



# Prediction of Shear Capacity of Reinforced Concrete Beams using Support Vector Regression and Adaptive Neuro-Fuzzy Inference Algorithms Optimized with Meta-Heuristic Algorithms

F. Esfandnia, M. R. Mohammadzadeh\*

Department of Civil Engineering, University of Hormozgan, Bandar Abbas, Iran.

**ABSTRACT:** Considering the complexity of shear mechanisms of reinforced concrete beams and the effects of various parameters, creating a general model for the accurate estimation of the shear capacity is difficult. In addition, most guidelines for the determination of the shear capacity of reinforced concrete beams in empirical design codes have been obtained experimentally. Artificial intelligence algorithms have been widely used in this area in recent years. In this study, SVR, PANFIS, and GANFIS algorithms were used to predict the shear capacity of reinforced concrete beams. In this regard, the data of 175 experimental RC beam samples were collected. In these algorithms, values of nine parameters affecting shear capacity were used as the input parameter and the shear capacity of the reinforced concrete beams as the output parameter. Using the Kfold validation method, training and test data were defined, and the predictions were performed accordingly. The results of predictions showed that the neuro-fuzzy inference system model with the genetic optimization algorithm had a higher accuracy than other algorithms with a second root mean square error of 0.06634 and a correlation coefficient of 0.996. Also, the grey system theory was used to determine the parametric sensitivity of the study variables on the shear capacity of reinforced concrete beams. The results showed that the mean coefficient of sensitivity analysis of the longitudinal rebar percentage parameter is greater than other parameters, indicating that the longitudinal rebar percentage parameter had more effects on shear capacity.

## Review History:

Received: Jan. 26, 2020

Revised: Mar. 04, 2020

Accepted: Mar. 10, 2020

Available Online: Apr. 03, 2020

## Keywords:

Shear capacity

Reinforced concrete beam

GST

PANFIS

GANFIS

SVR

## 1. INTRODUCTION

Since shear mechanisms of reinforced concrete beams (RCs) are very complex, it is difficult to develop a general model capable of estimating the shear capacity accurately. Improving prediction performance is significantly important when designing reinforced concrete beams. Recently, artificial intelligence (AI) algorithms were proposed as one of the key strategies that can provide an acceptable model for this purpose [1]. Accordingly, many emphasized the successful application of artificial intelligence in civil engineering including the work of Dao *et al.*, Moshiri and Ala, Sogana *et al.*, and Naderpour and Mirshid [2-5]. In the present paper, first, we studied the parameter sensitivity analysis, and then, the performances of three different artificial intelligence algorithms (SVR, PANFIS, and GANFIS) were investigated. Finally, the obtained results about the prediction performance of these algorithms were analyzed and compared with each other.

## 2. EXPERIMENTAL DATA


The experiment data are applied as input and output data to conduct the sensitivity analysis on the given parameters using the GST algorithm and predict the shear capacity

of reinforced concrete beams using SVR, PANFIS, and GANFIS algorithms. Experimental data obtained from 175 reinforced concrete beams with shear reinforcement have been used for this purpose [6].

## 3. SENSITIVITY ANALYSIS USING GST (GREY SYSTEM THEORY)

The process of analyzing a particular relationship or a particular model and also examining the impact of changes on each parameter in the model output is called sensitivity analysis. In this section, a numerical model of GST theory [7] is used to determine the parametric sensitivity of variables investigated to determine the shear capacity of reinforced concrete beams. In this theory,  $\lambda$  is used as an indicator of the relationship between independent and dependent variables. The closer the value gets to 1, the stronger the correlation between the two variables. According to the above explanation, the diagram of correlations between each independent parameter and the shear capacity was indicated in Fig. 1. It can be seen that the maximum value is related to the percentage of longitudinal reinforcement ( $\rho_l$ ).

\*Corresponding author's email: mrzmohammadzadeh@yahoo.com






Fig. 1. Parametric sensitivity analysis for key variables of shear capacity

#### 4. PREDICTING THE SHEAR CAPACITY OF REINFORCED CONCRETE BEAMS WITH SVR, PANFIS, AND GANFIS ALGORITHMS

##### 4.1. Support vector regression (SVR)

Support vector regression is a machine learning algorithm that works based on statistical training theory. This algorithm is one of the supervised training algorithms and connects the input data to the dependent parameter values by minimizing the structural risk. A kernel function is used to solve the operating issue of this algorithm in a high-dimensional space. The purpose of SVR is to estimate the weights and the slopes parameters of the function that have the best compatibility with the data [8].

##### 4.2. An adaptive neuro-fuzzy inference system

The fuzzy inference system (FIS) is introduced as a nonlinear mapping of the input space to the output space. The mapping mechanism is based on converting input parameters from the numerical scale to fuzzy scale using three functional components including (1) a set of rules that consisting of fuzzy rules; (2) a database defining the membership functions (MFs) used in fuzzy rules; and (3) a reasoning mechanism that use the inference method based on the rules to obtain an output. The ANFIS algorithm was applied based on the adaptive network’s framework [9]. The ANFIS algorithm uses the advantages of neural networks and fuzzy systems. In this algorithm, data training is considered as a major challenge. Hence, meta-heuristic algorithms with a random search nature may be used as an alternative and useful choice of algorithms. The weights obtained from the previous fuzzy parameters and the linear parameters  $C_i$  are adjusted through the heuristic algorithms to solve the optimization problem caused by using PSO and GA algorithms.

##### 4.3. Particle swarm optimization Algorithm (PSO)

The particle swarm optimization Algorithm is considered as one of the most important algorithms in the field of swarm intelligence. This algorithm was introduced by Kennedy *et al.* (1995) and was designed by inspiring the social behavior of animals such as fish and birds that live in small and large groups. This algorithm works based on the fact that in every moment, each particle adjusts its location on the search space

Table 1. Comparison of results obtained by using SVR, PANFIS, GANFIS, ANN algorithms, and ACI-318-02 and CSA regulations

Method	Reference	RMSE	R <sup>2</sup>
SVR	Present study	0.0994	0.925
PANFIS	Present study	0.07541	0.986
GANFIS	Present study	0.06634	0.996
ACI	[6]	0.14	0.87
CSA	[6]	0.114	0.82
ANN	[6]	0.097	0.96

by comparing the best location it has positioned into and the best location in all its neighborhoods [10].

##### 4.4. Genetic algorithm (GA)

The genetic algorithm is one of the first evolutionary algorithms, which was defined based on the genetic process of individuals [11]. To solve the problems, the genetic algorithms simulate the “survival of the fittest” principle among members of a population over successive generations. Each generation consists of a string of characters that their functions are similar to DNA chromosomes. Each person represents a point in the search space and a possible solution. Members of each generation also go through a process similar to that of living things.

#### 5. PREDICTION ALGORITHMS ANALYSIS

##### 5.1. Validation method

In the present study, the dataset was divided randomly for training and testing purposes with the use of k-fold cross-validation ( $k = 10$ ). In each iteration, one subset was used for the validation process, while the other nine subsets were used for the training process. In total, 157 data were randomly selected for the training part and the rest of the data were used for testing.

##### 5.2. Results analysis

In this section, the obtained results of the prediction performance of SVR, PANFIS, and GANFIS algorithms were compared with the shear capacity defined in the ACI [12] and CSA [13] construction regulation. The root mean square error (RMSE) and the coefficient of determination ( $R^2$ ) values are presented in Table 1 for 175 reinforced concrete beam specimens obtained from SVR, PANFIS, GANFIS, ANN algorithms based on ACI-318-02 and CSA regulations. According to the results, the accuracy of predictions of the GANFIS algorithm on the shear strength parameter of reinforced concrete beams is higher than other developed algorithms. According to the results, the GANFIS algorithm with  $RMSE = 0.0634$  (the second root mean square error) and  $R^2 = 0.996$  have the highest accuracy when predicting shear capacity in reinforced concrete beams among all the algorithms used in this study.

## 6. CONCLUSION

The present study suggests that the PANFIS and GANFIS artificial intelligence algorithms can be used to predict the ultimate shear capacity of reinforced concrete beams. The results indicated that the GANFIS algorithm has better and stronger prediction power compared to SVR, PANFIS, ANN algorithms, and ACI-318-02 and CSA regulations. In another part of the study, the sensitivity analysis of parameters was investigated with the use of the GST theory. The results of this analysis exhibited that the average value of the correlation index between shear capacity and effective parameters is higher for the percentage of longitudinal reinforcement ( $\rho_l$ ) compared to other parameters.

## REFERENCES

- [1] Danglade, F., Pernot, J.P., Véron, P., and Fine, L., 2017. "Evaluation of simulation models preparation processes using artificial intelligence techniques", *Computers in Industry*, 91, 45-61.
- [2] Dao, D. V., Ly, H. B., Trinh, S. H., Le, T. T., and Pham, B. T., 2019. "Artificial intelligence approaches for prediction of compressive strength of geopolymer concrete" *Materials*, 12(6), 983-990.
- [3] Mashrei, M. A., and Mahdi, A. M., 2019. "An Adaptive Neuro-Fuzzy Inference Model to Predict Punching Shear Strength of Flat Concrete Slabs" *Journal of Applied Sciences*, 9(4), 809-829.
- [4] Naderpour, H., and Mirrashid, M., 2018. "Shear Strength Prediction of RC Beams Using Adaptive Neuro-Fuzzy Inference System" *Scientia Iranica*,
- [5] Suguna, K., Raghunath, P. N., Karthick, J., and Uma Maheswari, R., 2018. "ANN based modeling for high strength concrete beams with surface mounted FRP laminates" *International Journal of Optimization in Civil Engineering*.
- [6] Mansour, M. Y., Dicleli, M., Lee, J. Y., and Zhang, J., 2004. "Predicting the shear strength of reinforced concrete beams using artificial neural networks" *Engineering Structures*, 26(6), 781-799.
- [7] Liu, S., Zhang, H., and Yang, Y., 2017. "Explanation of terms of grey incidence analysis models" *Grey Systems: Theory and Application*, 7(1), 136-142.
- [8] Yu, H., and Kim, S., 2012. SVM tutorial: classification, regression, and ranking Handbook of Natural Computing, Springer Berlin Heidelberg, 479-506.
- [9] Guan, J., Zurada, J., and Levitan, A., 2008. "An Adaptive Neuro-fuzzy inference system-based approach to real estate property assessment" *Journal of Real Estate Research*, 30(4), 395-422.
- [10] Eberhart, R. C., Shi, Y., and Kennedy, J., 2001, intelligence, Morgan Kaufmann Publishers.
- [11] Holland, J. H., 1992. "Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence" *MIT press*.
- [12] American Concrete Institute (ACI), 2011. "Committee 318-11: Building Code Requirements for Structural Concrete and Commentary", American Concrete Institute, USA.
- [13] Canadian, C. S. A., 1994. "Building Code, Design of Concrete Structures (Design)-A National Standard of Canada (CAN-A23. 3-94)" Clause 11.1.2, Toronto.

### HOW TO CITE THIS ARTICLE

F. Esfandnia, M.R. Mohammdzadeh, Prediction of Shear Capacity of Reinforced Concrete Beams using Support Vector Regression and Adaptive Neuro-Fuzzy Inference Algorithms Optimized with Meta-Heuristic Algorithms, Amirkabir J. Civil Eng., 53(8) (2021) 719-722.

