



Simulation of soil stress in earth dams using artificial intelligence models and determination of effective features

H. Hakimi Khansar, J. Parsa*, A. Hosseinzadeh Dalir, J. Shiri

Water Engineering Department, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

ABSTRACT: The general purpose of this paper is to select effective features and model soil stress in earth dams during construction. Five features, including fill level, duration of construction, reservoir level (impoundment), impounding rate and fill rate, were selected as hybrid model inputs. By performing hybrid algorithm and sensitivity analysis and feature selection method, fill level and duration of construction were recognized as the most effective features in modeling the total stress in selected cells, because concurrent mean square error values for the fill level and duration of construction in TPC25.1, TPC25.3 and TPC25.4 cells were 1.523, 2.747 and 0.750, respectively. In TPC25.2 cell, three features including fill level, duration of construction and impoundment level, had the greatest effect in modeling the total soil stress based on the mean square error value of 5.245. Comparison of the results of the ANN model with ANFIS and GEP showed that although the difference in the accuracy of the models is very small, all three models had acceptable results in the test step, the ANFIS model results indicated that the statistical error measures of R^2 , RMSE, MAE and NS in TPC25.4 cell were 0.9955, 0.0227, 0.0185 and 0.9666, respectively. It showed that how much the input data are more scattered, the ANFIS model had more capability than ANN and GEP models to simulate the soil stress in the studied earth dam.

Review History:

Received: Jul. 06, 2020
Revised: Apr. 08, 2021
Accepted: Apr. 09, 2021
Available Online: Apr. 18, 2021

Keywords:

Earth dam
PSO-ANN hybrid algorithm
Feature selection
ANFIS
Soil vertical stress

1- Introduction

Instrumentation during the construction of earth dams is used to ensure safety, minimize construction costs and control construction methods for better measurement of committees [1]. Nowadays, the use of new methods such as artificial intelligence and meta-heuristic algorithms is very important in the analysis and evaluation of engineering and executive designs [2]. In this research, different parameters as inputs to artificial intelligence models for simulating the soil stress during the construction of earth dams were proposed and the superior model among the ANN, ANFIS and GEP models was identified based on statistical error measures.

2- Materials and methods

For the present study, the recorded data in Kaboudwal Dam, located in Golestan Province [3], were used during the dam construction.

2- 1- Hybrid particle swarm algorithm - artificial neural network

In this study, fill level (F) (m.a.s.l), reservoir water level (R) (m.a.s.l), duration of dam construction (T) (day), fill rate ((m.a.s.l)/day) and impounding rate ((m.a.s.l)/day) were selected as inputs, and vertical soil stress P (kPa) during the construction was considered as the output of the models. A meta-heuristic algorithm was combined with a nonlinear

modeling method such as an artificial neural network and a hybrid algorithm that can simulate complex and nonlinear relationships well and has the capability to identify the effective features with appropriate accuracy. The data were randomly divided into two parts: training (70%) and test (30%) and the weighted average errors in all cells were used to calculate the model error as follows:

$$\text{Error}_f = 0.8\text{error}_t + 0.2\text{error}_e \quad (1)$$

In which, Error_f , error_t and error_e are total model error for different subsets of features, training data error, and testing data error, respectively.

2- 2- Modeling of total stress with ANN model

According to Table 3 and the values of statistical error measures in both training and test steps, the ANN model is superior in modeling the target variable (total stress). Comparison of ANN model with ANFIS and GEP Tables 3 and 4 show the values of statistical error measures for different soil stress models in the training and test steps. According to the statistical error measures for different models and considering the results of Tables 2 and 3 in different cells, although the differences in the accuracy of the models are very small, all three models have acceptable and satisfactory results.

*Corresponding author's email: jparsa78@gmail.com



Table 1. Optimal values of PSO algorithm

| Max Iteration | Number of Population (search agent) | Range partitions | Swarm Size | Cognition coefficient (c1) | Social Coefficient (c2) |
|---------------|-------------------------------------|------------------|------------|----------------------------|-------------------------|
| 1000 | 100 | LB=0; UB=1 | 10 | 2 | 2 |




