al. (2014) است. البته هر دو معادلات از دقت قابل قبول و

RMSE برای مدل MARS است که در حدود ۰/۰۵۶/۰ در داده‌های آموزش به دست آمد.

در نهایت با توجه به اهمیت موضوع و گستردگی مدل‌های هوش مصنوعی و با توجه به نتایج پژوهش انجام‌شده، مواردی برای ادامه کار پیشنهاد می‌گردد. در نظر گرفتن عدم قطعیت مدل‌های موردبررسی، ارزیابی سایر مدل‌های هوش مصنوعی مانند سامانه استنتاج فازی، شبکه عصبی موجک و مدل‌های یادگیری عمیق جهت پیش‌بینی افت انرژی در سرریزهای گابیونی از جمله این پیشنهادها است. همچنین استفاده از تعداد زیاد نمونه داده (بیش از ۷۴ نمونه داده موجود در این پژوهش) منجر به ساخت بهتر مدل‌های هوش مصنوعی برای بهبود پژوهش‌های آتی خواهد شد.

#### دسترسی به داده‌ها

تمام داده‌های تولید شده یا تحلیل شده در این پژوهش در مقاله دیگری با شماره DOI (<https://doi.org/10.1007/s11269-014-0545-y>) موجود است

#### تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که، هیچ‌گونه تضاد منافی در رابطه با نویسندگی و یا انتشار این مقاله ندارند.

## References

- Barani, G. and Sadeghi, H. (2003). Estimation of energy dissipation over stepped weirs using artificial neural network. Proc. 2003 6<sup>th</sup> Int. Conf. on Civil Engineering, Iran [In Persian]
- Chen, W., Panahi, M., Khosravi, K., Pourghasemi, H. R. and Rezaie, F. and Parvinnezhad, D. (2019). Spatial prediction of groundwater potentiality using ANFIS ensembled with teaching-learning-based and biogeography-based optimization. J. Hydrol., 572, 435-448. DOI: [10.1016/j.jhydrol.2019.03.013](https://doi.org/10.1016/j.jhydrol.2019.03.013).
- Fathi-moghaddam, M., Sadrabadi, M. T. and Rahmanshahi, M. (2018). Numerical simulation of the hydraulic performance of triangular and trapezoidal gabion weirs in free flow condition. J. Flow Measure. Instrument., 62(1), 93-104. DOI: [10.1016/j.flowmeasinst.2018.05.005](https://doi.org/10.1016/j.flowmeasinst.2018.05.005)
- Friedman, J. H. (1991). Multivariate adaptive regression splines. Annal. Statistic., 19(1), 1-67. DOI: [10.1214/aos/1176347963](https://doi.org/10.1214/aos/1176347963)

در این پژوهش به تخمین افت انرژی جریان از روی سرریزهای پلکانی گابیونی با استفاده از دو مدل یادگیری ماشین (مدل‌های MARS و EPR) بر مبنای استخراج رابطه رگرسیونی پرداخته شد. از ۷۴ داده آزمایشگاهی Khatibi et al. (2014) برای ارزیابی مدل‌ها استفاده شد. با توجه به ماهیت مدل‌های هوش مصنوعی با ۷۵٪ داده‌ها مدل‌های مذکور ساخته و روابط آن‌ها نیز استخراج شد. با توجه به نتایج می‌توان نتیجه‌گیری ذیل را برای این پژوهش لحاظ نمود.

۱- مدل MARS مناسب‌ترین مدل برای پیش‌بینی افت انرژی در سرریز گابیونی بود. در این مدل مقادیر RMSE، CC، MAPE و SI برای داده‌های آزمایش به ترتیب برابر ۰/۰۵۴، ۰/۹۹، ۰/۱۷ و ۰/۰۴ به دست آمد.

۲- دقت پیش‌بینی مدل MARS و EPR بهتر از مدل‌های ANN و GEP در پژوهش‌های Khatibi et al. (2014) بود.

۳- در نمودار تیلور بیش‌ترین ضریب همبستگی برای مدل MARS بوده که برابر با ۰/۹۹ بود. همچنین کم‌ترین مقدار

- Ghorbani, A. and Eslami, A. (2021). Energy-based model for predicting liquefaction potential of sandy soils using evolutionary polynomial regression method. Comput. Geotechnic., 129, 103867. DOI: [10.1016/j.compgeo.2020.103867](https://doi.org/10.1016/j.compgeo.2020.103867)
- Giustolisi, O. and Savic, D. A. (2006). A symbolic data-driven technique based on evolutionary polynomial regression. J. Hydroinform., 8(3). DOI: [10.2166/hydro.2006.020b](https://doi.org/10.2166/hydro.2006.020b)
- Jamei, M., Karbasi, M., Mosharaf-Dehkordi, M., Olumegbon, I. A., Abualigah, L., Said, Z. and Asadi, A. (2021). Estimating the density of hybrid nanofluids for thermal energy application: Application of non-parametric and evolutionary polynomial regression data-intelligent techniques. Measure., 110524. DOI: [10.1016/j.measurement.2021.110524](https://doi.org/10.1016/j.measurement.2021.110524)
- Kayhomayoon, Z. Azar, N. A. Milan, S. G. Moghaddam, H. K. and Berndtsson, R. (2021). Novel approach for predicting