DOI: [10.22060/ceej.2020.17798.6679](https://doi.org/10.22060/ceej.2020.17798.6679)







## پیش بینی ظرفیت برشی تیرهای بتن مسلح با استفاده از الگوریتم های رگرسیون بردار پشتیبان و سیستم استنتاج تطبیقی فازی-عصبی بهینه شده با الگوریتم های فرا ابتکاری

فرناز اسفند نیا، محمد رضا محمدی زاده\*

دانشکده فنی و مهندسی، دانشگاه هرمزگان، بندرعباس، ایران

### تاریخچه داوری:

دریافت: ۱۳۹۸/۱۱/۰۶  
بازنگری: ۱۳۹۸/۱۲/۱۴  
پذیرش: ۱۳۹۸/۱۲/۲۰  
ارائه آنلاین: ۱۳۹۹/۰۱/۱۵

### کلمات کلیدی:

ظرفیت برشی  
تیر بتن مسلح  
GST  
PANFIS  
GANFIS  
SVR

**خلاصه:** با توجه به پیچیدگی مکانیزم های برشی تیرهای بتن مسلح و تأثیرگذاری پارامترهای مختلف، ایجاد یک مدل کلی جهت تخمین دقیق ظرفیت برشی، دشوار می باشد. همچنین اکثر دستورالعمل های تعریف شده برای تعیین ظرفیت برشی تیرهای بتن مسلح در آیین نامه های طراحی به صورت تجربی بدست آمده است. در سال های اخیر الگوریتم های هوش مصنوعی در این زمینه بسیار مورد استفاده واقع شده است. در این مطالعه از الگوریتم های رگرسیون بردار پشتیبان و سیستم استنتاج تطبیقی فازی-عصبی بهینه شده با دو الگوریتم انبوه ذرات و الگوریتم ژنتیک برای پیش بینی ظرفیت برشی تیرهای بتن مسلح استفاده شده است. در این الگوریتم ها، مقادیر ۹ پارامتر تأثیرگذار در ظرفیت برشی به عنوان ورودی و ظرفیت برشی تیرهای بتن مسلح به عنوان پارامتر خروجی مورد استفاده قرار گرفته است. با استفاده از روش اعتبارسنجی Kfold، داده های آموزشی و تستی تعریف شده و بر اساس این داده ها پیش بینی صورت گرفته است. نتایج بدست آمده از پیش بینی نشان داد که مدل سیستم استنتاج فازی عصبی با الگوریتم بهینه سازی ژنتیک با ریشه دوم میانگین مربعات خطا برابر ۰/۰۶۶۳۴ و ضریب همبستگی ۰/۹۹۶ نسبت به سایر الگوریتم ها از دقت بالاتری برخوردار است. همچنین جهت تعیین حساسیت پارامتری متغیرهای مورد بررسی بر روی ظرفیت برشی تیرهای بتن مسلح از تئوری سیستم خاکستری (GST) استفاده شد. بررسی نتایج حاصل از این آنالیز نشان می دهد که میانگین ضریب آنالیز حساسیت پارامتر درصد آرماتورهای طولی ( $\rho_l$ ) نسبت به سایر پارامترها بزرگتر است که نشان از تأثیر بیشتر پارامتر درصد آرماتورهای طولی بر روی ظرفیت برشی دارد.

### ۱- مقدمه

از همین رو، بتن های مسلح ( $RC^1$ ) جهت مقاومت در برابر شکست برشی به کار گرفته می شوند. با توجه به پیچیدگی مکانیزم های برشی تیرهای بتن مسلح ( $RC$ ) و تأثیرگذاری پارامترهای مختلف، ایجاد یک مدل کلی جهت تخمین دقیق ظرفیت برشی، دشوار می باشد و اکثر آیین نامه های طراحی و دستورالعمل های تعریف شده برای ظرفیت برشی تیرهای بتن مسلح به صورت تجربی بدست آمده است. فرمول های تجربی پیشنهادی در آیین نامه های بتن تنها برای مجموعه داده هایی خاص نتایج خوبی را ارائه می دهند. همچنین در بسیاری از پژوهش ها تلاش شده است که ظرفیت برشی تیرهای

امروزه سازه های بتنی بسیار مورد استفاده قرار می گیرند. چندین حالت شکست در امان های سازه های بتن وجود دارد. شکست برشی از جمله مهم ترین و نامطلوب ترین حالات شکست می باشد. شکست برشی که بر اثر نیروهای برشی و گشتاور خمشی به وجود می آید، با انحراف بسیار کوچک و عدم شکل پذیری مشخص می شود [۱]. چنین شکستی به صورت ناگهانی و بدون هیچ هشدار رخ می دهد.

\* نویسنده عهده دار مکاتبات: mrz\_mohammadizadeh@hormozgan.ac.ir

1 Reinforced concrete



نتایج بدست آمده از این تحقیق نشان داد که الگوریتم های ANN و ANFIS پتانسیل بسیار بالایی برای پیش بینی مقاومت فشاری بتن های ژئوپلیمری دارند [۱۱]. همچنین از دیگر کاربردهای موفق این الگوریتم در مهندسی عمران می توان به کارهای مشیری و آلا<sup>۶</sup>، سوگانا و همکاران<sup>۷</sup>، نادرپور و میررشید، کشاورز و ترکیان، ساتاپان و همکاران<sup>۸</sup>، اوزکان و همکاران<sup>۹</sup>، گل افشانی و همکاران، الشیری و همکاران<sup>۱۰</sup>، سبحانی و همکاران، بال و بویل<sup>۱۱</sup>، گانگ و زانگ<sup>۱۲</sup>، ویلد و همکاران<sup>۱۳</sup>، خطیبی نیا و محمدی زاده اشاره نمود [۲۴-۱۲]. رگرسیون بردار پشتیبان (SVR<sup>۱۴</sup>) یکی دیگر از برجسته ترین الگوریتم های هوش مصنوعی برای حل مشکلات مهندسی در پیش بینی می باشد. از ویژگی های شاخص این الگوریتم قابلیت اطمینان و دقت بالای آن می باشد [۲۵]. یادگیری ماشین به عنوان یک ابزار مدل سازی پیشرفته به طور مؤثر در مهندسی عمران به کار گرفته شده است که در این راستا می توان به کارهای ماندهر یاسین و همکاران<sup>۱۵</sup>، کشتکار و همکاران، پال و همکاران<sup>۱۶</sup>، خادمی و همکاران، لی و همکاران<sup>۱۷</sup>، هوآنگ و همکاران<sup>۱۸</sup>، چو و همکاران<sup>۱۹</sup> و غلامپور و همکاران اشاره نمود [۳۳-۲۶]. همچنین از تحقیق فام<sup>۲۰</sup> و همکاران می توان به عنوان یکی از جامع ترین پژوهش های پیش بینی با استفاده از الگوریتم های هوش مصنوعی و یادگیری ماشین در حوزه مهندسی عمران نام برد. در این تحقیق با استفاده از الگوریتم های مختلف یادگیری ماشین مانند PANFIS<sup>۲۱</sup>، GANFIS<sup>۲۲</sup>، SVR و ANN به پیش بینی ظرفیت برشی خاک نرم پرداخته شده است. نتایج این پژوهش نشان می دهد که الگوریتم PANFIS از بالاترین قابلیت پیش بینی برخوردار است [۳۴]. کاربرد الگوریتم های مختلف هوش

بتن مسلح (RC) با استفاده از روابط تجربی مختلف و مدل های تحلیلی، پیش بینی شود [۲-۳]. بهبود عملکرد پیش بینی در طراحی تیرهای بتن مسلح از اهمیت بسیار زیادی برخوردار است، بنابراین یک مدل مؤثر جهت افزایش دقت پیش بینی ظرفیت برشی برای انواع مختلف تیر بتن مسلح مورد نیاز می باشد. از جمله راهکارهایی که در سال های اخیر جهت ارائه یک مدل مناسب برای انجام این کار پیشنهاد شده است، استفاده از الگوریتم های هوش مصنوعی (AI<sup>۱</sup>) است. الگوریتم های هوش مصنوعی در برنامه های مختلفی مانند پیش بینی فیزیکی، طراحی، شناخت، مهندسی معکوس و به کار گرفته شده است [۴]. این الگوریتم ها نسبت به روش های معمول از قابلیت پیش بینی بهتری برخوردار هستند. شبکه عصبی مصنوعی (ANN<sup>۲</sup>) از جمله اولین الگوریتم های هوش مصنوعی بوده است که در پیش بینی ظرفیت برشی تیرها به کار گرفته شده است [۵-۶]. هرچند این الگوریتم در بسیاری از مسائل و برنامه های کاربردی به کار گرفته می شود، اما توسعه آن می تواند زمانگیر باشد. مهم ترین مزیت الگوریتم ANN این است که نیازی به اولویت بندی ارتباط عملکردی بین متغیرهای مختلف وجود ندارد. الگوریتم استنتاج تطبیقی فازی-عصبی (ANFIS<sup>۳</sup>) یکی دیگر از الگوریتم های هوش مصنوعی می باشند که قابلیت پیش بینی مناسبی دارند. این سیستم ها ترکیبی از ویژگی های برجسته سیستم استنتاج فازی (FIS<sup>۴</sup>) و شبکه عصبی می باشند. در این سیستم ها قوانین فازی نمونه ها از طریق شبکه عصبی (ANN) تعیین می شود [۷]. در یکی از جدیدترین پژوهش های صورت گرفته، با بهره گیری از الگوریتم های عصبی-فازی به آنالیز عوامل تأثیرگذار بر پیش بینی ظرفیت برشی یک اتصال برشی زاویه دار V شکل در تیرهای کامپوزیت پرداخته شده است [۸]. در پژوهشی دیگر با استفاده از الگوریتم ANFIS به ارزیابی عوامل مؤثر بر ظرفیت برشی کامپوزیت های فولادی پرداخته شده است [۹]. کاربرد الگوریتم های ANFIS بر عملکرد اتصالات برشی زاویه ای C و L در پژوهش [۱۰] مورد بررسی قرار گرفته است. دائو<sup>۵</sup> و همکاران به استفاده از هوش مصنوعی برای پیش بینی مقاومت فشاری بتن ژئوپلیمری پرداختند.

- 6 Mashrei & Alla
- 7 Suguna et al.
- 8 Saathappan et al.
- 9 Ozkan et al.
- 10 Alshiri et al.
- 11 Bal et al.
- 12 Guang & Zong
- 13 Wild et al.
- 14 Support Vector Regression
- 15 Mandher Yaseen et al.
- 16 Pal et al.
- 17 Li et al.
- 18 Hoang et al.
- 19 Chou et al.
- 20 Pham
- 21 Particle Swarm Optimization - Adaptive Network based Fuzzy Inference System
- 22 Genetic Algorithm - Adaptive Network based Fuzzy Inference System

- 1 Artificial Intelligence
- 2 Artificial Neural Network
- 3 Adaptive Neuro-Fuzzy Inference System
- 4 Fuzzy Inference System
- 5 Dao et al.