Fig. 1. Features values in the Features selection method for cells

Table 2. Statistical error measures in predicting soil stress, training and testing of ANN model

| cell | inputs | raining | | | | | testing | | | | | Parameter |
|---------|-----------|---------|--------|--------|--------|----------------|---------|--------|--------|--------|----------------|-----------|
| | | GMER | NS | MAE | RMSE | R ² | GMER | NS | MAE | RMSE | R ² | |
| TPC25.1 | T ∙ F | 1.0008 | 0.7902 | 0.0081 | 0.0105 | 0.9980 | 1.0007 | 0.4725 | 0.0121 | 0.0206 | 0.9939 | MLP 2-2-1 |
| TPC25.2 | T ∙ F ∙ R | 1.0012 | 0.9433 | 0.0121 | 0.0168 | 0.9969 | 0.9809 | 0.6800 | 0.0137 | 0.0205 | 0.9960 | MLP 3-3-1 |
| TPC25.3 | T ∙ F | 1.0185 | 0.9061 | 0.0089 | 0.0127 | 0.9985 | 1.0071 | 0.6147 | 0.0096 | 0.0121 | 0.9979 | MLP 2-2-1 |
| TPC25.4 | T ∙ F | 1.0016 | 0.8969 | 0.0203 | 0.0286 | 0.9911 | 0.9924 | 0.7285 | 0.0189 | 0.0149 | 0.9921 | MLP 2-2-1 |

In the above table, F is the fill level, R is the reservoir level and T is duration of construction.

3- Results and discussion

Feature selection using the PSO-ANN hybrid algorithm Table 1 shows the optimal values of the parameters of the PSO algorithm. According to Figure 1, in TPC25.1, TPC25.3 and TPC25.4 cells, among the 5 mentioned features, two features, i.e. fill level and duration of construction, have the greatest effect in modeling the total soil stress. In TPC25.2 cell, three characteristics of fill level, duration of construction and reservoir level have the greatest effect on modeling total soil stress.

On the other hand, the genetic programming model has a comparative advantage over other models; because genetic programming is able to provide a relationship between model inputs and outputs. Table 4 shows the relationships for estimating soil stress (P) in the cross-section in which 25th cells have been installed.

4- Conclusion

Among the five features as inputs of the PSO-ANN hybrid model, fill level, duration of construction and reservoir level were the most effective features in modeling total stress in selected cells and impounding rate and fill rate has less effect on total stress modeling. Also, the error in the installed cells behind the filter and drainage layers is less than errors in other cells. The results of sensitivity analysis in the ANN model showed that the fill level and duration of construction with the highest sensitivity coefficient are the most important features in modeling the total stress in most cells. As an important result, the position of the installation of cells with respect to the filter and drainage layers, as well as the levels of cells installation, are effective in modeling the total soil stress and the selection of inputs as well.

Table 3. Statistical error measures for different cells in the training and testing stages of the ANFIS model

| Model ANFIS | Training | | | | | testing | | | | | Parameter | |
|-------------|----------|--------|--------|--------|----------------|---------|---------|--------|--------|----------------|-----------|--------------------------------|
| | GMER | NS | MAE | RMSE | R ² | GMER | NS | MAE | RMSE | R ² | MF Type | Number of membership functions |
| TPC25.1 | 1/0000 | 0.9859 | 0.0015 | 0.0023 | 0.9999 | 0.9996 | 0.96666 | 0.0059 | 0.0087 | 0.9980 | Gauss2mf | 3 |
| TPC25.2 | 0.0010 | 0.9856 | 0.0032 | 0.0059 | 0.9997 | 0.0120 | 0.9668 | 0.0118 | 0.0229 | 0.9955 | Gaussmf | 4 |
| TPC25.3 | 0.9998 | 0.9852 | 0.0016 | 0.0024 | 0.9999 | 0.9926 | 0.9605 | 0.0109 | 0.0169 | 0.9972 | psagmf | 3 |
| TPC25.4 | 0.0012 | 0.9857 | 0.0032 | 0.0045 | 0.9997 | 0.9911 | 0.9666 | 0.0185 | 0.0227 | 0.9955 | Gaussmf | 3 |

Table 4. Relationships obtained from each subtree to predict soil vertical stress for different cells

| cell | Relationships derived from each subtree | R ² |
|---------|---|----------------|
| TPC25.1 | $P = (((F) - (T)^5)^3) / ((1.0 / (1.28)) + -4.23) + ((((((T)^5 * (R)) + -0.91)^3)^2) / 6.56) + (F)$ | 0.99 |
| TPC25.2 | $P = (T) + ((R) / -9.38) + ((F) / -6.87)^2$ | 0.97 |
| TPC25.3 | $P = (((F)^4 - (T))^2)^2 + (((R) - (F))^5)^5 + (F)$ | 0.99 |
| TPC25.4 | $P = ((F) - (R)^5) + ((F) - (T))^4 + ((R)^5)$ | 0.98 |