- groundwater storage loss using machine learning. *J. Environ. Manage.*, 296, 113237. DOI: [10.1016/j.jenvman.2021.113237](https://doi.org/10.1016/j.jenvman.2021.113237)
- Khatibi, R., Salmasi, F., Ghorbani, M. A. and Asadi, H. (2014). Modelling energy dissipation over stepped-gabion weirs by artificial intelligence. *Water Resour. Manage.*, 28(7), 1807-1821. DOI: [10.1007/s11269-014-0545-y](https://doi.org/10.1007/s11269-014-0545-y)
- Mehri, Y., Soltani, J. and Khashehchi, M. (2019). Predicting the coefficient of discharge for piano key side weirs using GMDH and DGMDH techniques. *Flow Measure. Instrument.*, 65, 1-6. DOI: [10.1016/j.flowmeasinst.2018.11.002](https://doi.org/10.1016/j.flowmeasinst.2018.11.002)
- Milan, S. G., Roozbahani, A., Azar, N. A. and Javadi, S. (2021). Development of adaptive neuro fuzzy inference system–Evolutionary algorithms hybrid models (ANFIS-EA) for prediction of optimal groundwater exploitation. *J. Hydrol.*, 598, 126258. DOI: [10.1016/j.jhydrol.2021.126258](https://doi.org/10.1016/j.jhydrol.2021.126258)
- Moghaddam, H. K., Milan, S. G., Kayhomayoon, Z. and Azar, N. A. (2021). The prediction of aquifer groundwater level based on spatial clustering approach using machine learning. *Environ. Monit. Assess.*, 193(4), 1-20. DOI: [10.1007/s10661-021-08961-y](https://doi.org/10.1007/s10661-021-08961-y)
- Naseri, R. and Kashefipour, S. M. (2019). The effect of stepped spillway proslity with gabion on weir energy dissipation and characteristics of downstream hydraulic jump. *Irrig. Sci. Eng.*, 45(1), 1-17. DOI: [10.22055/jise.2019.18454.1337](https://doi.org/10.22055/jise.2019.18454.1337) [In Persian]
- Reeve, D. E., Zuhaira, A. A. and Karunaratna, H. (2019). Computational investigation of hydraulic performance variation with geometry in gabion stepped spillways. *Water Sci. Eng.*, 12(1), 62-72. DOI: [10.1016/j.wse.2019.04.002](https://doi.org/10.1016/j.wse.2019.04.002)
- Rezaie-Balf, M. (2019). Multivariate adaptive regression splines model for prediction of local scour depth downstream of an apron under 2D horizontal jets. *Iran. J. Sci. Technol. Transact. Civil Eng.*, 43(1), 103-115. DOI: [10.1007/s40996-018-0151-y](https://doi.org/10.1007/s40996-018-0151-y)
- Salmasi, F., Farsadizade, D. and Mohit, H. (2011). Experimental Evaluation of energy dissipation over gabion stepped spillway. *Wate Soil Sci.*, 21(4), 152-164 [In Persian].
- Sattar, A. A., Elhakeem, M., Rezaie-Balf, M., Gharabaghi, B. and Bonakdari, H. (2019). Artificial intelligence models for prediction of the aeration efficiency of the stepped weir. *Flow Measure. Instrument.*, 65, 78–89. DOI: [10.1016/j.flowmeasinst.2018.11.017](https://doi.org/10.1016/j.flowmeasinst.2018.11.017)
- Vashisth, A. (2017). Energy dissipation over stepped gabion weir. *Int. J. Dynamic. Fluid.*, 13(1), 153-159.
- Zhang, W. and Goh, A. T. (2016). Multivariate adaptive regression splines and neural network models for prediction of pile drivability. *Geosci. Front.*, 7(1), 45-52. DOI: [10.1016/j.gsf.2014.10.003](https://doi.org/10.1016/j.gsf.2014.10.003)

### How to cite this paper:

Mobayen, R., Najafzadeh, M. and Farrahi-Moghaddam, K. (2023). Evaluation of regression-based soft computing techniques for estimating energy loss in gabion spillways. *Environ. Water Eng.*, 9(2), 241–255. DOI: [10.22034/ewe.2022.329153.1724](https://doi.org/10.22034/ewe.2022.329153.1724)