در ابتدا به بررسی آنالیز حساسیت پارامترها و سپس بررسی عملکرد سه الگوریتم SVR، PANFIS و GANFIS پرداخته شده و پس از آن نتایج حاصل از پیش بینی صورت گرفته توسط هر یک از این الگوریتم‌ها ارزیابی و با یکدیگر مقایسه می‌گردد. طرح کلی این مقاله به شرح زیر است. در بخش ۲، داده‌های تجربی مورد استفاده در الگوریتم‌های مختلف هوش مصنوعی مورد بحث قرار می‌گیرند. در بخش ۳، به بررسی آنالیز حساسیت پارامترها با استفاده از تئوری GST پرداخته می‌شود. همچنین عملکرد الگوریتم‌های SVR، PANFIS و GANFIS در بخش ۴ ارزیابی می‌شوند و نتایج با یکدیگر و آیین‌نامه‌های ACI و CSA برای نشان دادن کارایی و دقت الگوریتم‌ها در بخش ۵ مقایسه می‌شوند.

## ۲- داده های تجربی

جهت آنالیز حساسیت پارامترها با استفاده از الگوریتم GST و پیش بینی ظرفیت برشی تیرهای بتن مسلح با استفاده از الگوریتم‌های SVR، PANFIS و GANFIS نیازمند داده های تجربی می باشد تا به عنوان داده های ورودی و خروجی مورد استفاده قرار گیرند. برای این منظور از داده های تجربی ۱۷۵ تیر بتن مسلح که دارای آرماتور برشی می باشند، بهره گرفته شده است [۶]. براساس مطالعات صورت گرفته در این زمینه، پارامترهای مؤثر بر ظرفیت برشی تیرهای بتن مسلح عبارتند از: فاصله برش ( $a$ )، طول مؤثر تیر ( $L$ )، عمق مؤثر ( $d$ )، عرض مقطع ( $b_w$ )، مقاومت فشاری ۲۸ روزه بتن سیلندری نمونه  $15 \times 30$  آمریکایی ( $f'_c$ )، تنش تسلیم آرماتورهای طولی ( $f_{yt}$ )، تنش تسلیم آرماتورهای عرضی ( $f_{yt}$ )، درصد آرماتور طولی ( $\rho_l$ ) و درصد آرماتورهای برشی ( $\rho_t$ ). پارامتر تعریف شده به عنوان ورودی در هر یک از الگوریتم‌های هوش مصنوعی استفاده می شوند و مقدار ظرفیت برشی تیرهای بتن مسلح نیز به عنوان خروجی این سیستم ها می باشد. در جدول ۱، محدوده پارامترهای ورودی داده های مذکور، نشان داده شده است. به منظور عملکرد بهتر در آنالیز حساسیت و پیش بینی ظرفیت برشی تیرهای بتن مسلح با استفاده از الگوریتم‌های SVR، PANFIS و GANFIS مقادیر پارامترهای مؤثر پس از نرمال سازی مورد استفاده قرار می‌گیرد. برای این منظور با استفاده از رابطه (۱)، مقادیر داده های ورودی در بازه  $(-1,+1)$  قرار می‌گیرد [۶].

مصنوعی برای پیش‌بینی ظرفیت برشی تیرهای بتن مسلح با توجه به سادگی و قابلیت اطمینان آن‌ها و همچنین توانایی یادگیری مستقیم از داده‌های تجربی، توجه بسیاری از محققین را به خود جلب نموده است. لازم به ذکر است که رویکردهای مدل‌سازی مبتنی بر یادگیری ماشین و سیستم‌های استنتاج فازی عصبی، اغلب به عنوان جعبه‌های سیاه دیده می‌شوند که در آن‌ها پارامترهای ورودی به پارامتر خروجی تبدیل می‌شوند. با این حال الگوریتم‌های توسعه‌یافته با دقت بالا، از اهمیت فیزیکی لازم برخوردار نمی‌باشند. بنابراین، درک مکانیسم حساسیت پارامترهای ورودی نسبت به پارامتر خروجی، برای ارائه معانی فیزیکی در مدل‌های مبتنی بر الگوریتم‌های هوش مصنوعی ضروری است. نظریه GST<sup>۱</sup> یک روش ریاضی امیدوارکننده برای ارزیابی حساسیت متغیرهای مستقل نسبت به متغیرهای وابسته از نظر همبستگی‌های Grey آنها است؛ یعنی از GST می‌توان برای پیش‌بینی نزدیکی هندسی بین توالی‌های گسسته مختلف درون یک سیستم استفاده کرد [۳۵]. رتبه‌بندی همبستگی‌های Grey بین پارامترهای اصلی و زیر پارامترهای تعیین شده توسط روش GST به عنوان شاخص حساسیت این پارامترها مورد استفاده قرار می‌گیرد. اخیراً پژوهشی در خصوص تئوری GST برای تعیین موفقیت حساسیت پارامتری متغیرها بر روی رفتار فشاری ستون‌های بتن مسلح ساخته شده با استفاده از مواد بازیافتی (RACs<sup>۲</sup>) انجام شده است [۳۶]. بررسی دقیق مطالعات در این زمینه نشان می‌دهد که اطلاعات کمی در خصوص استفاده از این الگوریتم هوش پیشرفته جهت ارزیابی حساسیت پارامتریک وجود دارد. با مرور ادبیات فنی مشخص می‌گردد که اکثر تحقیقات انجام گرفته در خصوص الگوریتم‌های هوش مصنوعی مانند یادگیری ماشین و الگوریتم‌های مدل سازی داده محور، به طور مستقیم و بدون انجام تجزیه و تحلیل حساسیت انجام شده است. در مطالعه حاضر الگوریتم GST برای آنالیز حساسیت پارامترهای مؤثر در ظرفیت برشی تیرهای بتن مسلح مورد بررسی قرار گرفته است. همچنین از الگوریتم‌های رگرسیون بردار پشتیبان (SVR)، سیستم استنتاج تطبیقی فازی-عصبی بهینه شده با دو الگوریتم انبوه ذرات (PANFIS) و الگوریتم ژنتیک (GANFIS) جهت پیش بینی ظرفیت برشی تیرهای بتن مسلح (RC) استفاده شده است. برای این منظور در بخش‌های بعدی،

1 Grey Theory System

2 Recycled Aggregate Concrete

پس از نرمال سازی ضرایب وابستگی خاکستری را می توان مطابق با رابطه ی (۴) بدست آورد.

$$\gamma_i[x_0(j).x_i(j)] = \left| \frac{\min_{i=1..n} \min_{j=1..m} \Delta_i(j) + \rho \max_{i=1..m} \Delta_i(j)}{\Delta_i + \rho \max_{i=1..n} \max_{i=1..m} \Delta_i(j)} \right| \quad (4)$$

که در رابطه فوق:

$$\Delta_i(j) = |x_0(j) - x_i(j)| \quad (5)$$

$$\min_{i=1..n} \min_{j=1..m} \Delta_i(j) = \max_i(\max_j |x_0(j) - x_i(j)|) \quad (6)$$

$$\max_{i=1..n} \max_{i=1..m} \Delta_i(j) = \min_i(\min_j |x_0(j) - x_i(j)|) \quad (7)$$

و  $\rho$  عددی بین ۰ و ۱ می باشد که غالباً برابر با ۰/۵ در نظر گرفته می شود. به کمک ضرایب وابستگی GST می توان میزان همبستگی ماتریس مرجع و ماتریس های مقایسه ای را مطابق با رابطه (۸) بدست آورد.

$$\ddot{e} = \frac{1}{n} \sum_{i=1}^n \gamma_i [x_0(j).x_i(j)] \quad (8)$$

مقدار  $\lambda$  به عنوان شاخص ارتباط بین متغیرهای مستقل و وابسته استفاده می شود که مقدار آن بین ۰ و ۱ می باشد. هر چقدر مقدار  $\lambda$  به ۱ نزدیک تر باشد، همبستگی بین دو متغیر قوی تر می باشد و در طرف مقابل هرچه این مقدار نزدیک به ۰ باشد، همبستگی بین دو متغیر ناچیز است. با توجه به توضیحات گفته شده، در شکل ۱ نمودار مربوط به میزان همبستگی هریک از پارامترهای مستقل بر ظرفیت برشی نشان داده شده است.

نقاط قرمز در شکل، مقدار میانگین  $\lambda$  برای هریک از متغیرها را نشان می دهد. مشاهده می شود که بیش ترین مقدار مربوط به درصد آرماتورهای طولی ( $\rho_l$ ) می باشد. به منظور بررسی دقیق تر در جدول ۲ مقدار میانگین ( $Ave^1$ )، انحراف معیار ( $SD^2$ ) و ضریب

$$U = -1 + 2 \times \frac{(X - X_l)}{(X_u - X_l)} \quad (1)$$

که در این رابطه  $X$  مقدار واقعی پارامترها،  $X_u$  و  $X_l$  به ترتیب به عنوان مقادیر کمینه و بیشینه هر پارامتر می باشند.

### ۳- آنالیز حساسیت با استفاده از تئوری GST

آنالیز حساسیت فرآیندی است که به تجزیه و تحلیل روابط و یا مدلی خاص می پردازد و همچنین تأثیر تغییرات هر یک از پارامترها را به تنهایی و نیز در ارتباط با هم، در خروجی مدل بررسی می کند و همچنین پارامترهایی که حساس تر هستند و نیاز به توجه بیشتری دارند را مشخص می نماید. در این الگوریتم فرض می شود برآوردها در روش تجربی مذکور، صحیح می باشد و تنها حساسیت فاکتورها در قالب کلی مدل سنجیده می شود. در این بخش یک مدل عددی از تئوری GST [۳۷] جهت تعیین حساسیت پارامتری متغیرهای مورد بررسی بر روی ظرفیت برشی تیرهای بتن مسلح به کار گرفته شده است. در GST یک ماتریس مرجع شامل متغیرهای وابسته و یک ماتریس مقایسه ای که در برگیرنده ی متغیرهای مستقل می باشند، در اختیار می باشد. در این مطالعه ظرفیت برشی به عنوان ماتریس مرجع و ۹ پارامتر معرفی شده در بخش ۲ در ماتریس مقایسه ای گنجانده شده اند. مقادیر هریک از ماتریس ها مطابق با رابطه (۲) می باشد.


$$\begin{aligned} X_0 &= X_0(1). X_0(2).....X_0(n) \\ X_1 &= X_1(1). X_1(2).....X_1(n) \\ &..... \\ X_m &= X_m(1). X_m(2).....X_m(n) \end{aligned} \quad (2)$$

در رابطه فوق،  $X_0$  ماتریس مرجع و  $X_1$  تا  $X_m$  ماتریس مقایسه ای می باشند.  $m$  تعداد متغیرهای بکار رفته و  $n$  تعداد مقادیر مربوط به هریک از متغیرها می باشد. در اینجا  $m$  برابر با ۹ و  $n$  برابر با تعداد آزمایش های صورت گرفته است که برابر با ۱۷۵ می باشد. به منظور کاهش نوسانات عددی از رابطه ی (۳) جهت نرمال سازی استفاده می شود.