References

[1] F. Salmasi, H. Hakimi Khansar B. Norani, (2019). Investigation of the Structure of the Dam Body during Construction and its Comparison with the Analytical Results Using PLAXIS Software (the Case Study of Kaboodvall Dam). JWSS, 22(4), 155-171. (In Persian)

[2] V. Nourani. (2015). Basics of hydroinformatics ANFIS model for multi-station modelling of rainfall–runoff process. Journal of Hydrology, 490, 41-55(In Persian).

[3] Regional Water Company of Golestan. (2013). Reporting the Behavior of Kabudwal Dam Golestan. Golestan: Kabudwal Dam Behavior Report.32-52.

HOW TO CITE THIS ARTICLE

H. Hakimi Khansar, J. Parsa, A. Hosseinzadeh Dalir, J. Shiri, Simulation of soil stress in earth dams using artificial intelligence models and determination of effective features, Amirkabir J. Civil Eng., 54(1) (2022) 55-58.

DOI: 10.22060/ceej.2021.18682.6925





مدل سازی تنش خاک در سدهای خاکی با روش های هوش مصنوعی و تعیین ویژگی های موثر

حسین حکیمی خانسر، جواد پارسا*، علی حسین زاده دلیر، جلال شیرینی

دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

تاریخچه داوری:

دریافت: ۱۳۹۹/۰۴/۱۶

بازنگری: ۱۴۰۰/۰۱/۱۹

پذیرش: ۱۴۰۰/۰۱/۲۰

ارائه آنلاین: ۱۴۰۰/۰۱/۲۹

کلمات کلیدی:

سد خاکی

الگوریتم هیبریدی PSO-ANN

انتخاب ویژگی

سیستم استنتاج عصبی - فازی تطبیقی

تنش قائم خاک

خلاصه: هدف کلی این مقاله انتخاب ویژگی های موثر و مدل سازی تنش خاک در سدهای خاکی در زمان ساخت با شبکه عصبی به کمک یک الگوریتم بهینه ساز و در ادامه نتایج مدل هیبریدی با روش های مرسوم ANFIS و GEP مقایسه شده است. پنج ویژگی شامل تراز خاکریزی، زمان ساخت سد، تراز مخزن (آبگیری)، سرعت آبگیری و سرعت خاکریزی به عنوان ورودی های مدل هیبریدی انتخاب شده است. با اجرای الگوریتم هیبریدی و تحلیل حساسیت و روش انتخاب ویژگی، تراز خاکریزی و زمان ساخت سد، مؤثرترین ویژگی ها در مدل سازی تنش کل در سلول های منتخب بودند؛ زیرا ترکیب دوتایی شامل تراز خاکریزی و زمان ساخت در سلول های TPC_{25,1} و TPC_{25,3} و TPC_{25,4} به ترتیب با مقادیر خطا (MSE) برابر ۱/۵۲۳، ۲/۷۴۷ و ۰/۷۵۰ مؤثرترین ویژگی ها در این سلول ها بودند. در سلول TPC_{25,2} انتخاب سه ویژگی تراز خاکریزی، زمان ساخت و تراز مخزن با توجه به مقدار خطای ۵/۲۴۵ بیشترین تأثیر را در مدل سازی تنش کل خاک در این سلول داراست. مقایسه بین مدل ANN با ANFIS و GEP نشان داد، هر چند که اختلاف در دقت مدل ها بسیار ناچیز است، می توان گفت هر سه مدل جواب قابل قبول و نزدیک به هم داشته اند. هم چنین نتایج نشان می دهد که هر چه پراکندگی داده های ورودی مدل بیشتر باشد، مدل استنتاج عصبی - فازی تطبیقی دارای توانایی بیشتری در شبیه سازی نسبت به دو مدل ANN و GEP است، زیرا در سلول TPC_{25,4} مدل ANFIS در دوره آزمون با شاخص های آماری R^2 ، MAE، RMSE و NS به ترتیب برابر مقادیر ۰/۹۹۵۵، ۰/۰۲۲۷، ۰/۰۱۸۵ و ۰/۹۶۶۶ دارای عملکرد بهتری نسبت به دو مدل دیگر است.