$$x_i(j) = \frac{X_i(j)}{\frac{1}{n} \sum_{i=1}^n X_i(j)} \quad (3)$$

1 Average  
2 Standard Deviation





شکل ۱. آنالیز حساسیت پارامتری متغیرهای کلیدی بر ظرفیت برشی

Fig. 1. Parametric sensitivity analysis for key variables of shear capacity

جدول ۱. بازه پارامترهای ورودی به الگوریتمهای GST, SVR, PANFIS و GANFIS [۶]

Table 1. Input parameters rang for algorithms: GST, SVR, PANFIS and GANFIS

پارامتر ورودی	بازه
$f'_c$ (MPa)	۴۲/۱۲-۲/۱۷
$f_{y1}$ (MPa)	۳۴۰-۱۰۲۹
$f_{yt}$ (MPa)	۲۵۰-۱۴۳۱
$a/d$	۷/۱-۲/۵۶
$b_w$ (mm)	۱۴۰-۳۰۵
$d$ (mm)	۴۹۵/۲۴۴-۳
$L/d$	۱۴/۳-۴/۳۳
$\rho_l$ (%)	۰/۴-۶۱/۷۶
$\rho_t$ (%)	۱/۰-۴۷/۰۹۹

ارتباط برقرار می‌نماید. کمینه‌سازی ریسک ساختاری، نسبت به الگوریتم متداول کمینه‌سازی ریسک تجربی که مورد استفاده در الگوریتم‌هایی مانند شبکه‌های عصبی و روش‌های کلاسیک آماری است، دارای برتری می‌باشد و برخلاف روش‌هایی مانند شبکه‌های عصبی، به جواب‌های موضعی همگرا نمی‌گردد. SVR الگوریتمی برای تخمین یک تابع می‌باشد که بر اساس داده‌های آموزشی از یک شیء ورودی به یک عدد واقعی نگاشته می‌شود. در مسائل رگرسیون، بردارهای ورودی به یک فضای چند بعدی نگاشت می‌شوند؛ سپس یک ابر صفحه ساخته می‌شود که بردارهای ورودی را با بیشترین فاصله ممکن، از یکدیگر جدا می‌کند. برای رفع مشکل عملیات در فضای با

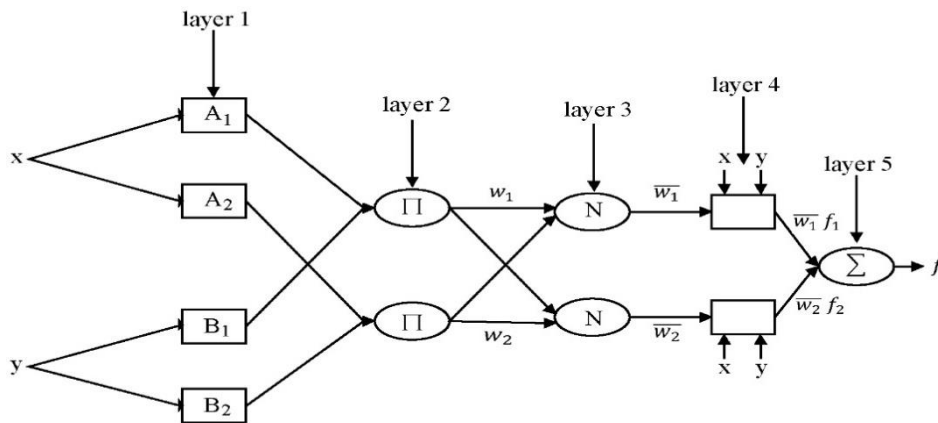
تغییر ( $CV^1$ ) هر یک از پارامترها نشان داده شده است.

#### ۴- پیش‌بینی ظرفیت برشی تیرهای بتن مسلح با استفاده از الگوریتم‌های SVR, PANFIS و GANFIS

##### ۴-۱- رگرسیون بردار پشتیبان (SVR)

رگرسیون بردار پشتیبان یکی از الگوریتم‌های یادگیری ماشین می‌باشد؛ که بر اساس تئوری آموزش آماری استوار است. این الگوریتم یکی از الگوریتم‌های آموزش نظارت شده می‌باشد و بین داده‌های ورودی و مقدار پارامتر وابسته، براساس کمینه‌سازی ریسک ساختاری

1 Coefficient of Variation



شکل ۲. ساختار سیستم استنتاج تطبیقی عصبی-فازی (ANFIS)  
 Fig. 2. Structure of the Neuro-Fuzzy Adaptive Inference System (ANFIS)

ویژگی ابعاد بالا بوده و  $b$  نیز به عنوان بایاس<sup>۲</sup> تعریف می شود. برای مسأله رگرسیون، تابع  $R$  با استفاده از بهینه سازی محدود مطابق با رابطه (۱۰) تعریف گردیده است.

$$\text{Minimize : } R(\omega, \varepsilon, b) = \frac{1}{2} \omega^2 + c \sum_{i=1}^n \varepsilon_i^2 \quad (10)$$

$$\text{Subjected to : } y_i = \omega^T \varphi(x_i) + b + \varepsilon_i, \quad i = 1, \dots, n$$

#### ۲-۴- مدل استنتاج تطبیقی فازی-عصبی (ANFIS)

سیستم استنتاج فازی (FIS<sup>۳</sup>) به عنوان یک نگاشت غیر خطی از فضای ورودی به فضای خروجی معرفی می گردد. سازوکار نگاشت براساس تبدیل پارامترهای ورودی از حوزه عددی به حوزه فازی با استفاده از سه مؤلفه عملکردی می باشد که عبارتند از: یک پایگاه قانون ها که شامل انتخاب قوانین فازی است؛ یک پایگاه داده که توابع عضویت (MFs<sup>۴</sup>) مورد استفاده در قوانین فازی را تعریف می کند و یک مکانیزم استدلال که روش استنباط را براساس قوانین برای به دست آوردن یک خروجی انجام می دهد. الگوریتم انفیس در چارچوب شبکه های تطبیقی به کار گرفته می شود. هر قانون در ساختار ANFIS را می توان به شکل زیر تعریف کرد:

$$\text{IF } x_1 \text{ is } A_{1,j} \text{ AND } x_2 \text{ is } A_{2,j} \text{ AND } \dots \text{ AND } x_n \text{ is } A_{n,j} \quad (11)$$

$$\text{Then } y = c_0 + c_1 x_1 + \dots + c_n x_n$$

ابعاد زیاد، از یک تابع کرنل<sup>۱</sup> استفاده می شود. در این صورت عملیات می تواند با همان سرعت فضای داده های ورودی انجام شود. در واقع با استفاده از تابع کرنل، مشکل چند بعدی و غیرخطی بودن نگاشت، رفع می شود. فرآیند بهینه سازی بایستی با یک تابع افت اصلاح شده همراه گردد؛ تا بتواند سنجش فاصله را در بر گیرد. در حقیقت هدف SVR، تخمین پارامترهای وزن ها و اریب تابعی است که از بهترین انطباق با داده ها برخوردار باشد [۳۸]. تابع SVR می تواند خطی و یا غیر خطی باشد. در حالت غیرخطی، محاسبه تابع رگرسیون در یک فضای ویژه با ابعاد بالا صورت می گیرد؛ به طوری که داده های ورودی از طریق یک تابع غیرخطی، نگاشت می شوند. هدف SVR این است که تابع  $f(x)$  را برای الگوهای آموزشی  $x$  طوری تشخیص دهد که بیشینه حاشیه را از مقادیر آموزشی  $\varepsilon$  داشته باشد. به عبارت دیگر SVR مدلی است که منحنی با فاصله  $\varepsilon$  را به داده ها برازش می دهد؛ به نحوی که کمترین خطا در داده های آزمون صورت گیرد. برای کمینه کردن خطای آزمون باید عبارت پیچیدگی حداقل شود که مستلزم کمینه سازی نرم بردار وزن است. این شرایط می تواند به راحتی برای SVR با حاشیه نرم گسترش داده شود [۳۹]. رابطه (۹) نشان دهنده عملکرد تصمیم SVR می باشد:

$$y(x) = \omega^T \varphi(x) + b \quad (9)$$

که  $\varphi(x): R^n \rightarrow R^{nh}$  و  $x \in R^n, y \in R$  نگاشت فضای

2 Bias  
 3 Fuzzy Inference System  
 4 Membership Functions

1 Kernal

جدول ۲. مقادیر میانگین، انحراف معیار و ضریب تغییرات  $\lambda$

Table 2. Mean, standard deviation and coefficient of variation  $\lambda$  values

پارامتر ورودی	Ave	CV	SD
a/d	۰/۷۸۷	۰/۱۹۵	۰/۱۵۳
b <sub>w</sub>	۰/۴۶۶	۰/۰۷۴	۰/۰۳۴
d	۰/۴۳۰	۰/۱۲۴	۰/۰۵۳
f' <sub>c</sub>	۰/۴۴۵	۰/۱۴۸	۰/۰۶۶
f <sub>y1</sub> (MPa)	۰/۴۸۸	۰/۱۹۹	۰/۰۹۷
f <sub>y2</sub> (MPa)	۰/۶۱۵	۰/۲۱۵	۰/۱۳۲
L/d	۰/۶۲۵	۰/۱۸۱	۰/۱۱۳
$\rho_l$ (%)	۰/۹۱۸	۰/۲۲۳	۰/۲۰۵
$\rho_t$ (%)	۰/۴۱۰	۰/۲۰۹	۰/۰۸۵

$$Q_{1,i} = \mu A_i(x). \quad \text{for } i=1,2 \quad Q_i \quad B \quad x \quad \text{for } i \quad (12)$$

$$Q_{1,i} = \mu B_i(x). \quad \text{for } i=3,4$$

که  $Q_{1,i}$  ضرورتاً درجه عضویتی برای  $y \in x$  است. لایه دوم، لایه قوانین می باشد. همه گره ها در این لایه ثابت می باشد. این لایه قدرت هر قاعده را با استفاده از ضرب جبری، به صورت رابطه (۱۳) ارائه می کند:

$$w_i = \mu A_i(x) \cdot \mu B_i(y) = 1,2 \quad (13)$$

در این لایه هر گره از حاصل ضرب مقادیر ورودی در لایه قبلی، بدست می آید. ارزش بدست آمده نشان دهنده ی قدرت اجرایی  $\lambda$ امین قاعده، جایی که متغیر  $x_j$  ارزش زبان شناختی  $A_j$  را دارد، می باشد. لایه سوم، لایه نرمال سازی بوده که در این لایه، قدرت قاعده، با استفاده از رابطه (۱۴) نرمال سازی می شود:

$$\bar{w}_i = \frac{w_i}{\sum w_i} = 1,2 \quad (14)$$

که در این رابطه  $w_i$  قدرت اجرایی  $\lambda$ امین قاعده می باشد. در لایه چهارم که لایه انطباقی می باشد، هر گره یک تابع خطی است و ضرایب این تابع از طریق ترکیبی از تقریب حداقل مربعات و پس انتشار تعدیل می شود. در لایه پنجم که لایه خروجی می باشد، نتایج به عنوان مجموعی از خروجی گره های لایه ی قبلی بدست آمده است.

در رابطه (۱۱)،  $A_{i,j}$   $\lambda$ امین عبارت زبان شناختی  $\lambda$ امین متغیر ورودی  $x_i$  است.  $n$  تعداد ورودی ها،  $y$  خروجی مدل و  $c_i$  پارامترهای نتیجه که در فرآیند آموزش تعیین شده اند، می باشند. از آن جایی که هر قانون، یک خروجی قطعی دارد، خروجی کلی از طریق میانگین وزنی بدست می آید. در ساختار ANFIS نوع سوگنوا، لایه های متوالی برای وظایف مختلفی همانند ایجاد یک فرآیند تصفیه ی تدریجی مدل اختصاص می یابند. فرآیند یادگیری از یک فرآیند جلوگذر و یک فرآیند عقب گذر، تشکیل شده است [۴۰]. در خلال فرآیند جلوگذر، پارامترهای اولیه ثابت بوده و پارامترهای نتیجه با استفاده از الگوریتم حداقل مربعات، بهینه سازی می شوند. فرآیند عقب گذر برای تعدیل پارامترهای اولیه توابع عضویت برای متغیرهای ورودی، از الگوریتم گرادیان نزولی استفاده می کند. خروجی به عنوان یک میانگین وزنی پارامترهای نتیجه، محاسبه می شود. هر خطای خروجی برای تعدیل پارامترهای مقدم، از الگوریتم های پس انتشار استفاده می کند [۴۰]. در شکل ۲ ساختار سیستم ANFIS نشان داده شده است. در این سیستم گره های دایره ای، نشان دهنده ی گره های ثابت بوده و گره های مربعی بیانگر گره های انطباقی که توان یادگیری دارند، می باشند. مشاهده می شود که این سیستم از ۵ لایه تشکیل شده است. لایه اول، لایه ی ورودی و خروجی توابع عضویت بوده و خروجی هر گره در رابطه (۱۲) نشان داده شده است:

جدول ۳. پارامترهای مربوط به الگوریتم PSO  
Table 3. The parameters related to PSO algorithm

۴۰	میزان جمعیت <sup>۱</sup>
۱۰۰۰	حداکثر تعداد تکرارها <sup>۲</sup>
۱	وزن ایده‌آل <sup>۳</sup>
۰/۹۹	نسبت شیب به وزن ایده‌آل <sup>۴</sup>
۱	ضریب یادگیری خصوصی <sup>۵</sup>
۲	ضریب یادگیری عمومی <sup>۶</sup>

- <sup>۱</sup> Population Size  
<sup>۲</sup> Maximum Number of Iterations  
<sup>۳</sup> Inertia Weight  
<sup>۴</sup> Inertia Weight Damping Ratio  
<sup>۵</sup> Personal Learning Coefficient  
<sup>۶</sup> Global Learning Coefficient

بدین ترتیب سرعت هر ذره، طبق رابطه‌ی (۱۵) تغییر می‌کند:

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_1 (pbes_{ij}(t) - x_{ij}(t)) + c_2 r_2 (gbest(t) - x_{ij}(t)) \quad (15)$$

که در آن  $v_{ij}$ ، بعد از  $t$  ام مربوط به ذره  $i$  در تکرار  $t$  ام است.  $\omega$ ، وزن اینرسی،  $c_1$  و  $c_2$  فاکتور وزنی،  $r_1$  و  $r_2$  عددی تصادفی بین ۰ و ۱،  $pbes_{ij}(t)$  موقعیت بعد از  $t$  ام مربوط به ذره  $i$  در تکرار  $t$  ام،  $gbest$  برابر  $pbest$  ذره در زمان  $t$  ام و  $gbest$  نیز  $gbest$  ذره در زمان  $t$  ام می‌باشد. موقعیت جدید هر ذره، به وسیله‌ی مجموع موقعیت گذشته و سرعت جدید، با استفاده از رابطه‌های (۱۶) و (۱۷) تعیین می‌شود:

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (16)$$

$$v_{ij}(t+1) = \text{sign}(v_{ij}(t)) \min(|v_{ij}(t)|, v_{max}) \quad (17)$$

در جدول ۳ مقادیر پارامترهای الگوریتم فرا ابتکاری PSO آورده شده است. با توجه به ترکیب الگوریتم PSO با الگوریتم انفیس جهت بهینه‌سازی پارامترهای پیشین و پسین، پارامترهای زیر بر اساس یک فرآیند سعی و خطا انتخاب شده‌اند.

#### ۳-۴- الگوریتم بهینه‌سازی انبوه ذرات (PSO)

الگوریتم بهینه‌سازی انبوه ذرات یکی از مهم‌ترین الگوریتم‌هایی است که در حوزه‌ی هوش جمعی جای می‌گیرد. این الگوریتم، توسط کندی<sup>۱</sup> و همکاران در سال ۱۹۹۵ معرفی و با الهام از رفتار اجتماعی حیواناتی چون ماهی‌ها و پرندگان که در گروه‌های کوچک و بزرگ در کنار یکدیگر زندگی می‌کنند، طراحی شده است [۴۱]. اساس کار الگوریتم PSO بر این استوار است که در هر لحظه، هر ذره مکان خود را در فضای جستجو با توجه به بهترین مکانی که تاکنون در آن قرار گرفته است و بهترین مکانی که در کل همسایگی‌های آن وجود دارد، تنظیم می‌کند [۴۲]. در این الگوریتم فرض می‌شود در یک فضای  $D$  بعدی،  $t$  امین ذره از جمعیت می‌تواند با یک بردار سرعت و یک بردار موقعیت نمایش داده شود. تغییر موقعیت ذرات، با تغییر در ساختار موقعیت و سرعت قبلی امکان‌پذیر است. هر ذره امکاناتی شامل بهترین مقداری را که تاکنون به آن رسیده است ( $pbest$ ) و موقعیت  $x_i$  را شامل می‌شود. این اطلاعات از مقایسه‌ی تلاش‌هایی که هر ذره برای یافتن بهترین جواب انجام می‌دهد، به دست می‌آید. همچنین هر ذره بهترین جوابی را که تاکنون (در گروه) از مقدار  $pbest$  به دست آمده است را به عنوان  $gbest$  ذخیره می‌نماید. هر ذره برای رسیدن به بهترین جواب سعی می‌کند موقعیت خود را با استفاده از اطلاعات زیر تغییر دهد: موقعیت کنونی  $x_i$ ، سرعت کنونی  $v_i$ ، بهترین موقعیت کنونی ذره  $pbest$ ، و بهترین موقعیت کلی  $gbest$ .

1 Particle Swarm Optimization  
2 Kennedy

جدول ۴. پارامترهای مربوط به الگوریتم GA  
Table 4. The parameters related to GA algorithm

میزان جمعیت <sup>۷</sup>	۱۰۰
حداکثر تعداد تکرارها <sup>۸</sup>	۵۰۰
درصد تقاطع <sup>۹</sup>	۰/۵
درصد تناوب <sup>۱۰</sup>	۰/۷
نرخ جهش <sup>۱۱</sup>	۰/۱
فشار انتخاب <sup>۱۲</sup>	۸
گاما ( $\gamma$ )	۰/۲

<sup>۱</sup> Population Size

<sup>۲</sup> Maximum Number of Iterations

<sup>۳</sup> Mutation Percentage

<sup>۴</sup> Crossover Percentage

<sup>۵</sup> Mutation Rate

<sup>۶</sup> Selection Pressure

#### ۴-۴- الگوریتم ژنتیک (GA)

توجه به ترکیب الگوریتم GA با الگوریتم انفیس جهت بهینه‌سازی پارامترهای پیشین و پسین، پارامترهای زیر بر اساس یک فرآیند سعی و خطا انتخاب شده‌اند.

الگوریتم ANFIS از امتیازهای مربوط به شبکه عصبی و سیستم‌های فازی بصورت همزمان استفاده می‌نماید. آموزش داده‌ها در این الگوریتم، به عنوان چالش اصلی مطرح است. بنابراین، استفاده از الگوریتم‌های فرا ابتکاری با طبیعت جستجوی تصادفی می‌تواند به عنوان الگوریتم‌های جایگزین و مفید مورد توجه قرار گیرد. برای حل مشکل بهینه‌سازی با استفاده از الگوریتم‌های PSO و GA، وزن حاصل از پارامترهای پیشین فازی و پارامترهای خطی مانند  $C_i$  از طریق الگوریتم‌های فرا ابتکاری تنظیم می‌شوند. این مطالعه براساس ترکیبی از سیستم فازی عصبی (ANFIS) با الگوریتم‌های بهینه‌سازی انبوه ذرات (PSO) و الگوریتم ژنتیک (GA) استوار است. این الگوریتم‌ها برای افزایش دقت الگوریتم ANFIS در رویکردی ترکیبی و برای بهینه‌سازی و تنظیم مقادیر پارامترهای ورودی و خروجی الگوریتم ANFIS استفاده می‌شوند.

#### ۵- ارزیابی الگوریتم‌های پیش بینی

همان‌طور که بیان شد یکی از اهداف این مطالعه بهره‌گیری از الگوریتم‌های SVR، PANFIS و GANFIS جهت پیش بینی ظرفیت برشی تیرهای بتن مسلح می‌باشد. در این بخش به ارزیابی نتایج حاصل از این پیش بینی پرداخته می‌شود.