۱- مقدمه

گسیختگی پیش رونده، تراکم خاک، تغییر مقاومت برشی و ایجاد نشست در آن می شود، بنابراین محاسبه تنش کل خاک یکی از ویژگی های مهمی است که در سدهای خاکی به وسیله ابزار دقیق نصب شده در آن محاسبه می شود [۷ و ۸].

تنش خاک در بدنه سد خاکی در زمان ساخت به عواملی مثل مدت زمان ساخت سد، تراز و سرعت خاکریزی، تراز و سرعت تغییرات تراز آب مخزن و ... در زمان ساخت سدهای خاکی، بستگی دارد که توزیع آن در هر پروژه تصادفی است؛ بنابراین با وجود پیچیدگی و عدم قطعیت های زیاد در این گونه پدیده ها، به کارگیری مدل های هوش مصنوعی که ورودی و خروجی مشاهداتی را دریافت نموده و فرایند مورد نظر را تخمین می زند، در بهبود مدل سازی این گونه پدیده ها می تواند مؤثر باشد [۹ و ۱۰]. امروزه، استفاده از دانش های نوین از جمله هوش مصنوعی و الگوریتم های تکاملی در تحلیل و ارزیابی طرح های مهندسی و اجرایی اهمیت زیادی پیدا کرده است. [۱۰].

به دلیل اهمیت سد از نظر اقتصادی و کارایی آن و البته خطرات شکست و خرابی آن، ایمنی و ریسک خرابی سدها از دیرباز مورد توجه پژوهشگران و مهندسين قرار گرفته است، همچنین سدها و مخازن ذخیره آب نقشی اساسی در توسعه مسائل اقتصادی و تأمین آب در کشور دارند [۱ و ۲]. سدهای خاکی در بین انواع مختلف سدها به علت صرفه های اقتصادی، سهولت اجرا، در دسترس بودن مصالح اجرایی و عملکرد سازه های اهمیت ویژه ای دارند [۳]. ابزارگذاری در حین ساخت برای اطمینان از ایمنی، حداقل نمودن هزینه های ساخت، کنترل روش و برنامه ساخت، فراهم نمودن محافظت قانونی و فراهم نمودن اطلاعات برای اندازه گیری کمیت ها مورد استفاده قرار می گیرد [۵] و [۴]. از دیدگاه ژئوتکنیک و روش ساخت، سدهای خاکی به دو گروه عمده تقسیم بندی می شوند که تقریباً تمامی آن ها در گروه غلظتی (کوئیدنی) قرار دارند [۶]. تغییر تنش در زمان ساخت سدهای خاکی باعث تغییر حجم، ایجاد

* نویسنده عهده دار مکاتبات: jparsa@tabrizu.ac.ir



مرکزی اتفاق افتاده و مقدار آن در محور و بخش میانی سد بیشتر از طرفین آن است. کماسی و بیرانوند در سال ۲۰۲۰ [۷] به بررسی جابجایی‌های قائم و افقی سد خاکی ایوشان با استفاده از ابزار دقیق و تحلیل عددی پرداختند. به منظور تطبیق داده‌های مشاهداتی و پیش‌بینی شده از رگرسیون چند متغیره و همچنین معیار ضریب تعیین استفاده شد که نتایج هم‌خوانی حدود ۸۵ درصدی بین داده‌های مشاهداتی و پیش‌بینی شده را نشان داد.

در این تحقیق ورودی‌های جدید در مدل‌سازی هوش مصنوعی برای تنش خاک در زمان ساخت سدهای خاکی پیشنهاد می‌گردد. بدین منظور، از سه مدل ANN، ANFIS و GEP استفاده شده و به منظور انتخاب بهترین ترکیب از ویژگی‌های ورودی در شبکه عصبی از الگوریتم بهینه‌ساز ازدحام ذرات برای ۴ سلول فشارسنجی سد خاکی کبودوال در مقطع ۲۵، استفاده شده است. بهترین ترکیب و موثرترین ویژگی‌های ورودی، با این روش استخراج شده و در ادامه بین مدل‌های ANN و ANFIS و GEP با توجه به شاخص‌های آماری مقایسه‌ای صورت گرفته است.