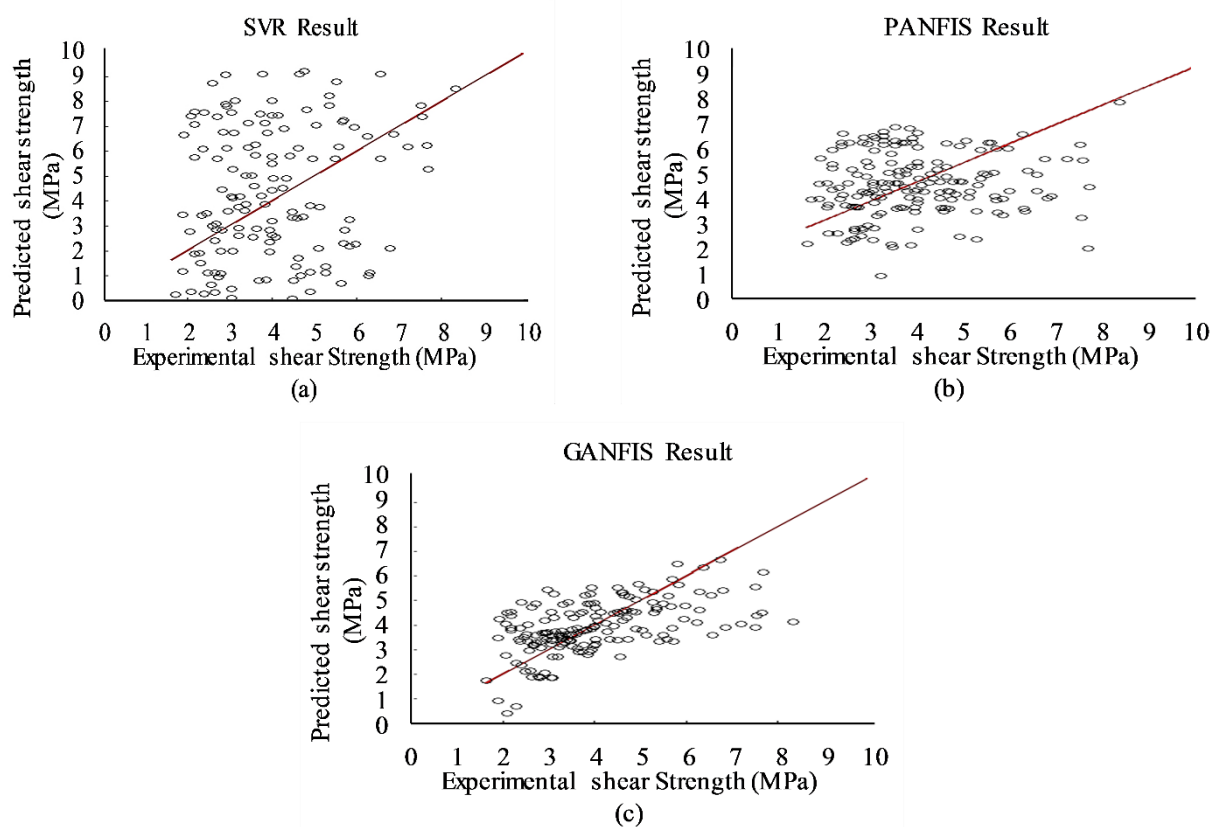
الگوریتم ژنتیک یکی از اولین الگوریتم‌های تکاملی است که ابتدا توسط هالند<sup>۲</sup> در سال ۱۹۷۵ ارائه شده است و بر اساس فرآیند ژنتیکی موجودات زنده تعریف می‌شود [۴۳]. این الگوریتم یک الگوریتم جستجوی ابتکاری انطباق‌پذیر است که بر مبنای ایده‌های تکاملی انتخاب طبیعی و ژنتیک طراحی شده است [۴۴]. به این ترتیب، الگوریتم ژنتیک نمایانگر انتخاب هوشمند از یک الگوریتم جستجوی تصادفی برای حل مسائل بهینه‌سازی می‌باشد. گرچه الگوریتم‌های ژنتیک از پدیده‌هایی تصادفی استفاده می‌کنند، اما خود به هیچ وجه تصادفی نیستند؛ بلکه از اطلاعات تاریخی موجود جهت هدایت عملیات جستجو به منطقه‌ای با عملکردی بهتر در فضای جستجو استفاده می‌نمایند. روش‌های اصلی در الگوریتم ژنتیک به گونه‌ای طراحی شده است که بتوانند فرآیندهای ضروری برای تکامل در سیستم‌های طبیعی را شبیه‌سازی نمایند. الگوریتم‌های ژنتیک برای حل مسائل، اصل بقای اصلح را در میان اعضای یک جمعیت در طی نسل‌های متوالی شبیه‌سازی می‌کنند. هر نسل شامل جمعیتی از یک رشته کاراکترها می‌باشد که مشابه کروموزوم‌هایی که در DNA دیده می‌شوند، عمل می‌کنند. هر فرد، نمایانگر یک نقطه در فضای جستجو و یک راه حل احتمالی خواهد بود. همچنین اعضای هر نسل، در فرآیندی مشابه فرآیند تکامل موجودات زنده وارد می‌شوند. جدول ۴ مقادیر پارامترهای الگوریتم فرا ابتکاری GA را نشان می‌دهد. با

1 Genetic Algorithm

2 Holland

جدول ۵. مقایسه نتایج بدست آمده با استفاده از الگوریتم‌های SVR، PANFIS، GANFIS، ANN و آیین‌نامه‌های ۲-۳۱۸-ACI و CSA  
 Table 5. Comparison of the results obtained using SVR, PANFIS, GANFIS, ANN algorithms and ACI318-02 and CSA codes

روش	مرجع	RMSE	R <sup>2</sup>
SVR	مطالعه حاضر	۰/۰۹۹۴	۰/۹۲۵
PANFIS	مطالعه حاضر	۰/۰۷۵۴۱	۰/۹۸۶
GANFIS	مطالعه حاضر	۰/۰۶۶۳۴	۰/۹۹۶
ACI	[۶]	۰/۱۴	۰/۸۷
CSA	[۶]	۰/۱۱۴	۰/۸۲
ANN	[۶]	۰/۰۹۷	۰/۹۶

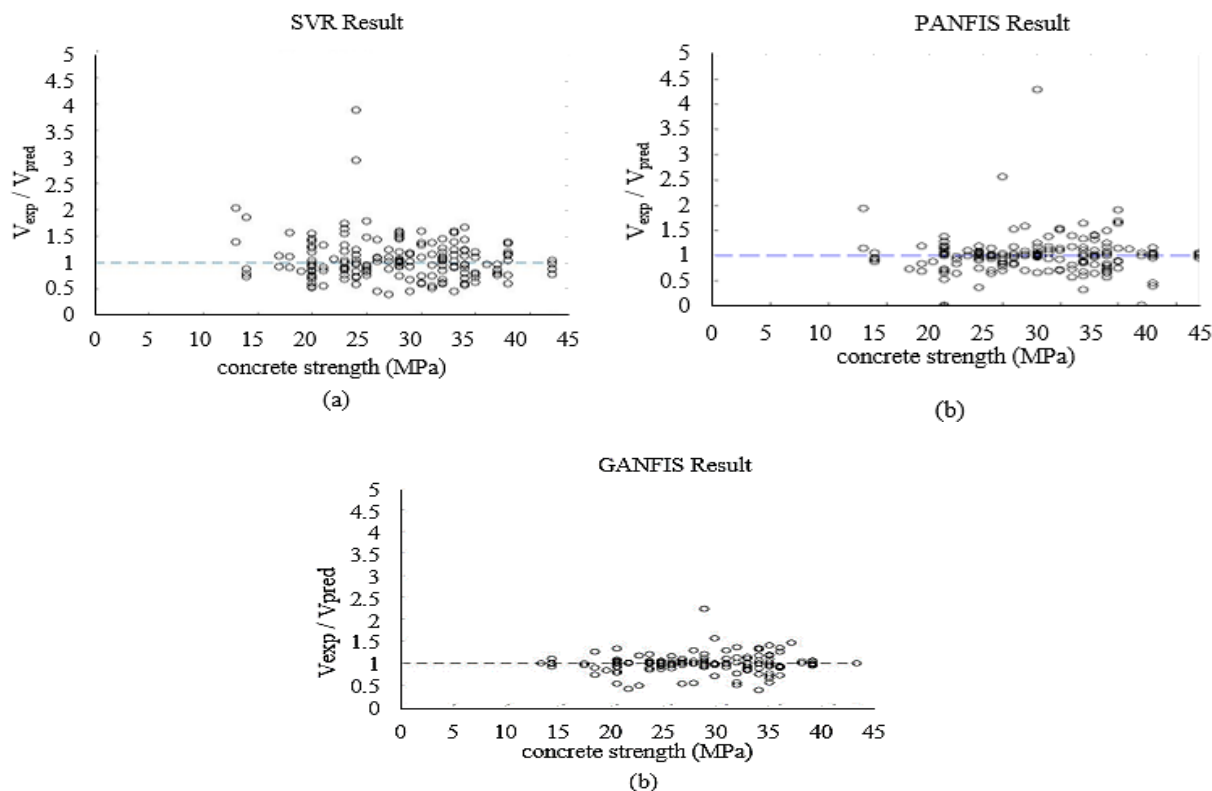


شکل ۳. نمودار نسبت ظرفیت برشی تجربی به پیش‌بینی شده. (a) الگوریتم SVR، (b) الگوریتم PANFIS و (c) الگوریتم GANFIS  
 Fig. ۳. Experimental to predicted shear capacity ratio diagram for: (a) SVR algorithm, (b) PANFIS algorithm, and (c) GANFIS algorithm

می‌شود و همه داده‌ها دقیقاً یک بار برای آموزش و یک بار برای اعتبارسنجی به کار می‌روند. در نهایت میانگین نتیجه این K بار اعتبارسنجی به عنوان یک تخمین نهایی برگزیده می‌شود. در این مطالعه، مجموعه داده‌ها با استفاده از اعتبارسنجی متقاطع k-fold (k=۱۰) بصورت تصادفی برای آموزش و تست تقسیم شده است. در مجموع ۱۵۷ داده به صورت تصادفی به عنوان بخش آموزشی انتخاب

#### ۵-۱- روش اعتبارسنجی

پس از نرمال‌سازی داده‌ها باید میزان داده‌های آموزشی و تستی مدل را تعیین نمود. برای این منظور از روش اعتبارسنجی Kfold استفاده شده است. در این نوع اعتبارسنجی داده‌ها به K زیرمجموعه افزایش می‌شوند. از این K زیرمجموعه، هر بار یکی برای اعتبارسنجی و K-1 عدد دیگر برای آموزش به کار می‌روند. این روال K بار تکرار



شکل ۴. رابطه مقاومت فشاری بتن با نسبت ظرفیت برشی تجربی به پیشبینی شده (a) الگوریتم SVR، (b) الگوریتم PANFIS و (c) الگوریتم GANFIS

Fig. ۴. Experimental to predicted shear capacity versus concrete compressive strength diagram for: (a) SVR algorithm, (b) PANFIS algorithm, and (c) GANFIS algorithm

GANFIS در پیش بینی میزان ظرفیت برشی تیرهای بتن مسلح، خطای مربع میانگین ریشه ( $RMSE^1$ ) و ضریب تعیین  $R^2$  برای الگوریتم های مورد مطالعه، محاسبه می شوند. روابط مربوط به این دو پارامتر مطابق با روابط (۱۸) و (۱۹) می باشد [۴۵].

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (18)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (P_i - P_m)(O_i - O_m)}{\sqrt{(\sum_{i=1}^N (P_i - P_m)^2)(\sum_{i=1}^N (O_i - O_m)^2)}} \quad (19)$$


که  $O_i$  مقدار اندازه گیری شده،  $P_i$  مقدار پیش بینی شده،  $P_m$  مقدار متوسط پیش بینی ها،  $O_m$  مقدار متوسط برای مشاهدات،  $N$  نیز تعداد نمونه های مورد بررسی می باشد که در این مطالعه برابر با ۱۷۵ نمونه متفاوت است.

و مابقی داده ها برای تست استفاده شدند. بخش آموزش نیز به دو مجموعه زیر داده تقسیم می شود. مجموعه آموزش در درجه اول متناسب سازی مدل استفاده می گردد. مجموعه اعتبارسنجی جهت اعتبارسنجی عملکرد آموزش قبلی و تنظیم دقیق مدل آموزش دیده استفاده می شود. در این مطالعه، از ۸۷٪ داده ها به عنوان نسبت زیر مجموعه آموزش و ۱۳٪ برای زیر مجموعه اعتبارسنجی استفاده شده است. با استفاده از رویکرد اعتبارسنجی متقابل، داده های آموزش بصورت تصادفی به ده زیرمجموعه متقابل منحصر به فرد گروه بندی شدند. در هر تکرار، یک زیر مجموعه برای فرآیند اعتبارسنجی استفاده گردید، در حالی که نه زیرمجموعه دیگر به نوبه ی خود برای فرآیند آموزش استفاده شدند. به این ترتیب، این مطالعه اطمینان حاصل می نماید که هر مجموعه داده حداقل یک بار در هر دو مرحله آموزش و تست استفاده می شود.

#### ۵-۲- تجزیه و تحلیل نتایج

جهت ارزیابی عملکرد الگوریتم های SVR، PANFIS و

1 Root Mean Square Error



شکل ۵. رابطه درصد آرماتورهای طولی با نسبت ظرفیت برشی آزمایشگاهی به پیشبینی شده (a) الگوریتم SVR، (b) الگوریتم PANFIS و (c) الگوریتم GANFIS

Fig. 5. Experimental to predicted shear capacity versus percentage of longitudinal reinforcement diagram for: (a) SVR algorithm, (b) PANFIS algorithm, and (c) GANFIS algorithm

طولی،  $V_u$  و  $M_u$  برش و گشتاور در مقطع بحرانی می باشند. برای تیرهایی که دارای آرماتور برشی باشند، این آیین نامه مقاومت برشی را متشکل از سهم برش بتن و سهم آرماتور برشی تعریف می کند. ACI بیان می کند که سهم برشی بتن و سهم آرماتور برشی نباید بیش از  $0.3\sqrt{f'_c}$  و  $0.66\sqrt{f'_c}$  در نظر گرفته شوند. در آیین نامه ساختمانی CSA دو رابطه برای سهم برشی بتن بسته به میزان آرماتور برشی و عمق مؤثر تیر تعریف شده است که طبق رابطه (۲۱) بیان می شود:

$$v_c = \begin{cases} 0.2\sqrt{f'_c} & \text{if } A_v \geq \frac{0.06\sqrt{f'_c} b_w s}{f_{yv}} \text{ or } d \leq 300 \text{ mm} \\ \left(\frac{260}{100+d}\right)\sqrt{f'_c} \geq 0.1\sqrt{f'_c} & \text{if } A_v \geq \frac{0.06\sqrt{f'_c} b_w s}{f_{yv}} \text{ and } d \leq 300 \text{ mm} \end{cases} \quad (21)$$

خطای مربع میانگین ریشه ( $RMSE$ ) و ضریب تعیین  $R^2$  برای ۱۷۵ نمونه تیر بتن مسلح حاصل از الگوریتم‌های SVR، PANFIS،


۳-۵- مقایسه نتایج الگوریتم‌های SVR، PANFIS و GANFIS با نتایج بدست آمده از فرمول‌های آیین‌نامه‌های 02-318 ACI و CSA

در این بخش به مقایسه نتایج حاصل از پیش بینی صورت گرفته با استفاده از الگوریتم‌های SVR، PANFIS و GANFIS با ظرفیت برشی تعریف شده در آیین نامه‌های ساختمانی ACI [۴۶] و CSA [۴۷] پرداخته می شود. در آیین نامه ساختمانی ACI، رابطه (۲۰) مربوط به محاسبه ظرفیت برشی در تیرهای بدون آرماتور برشی می‌باشد که عبارت است از:

$$v_c = V_c/b_w d = \left(0.16\sqrt{f'_c} + 17.2\rho_w \frac{V_u d}{M_u}\right) \quad (20)$$

که در این رابطه  $b_w$  عرض تیر،  $d$  عمق مؤثر تیر،  $f'_c$  مقاومت فشاری بتن نمونه استوانه‌ای  $15 \times 30$  آمریکا،  $\rho_w$  نسبت آرماتور کشش






شکل ۶. رابطه درصد آرماتورهای برشی با نسبت ظرفیت برشی آزمایشگاهی به پیشبینی شده (a) الگوریتم SVR، (b) الگوریتم PANFIS و (c) الگوریتم GANFIS

Fig. 6. Experimental to predicted shear capacity versus percentage of shear reinforcement diagram for: (a) SVR algorithm, (b) PANFIS algorithm, and (c) GANFIS algorithm

انتظار می رود، در نمودار نیز مشاهده می شود که عملکرد الگوریتم GANFIS نسبت به سایر الگوریتم های بهتر بوده است. مقادیر ظرفیت برشی پیش بینی شده بدست آمده از الگوریتم های مورد بررسی SVR، PANFIS و GANFIS بر حسب ظرفیت برشی بدست آمده از نتایج آزمایشگاهی به ترتیب در شکل های ۳ (a-c) نشان داده شده است. نتایج نشان می دهد که ظرفیت برشی پیش بینی شده با استفاده از الگوریتم GANFIS با ظرفیت برشی بدست آمده از نتایج آزمایشگاهی دارای تطابق بسیار خوبی می باشد. همچنین با نظر گرفتن تمامی پارامترهای ورودی، الگوریتم GANFIS با ریشه دوم میانگین مربعات خطا  $RMSE = 0.06634$  و ضریب تعیین  $R^2 = 0.996$  دارای بالاترین دقت برای پیش بینی میزان ظرفیت برشی در تیرهای بتن مسلح در بین همه الگوریتم های مورد استفاده در این مطالعه می باشد. در ادامه به بررسی تأثیر هر یک از پارامترهای ورودی پرداخته شده است. در شکل ۴ میزان تأثیر مقاومت فشاری بتن بر

ANN، GANFIS، آیین نامه ACI-318-02 و CSA در جدول ۵ ارائه شده است. مقایسه نتایج ارائه شده در این جدول نشان می دهد که کارایی و دقت الگوریتم های پیشنهادی در مطالعه حاضر برای پیش بینی ظرفیت برشی تیرهای بتن مسلح، بیشتر از فرمول های آیین نامه ای می باشد. همچنین نتایج نشان می دهد که الگوریتم GANFIS پارامتر مقاومت برشی تیر بتن مسلح را با دقت بسیار بالاتری در مقایسه با سایر الگوریتم های توسعه یافته پیش بینی می کند.

در شکل ۳ نمودار مربوط به نسبت مقدار داده های آزمایشگاهی و داده های پیش بینی شده با الگوریتم های SVR، PANFIS و GANFIS نشان داده شده است. محور افقی بیانگر داده های آزمایشگاهی و محور عمودی مقدار داده های پیش بینی شده را نشان می دهد. لذا هرچه پراکندگی داده ها در اطراف خط  $X=Y$  کم تر باشد، میزان خطای پیش بینی کم تر بوده و عملکرد سیستم بهتر می باشد. همان طور که از میزان خطای  $RMSE$  سه الگوریتم نیز



شکل ۷. رابطه  $a/d$  با نسبت ظرفیت برشی آزمایشگاهی به پیشبینی شده (الف) الگوریتم SVR، (ب) الگوریتم PANFIS و (ج) الگوریتم GANFIS  
**Fig. 7. Experimental to predicted shear capacity versus  $a/d$  ratio diagram for: (a) SVR algorithm, (b) PANFIS algorithm, and (c) GANFIS algorithm**

ترتیب در شکل‌های ۵ (c-a) نشان داده شده است. مقایسه عملکرد سه الگوریتم نشان می‌دهد که میزان تجمع داده‌ها بر محور  $y=1$  در الگوریتم GANFIS نسبت به سایر الگوریتم‌ها بیشتر می‌باشد. بطور مشابه در شکل ۶ میزان تأثیر درصد آرماتورهای برشی نسبت به ظرفیت برشی مورد بررسی قرار گرفته است. برای این منظور محور افقی مقدار درصد آرماتورهای برشی در هر آزمایش و محور عمودی نسبت مقدار آزمایشگاهی بر مقدار پیش‌بینی شده ظرفیت برشی را نشان می‌دهد. رابطه درصد آرماتورهای برشی با نسبت ظرفیت برشی آزمایشگاهی به پیش‌بینی شده برای الگوریتم‌های SVR، PANFIS و GANFIS به ترتیب در شکل‌های ۶ (c-a) نشان داده شده است. مشاهده می‌شود که در این نمودار نیز عملکرد GANFIS نسبت به سایر الگوریتم‌ها بهتر بوده است. آخرین پارامتر بررسی شده، نسبت دهانه برش به عمق مؤثر ( $a/d$ ) می‌باشد. نمودار مربوط به این پارامتر در شکل ۷ نشان داده شده است. رابطه  $a/d$  با نسبت ظرفیت برشی آزمایشگاهی به پیش‌بینی شده برای الگوریتم‌های SVR، PANFIS و GANFIS به ترتیب در

نسبت ظرفیت برشی مورد بررسی قرار گرفته است. برای این منظور محور افقی مقدار مقاومت فشاری بتن در هر آزمایش و محور عمودی نسبت مقدار آزمایشگاهی به مقدار پیش‌بینی شده ظرفیت برشی را نشان می‌دهد. بدیهی است که هرچه این نسبت به ۱ نزدیک‌تر باشد، عملکرد سیستم پیش‌بینی بهتر بوده است. رابطه مقاومت فشاری بتن با نسبت ظرفیت برشی آزمایشگاهی به پیش‌بینی شده برای الگوریتم‌های SVR، PANFIS و GANFIS به ترتیب در شکل‌های ۴ (c-a) نشان داده شده است. مقایسه عملکرد سه الگوریتم نشان می‌دهد که میزان تجمع داده‌ها بر محور  $y=1$  در الگوریتم GANFIS نسبت به سایر الگوریتم‌ها بیشتر می‌باشد.

شکل ۵ میزان تأثیر درصد آرماتورهای طولی نسبت به ظرفیت برشی نشان می‌دهد. برای این منظور، محور افقی مقدار درصد آرماتورهای طولی در هر آزمایش و محور عمودی نسبت مقدار آزمایشگاهی به مقدار پیش‌بینی شده ظرفیت برشی را نشان می‌دهد. رابطه درصد آرماتورهای طولی با نسبت ظرفیت برشی آزمایشگاهی به پیش‌بینی شده برای الگوریتم‌های SVR، PANFIS و GANFIS به

- [3] I.M. Boyan, C.B. Evan, P.C. Michael, Two-parameter kinematic theory for shear behavior of beep beams, *ACI Structural Journal*, 3(110), (2013), 456-447.
- [4] F. Danglade, J.P. Pernot, P. Ve'ron, L. Fine, A priori evaluation of simulation models preparation processes using artificial intelligence techniques, *Computers in Industry*, 91, (2017), 61-45.
- [5] H.G. Ni, J.Z. Wang, Prediction of compressive strength of concrete by neural networks, *Cement and Concrete Research*, 8(30), (2000), 1250-1245.
- [6] M.Y. Mansour, M. Dicleli, J.Y. Lee, J. Zhang, Predicting the shear strength of reinforced concrete beams using artificial neural networks, *Engineering Structures*, 6(26), (2004), 799-781.
- [7] A. Toghroli, M. Mohammadhassani, M. Suhatri, M. Shariati, Z. Ibrahim, Prediction of shear capacity of channel shear connectors using the ANFIS model, *Steel and Composite Structures*, 5(17), (2014), 639-623.
- [8] Mansouri, M. Shariati, M. Safa, Z. Ibrahim, M.M. Tahir, D. Petković, Analysis of influential factors for predicting the shear strength of a V-shaped angle shear connector in composite beams using an adaptive neuro-fuzzy technique, *Journal of Intelligent Manufacturing*, 3(30), (2019), 1257-1247.
- [9] M. Safa, M. Shariati, Z. Ibrahim, A. Toghroli, S.B. Baharom, N.M. Nor, D. Petkovic, Potential of adaptive neuro fuzzy inference system for evaluating the factors affecting steel-concrete composite beam's shear strength, *Steel and Composite Structures*, 3(21), (2016), 688-679.
- [10] Y. Sedghi, Y. Zandi, A. Toghroli, M. Safa, E.T. Mohamad, M. Khorami, K. Wakil, Application of ANFIS technique on performance of C and L shaped angle shear connectors, *Smart Structures and Systems*, 3(22), (2018), 340-335.
- [11] D.V. Dao, H.B. Ly, S.H. Trinh, T.T. Le, B.T. Pham, Artificial intelligence approaches for prediction of compressive strength of geopolymers concrete. *Materials*, 6(12), (2019), 990-983.
- [12] M.A. Mashrei, M.M. Alaa, An Adaptive Neuro-Fuzzy Inference Model to Predict Punching Shear Strength of

شکل‌های (c-a) نشان داده شده است. مشاهده می‌شود که در این نمودار نیز عملکرد GANFIS در مقایسه با دو الگوریتم SVR و PANFIS بهتر بوده است.