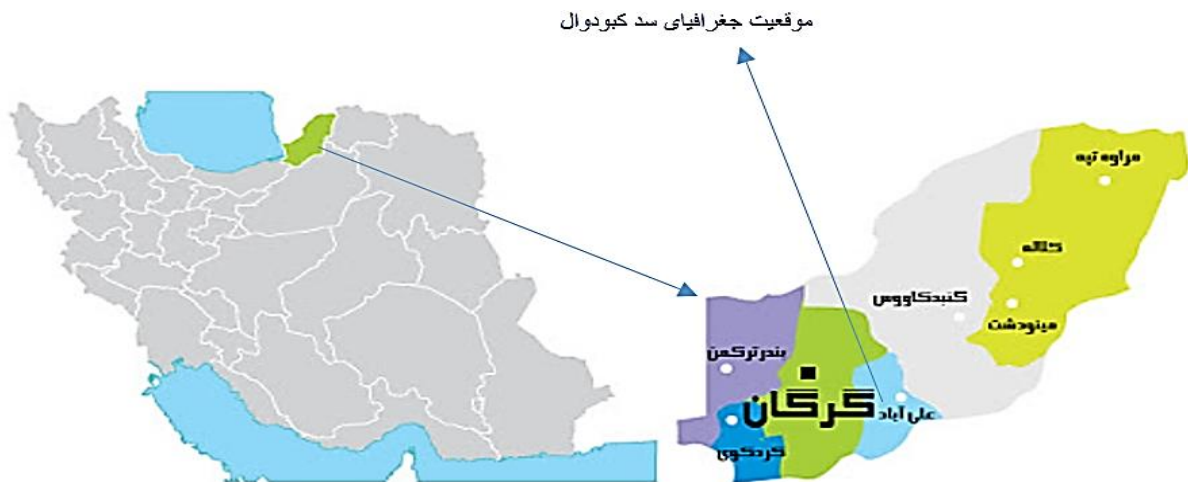
۲- الگوسازی نظری یا تجربی

۲-۱- سد مورد مطالعه

سد کبودوال (قره سو زرينگل) در استان گلستان در شمال شرق ایران و در حد فاصل طول جغرافیایی ۵۴ درجه و ۴۰ دقیقه تا ۵۴ درجه و ۵۶ دقیقه شرقی و عرض‌های جغرافیایی ۳۶ درجه و ۵۴ دقیقه تا ۳۷ درجه و ۶۰ دقیقه شمالی و اطراف شهر علی‌آباد قرار دارد. سد کبودوال همگن و دارای فیلتر و زهکش مایل است. طول تاج سد ۱۳۷۲ متر و حداکثر ارتفاع از پی ۳۳/۲۵ متر است. ارتفاع از بستر ۳۰٫۵ متر و همچنین تراز بستر سد ۱۶۲ متر از سطح دریا و حداقل تراز آب در مخزن ۱۷۱ متر از سطح دریا و نیز حداکثر تراز نرمال آب ۱۸۸/۲۵ متر از سطح دریا است. تراز تاج سد ۱۹۲/۲۵ متر از سطح دریا است. ضخامت در پی ۱۰ متر و آب قابل تنظیم سالیانه حدود ۵۵ میلیون مترمکعب است. تاریخ شروع ساخت سد در مهرماه سال ۱۳۸۲ و تاریخ پایان احداث آن دی ماه سال ۱۳۹۲ بوده است. سنگ بستر در تکیه‌گاه‌ها از جنس توف اندزیتی، آگلومرا و ماسه سنگ توفی بوده است که تا عمق ۱۰ متر شدیداً هوا زده و تجزیه‌پذیر بوده است. مطالعه نتایج دانه‌بندی اخذ شده، حاکی از آن است که اندازه دانه‌بندی مصالح جناح چپ سد کبودوال از راست ریزتر بوده و از نظر حدود اتربرگ جناح چپ دارای خاصیت خمیری کم تا متوسط و به ندرت زیاد و در جناح راست دارای خاصیت خمیری کم تا متوسط است [۱۹]. شکل ۱ موقعیت جغرافیایی سد کبودوال را نشان می‌دهد.