## ۶- نتیجه گیری

مطالعه صورت گرفته در این تحقیق نشان می‌دهد که می‌توان از الگوریتم‌های هوش مصنوعی SVR، PANFIS و GANFIS جهت پیش‌بینی ظرفیت برشی نهایی تیرهای بتن مسلح استفاده نمود. برای این منظور در ابتدا پارامترهای مؤثر بر ظرفیت برشی مورد بررسی قرار گرفت و سپس این داده‌ها در هر یک از الگوریتم‌های SVR، PANFIS و GANFIS به طور جداگانه استفاده شد و میزان  $RMSE$  و ضریب تعیین  $R^2$  برای هر یک محاسبه گردید. این مطالعه نشان داد که الگوریتم ANFIS به همراه الگوریتم‌های بهینه‌سازی به عنوان یک ابزار محاسباتی قدرتمند مطرح بوده و می‌تواند به منظور تجزیه و تحلیل روابط پیچیده بین پارامترهای مختلف در پیش‌بینی مقاومت برشی تیرهای بتن مسلح مورد استفاده قرار گیرد. همچنین نتایج نشان می‌دهد که در مجموع الگوریتم GANFIS از قدرت پیش‌بینی به مراتب بهتر و قوی‌تری نسبت به الگوریتم‌های SVR، PANFIS، ANN، آیین‌نامه ACI-318-02 و آیین‌نامه CSA برخوردار است. در بخش دیگری از مطالعه به بررسی آنالیز حساسیت پارامترها با استفاده از تئوری GST پرداخته شد. نتایج بدست آمده از این آنالیز نشان می‌دهد که میانگین مقدار شاخص ارتباط بین ظرفیت برشی و پارامترهای مؤثر برای پارامتر درصد آرماتورهای طولی ( $\rho_l$ ) نسبت به سایر پارامترها بالاتر می‌باشد که این نشان‌دهنده تأثیرگذاری بیش‌تر این پارامتر بر روی ظرفیت برشی تیرهای بتن مسلح می‌باشد.

## مراجع

- [1] V.T. Babar, P.K. Joshi, D.N. Shinde, Shear strength of steel fiber reinforced concrete beam without stirrups, *International Journal of Advanced Engineering Technology*, 2(5), (2015), 18-15.
- [2] B.M. Adolfo, K.H. Wong, Design of simply supported deep beams using strut-and-tie models, *ACI Structural Journal*, 6(100), (2003), 712-704.

- [22] N.H. Guang, W.J. Zong, Prediction of compressive strength of concrete by neural network, *Cement and Concrete Research*, 8(30), (2000), 1250-1245.
- [23] S. Wild, J. Bai, J.A. Ware, B.B. Sabir, Using neural networks to predict workability of concrete incorporating metakaolin and fly ash, *Advances in Engineering Software*, 11(34), (2003), 669-663.
- [24] M. Khatibinia, M.R. Mohammadzadeh, Intelligent fuzzy inference system approach for modeling of debonding strength in FRP retrofitted masonry elements, *Structural Engineering and Mechanics*, 5(56), (2017), 796-787.
- [25] J.S Chou, A.D. Pham, Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength, *Construction and Building Materials*, 49, (2013), 563-554.
- [26] Z. MundherYaseen, M.T. Tran, S. Kim, T. Bakhshpoori, R.C. Deo, Shear strength prediction of steel reinforced concrete beam using hybrid intelligence models: A new approach, *Engineering Structures*, 177, (2013), 255-244.
- [27] B. Keshtegar, M. Bagheri, Z. Mundher Yaseen, Shear strength of steel fiber-unconfined reinforced concrete beam simulation: Application of novel intelligent model, *Composite Structures*, 212, (2019), 242-230.
- [28] F. Khademi, S.M. Jamal, N. Deshpande, S. Londhe, Predicting strength of recycled aggregate concrete using Artificial Neural Network, Adaptive Neuro-Fuzzy Inference System and Multiple Linear Regression, *International Journal of Sustainable Built Environment*, 2(5), (2016), 369-355.
- [29] M. Pal, S. Deswal, Support vector regression based shear strength modelling of deep beams, *Computers and Structures*, 13(89), (2011), 1439-1430.
- [30] J.S. Chou, N.T. Ngo, A.D. Pham, Shear strength prediction in reinforced concrete deep beams using nature-inspired metaheuristic support vector regression, *Journal of Computing in Civil Engineering*, 1(30), (2015), 115-107.
- [31] N.D. Hoang, X.L. Tran, H. Nguyen, Predicting ultimate bond strength of corroded reinforcement and surrounding concrete using a metaheuristic optimized Flat Concrete Slabs, *Journal of Applied Sciences*, 4(9), (2019), 829-809.
- [13] H. Naderpour, M. Mirrashid, Shear Strength Prediction of RC Beams Using Adaptive Neuro-Fuzzy Inference System, Sharif University of technology, (2018).
- [14] K.P.N Suguna, J.K. Raghunath, R.U. Maheswari, ANN based modeling for high strength concrete beams with surface mounted FRP laminates. *International Journal of Optimization in Civil Engineering*, (2019).
- [15] Z. Keshavarz, H. Torkian, Application of ANN and ANFIS models in determining compressive strength of concrete, *Journal of Soft Computing in Civil Engineering*, 1(2), (2018), 70-62.
- [16] V.R.A Saathappan, P.N. Raghunath, K. Suguna, Adaptive neuro-fuzzy model for performance evaluation of RC T-beams with externally bonded GFRP reinforcement, *Journal of Reinforced Plastics and Composites*, 24(30), (2011), 2023-2015.
- [17] E.M. Golafshani, A. Rahai, M.H. Sebt, H. Akbarpour, Prediction of bond strength of spliced steel bars in concrete using artificial neural network and fuzzy logic, *Construction and Building Materials*, 36, (2012), 411-418.
- [18] M.M. Alshihri, A.M. Azmy, M.S. El-Bisy, Neural networks for predicting compressive strength of structural light weight concrete, *Construction and Building Materials*, 6(23), (2009), 2219-2214.
- [19] F. Ozcan, C.D. Atis, O. Karahan, E. Uncuoglu, H. Tanyildizi, Comparison of artificial neural network and fuzzy logic models for prediction of long-term compressive strength of silica fume concrete, *Advances in Engineering Software*, 9(40), (2009), 863-856
- [20] L. Bal, F. Buyle-Bodin, Artificial neural network for predicting drying shrinkage of concrete, *Construction and Building Materials*, 38, (2013), 254-246.
- [21] J. Sobhani, M. Najimi, A.R. Pourkhorshidi, T. Parhizkar, Prediction of the compressive strength of no-slump concrete: a comparative study of regression, neural network and ANFIS models, *Construction and Building Materials*, 5(24), (2010), 718-709.

- V. Vapnik, Support vector regression machines”, In Advances in Neural Information Processing Systems, 7(28), (1997), 784-779.
- [40] J. Guan, J. Zurada, A. Levitan, An Adaptive Neuro fuzzy inference system based approach to real estate property assessment”, Journal of Real Estate Research, 4(30), (2008), 422-395.
- [41] J. Kennedy, R.C. Eberhart, Y. Shiny, Swarm intelligence, Morgan Kaufmann Publishers, (2011).
- [42] A.N. Hanoon, M.S. Jaafar, F. Hejazi, F.N.A. Abdul Aziz, Energy absorption evaluation of reinforced concrete beams under various loading rates based on particle swarm optimization technique, Engineering Optimization, 9(49), (2016), 1501-1483.
- [43] J.H. Holland, Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence, MIT press, (1992).
- [44] H. Garg, A hybrid GSA-GA algorithm for constrained optimization problems, Information Sciences, 478, (2018), 523-499.
- [45] T. Chai, R.R. Draxler, Root mean square error (RMSE) or mean absolute error (MAE)–arguments against avoiding RMSE in the literature, Geoscientific model development, 3(7), (2014), .1250-1247
- [46] American Concrete Institute (ACI), Committee 11-318: Building Code Requirements for Structural Concrete and Commentary, American Concrete Institute, (2011).
- [47] Canadian Standards Association (CSA), Design of concrete structures: Structures (design), A national standard of Canada. CAN-A94-23.3, Clause 11.1.2, Toronto, (1994).
- least squares support vector regression model, Neural Computing and Applications, (2019), 21-1.
- [32] L. Li, W. Zheng, Y. Wang, Prediction of Moment Redistribution in Statically Indeterminate Reinforced Concrete Structures Using Artificial Neural Network and Support Vector Regression”, Applied Sciences, 1(9), (2019), 51-28.
- [33] A. Gholampour, I. Mansouri, O. Kisi, T. Ozbakkaloglu, Evaluation of mechanical properties of concretes containing coarse recycled concrete aggregates using multivariate adaptive regression splines (MARS), M5 model tree (M5Tree), and least squares support vector regression (LSSVR) models, Neural Computing and Applications, (2018).
- [34] B.T. Pham, T.A. Hoang, D.M. Nguyen, D.T. Bui, Prediction of shear strength of soft soil using machine learning methods, Catena, 166, (2018), 191-181.
- [35] S.F. Liu, Y.J. Yang, J. Forrest, Grey Data Analysis: Methods, Models and Applications, Springer Singapore, (2017).
- [36] J.J. Xu, Z.P. Chen, T. Ozbakkaloglu, X.Y. Zhao, C. Demartino, A critical assessment of the compressive behavior of reinforced recycled aggregate concrete columns”, Engineering Structures, 161, (2018), 175-161.
- [37] S. Liu, H. Zhang, Y. Yang, Explanation of terms of grey incidence analysis models”, Grey Systems: Theory and Application, 1(7), (2017), 142-136.
- [38] H. Yu, S. Kim, SVM tutorial: classification, regression, and ranking”, Handbook of Natural Computing, Springer Berlin Heidelberg, (2012), 506-479.
- [39] H. Drucker, C.J. Burges, L. Kaufman, A.J. Smola,

چگونه به این مقاله ارجاع دهیم

F. Esfandnia, M.R. Mohammdzadeh, Prediction of Shear Capacity of Reinforced Concrete Beams using Support Vector Regression and Adaptive Neuro-Fuzzy Inference Algorithms Optimized with Meta-Heuristic Algorithms, Amirkabir J. Civil Eng., 53(8) (2021) 3261-3278.

DOI: 10.22060/ceej.2020.17798.6679