مدل‌های هوش مصنوعی روش‌هایی موثر برای بررسی و مدل‌سازی مقادیر زیادی از داده‌های دینامیک، غیرخطی و دارای خطا ارائه می‌دهند [۱۱]. فرایند انتخاب ویژگی برای دو حالت تخمین و طبقه‌بندی ویژگی‌ها به کار می‌رود [۱۲]. تخمین زیرمجموعه همیشه نظارت شده است، در حالی که طبقه‌بندی ویژگی‌ها را می‌توان نظارت شده و یا در برخی موارد غیرنظارت شده انجام داد [۱۳]. با به کار بردن تکنیک‌های انتخاب ویژگی می‌توان محاسبات ضروری و دقت پیش‌بینی را بهبود بخشید و زمان اجرای محاسبات را کاهش داد [۱۴].

رانکوویچ و همکاران در سال ۲۰۱۴ [۱۵] رفتار یک سد بتنی را با استفاده از رگرسیون بردار پشتیبان مدل‌سازی کردند که نتایج نشان داد که مدل‌های محاسبات نرم نتایج دقیقی را ارائه می‌کند. نوکوویچ و همکاران در سال ۲۰۱۴ [۱۶] از یک مدل فازی-عصبی برای تخمین هد سد Iron Gate استفاده کردند که مقایسه مقادیر پیش‌بینی شده توسط مدل شناسایی بر اساس رگرسیون بردار پشتیبان (SVR) با داده‌های تجربی حاکی از آن بود که مدل شناسایی SVR نتایج دقیقی ارائه می‌کند. نورانی و همکاران در سال ۲۰۱۲ [۱] برای بررسی هد سلولی یک سد خاکی در ایران، مدل‌های ANN با استفاده از داده‌های تراز آب بالادست-پایین دست سد ایجاد کردند و نتایج به دست آمده را با نتایج مدل اجزاء محدود (FEM) مقایسه کردند و به این نتیجه رسیدند که مدل ANN می‌تواند جایگزین نسبتاً مناسبی برای مدل عددی FEM باشد. تایفور و همکاران در سال ۲۰۰۵ [۹] جریان داخل سد دی در لهستان را به روش اجزاء محدود و شبکه عصبی بررسی کردند. آن‌ها سطح آب در بالادست و پایین دست سد را به عنوان ورودی و سطح آب در داخل سلول را به عنوان خروجی مدل عصبی قرار دادند. این محققین نتایج حاصل از مدل‌سازی شبکه عصبی را دقیق‌تر از مدل‌سازی توسط اجزاء محدود عنوان کردند و به این نتیجه رسیدند که مدل‌سازی توسط شبکه عصبی برای بررسی سطح آب در داخل خاک، نتایج مناسبی در بر دارد. نورانی باباخانی در سال ۲۰۱۳ [۱۷] برای مدل‌سازی نشت از سدها، از ادغام شبکه مصنوعی با روش تابع شعاع پایه RBF استفاده نمودند. آن‌ها به این نتیجه رسیدند که شبکه عصبی به سبب انعطاف‌پذیری آن قادر به پیش‌بینی مناسبی از مقادیر نشت خواهد بود. سلماسی و همکاران در سال ۲۰۲۰ [۱۸] به تخمین رفتار سد کبودوال در حین ساخت با مدل‌سازی عددی سه بعدی و مقادیر حاصل از شبیه‌سازی عددی با تحلیل برگشتی را با مقادیر نظیر داده‌های ابزار دقیق سد مقایسه کردند. نتایج نشان داد که پیشینه افزایش فشار آب حفره‌ای، تنش، نشست و جابجایی افقی در بخش



شکل ۱. موقعیت جغرافیایی سد کبودوال در استان گلستان

Fig. 1. Geographic location of Kaboudwal Dam in Golestan Province



شکل ۲. موقعیت ابزارهای دقیق نصب شده در مقطع عرضی شماره ۲۵ [۲۵]

Fig.2. locations of accurate instruments installed in cross section No.25

است. سلول‌های فشارسنجی مقطع عرضی ۲۵ به نام‌های TPC۲۵.۱، TPC۲۵.۲، TPC۲۵.۳ و TPC۲۵.۴ هستند. موقعیت قرارگیری آن‌ها در شکل ۲ نشان داده شده است. سلول‌های TPC۲۵.۱ و TPC۲۵.۴ در این مقطع به ترتیب در بالادست و پایین‌دست بدنه سد قرار دارند. سلول TPC۲۵.۳ در این مقطع در قسمت میانی و در مرکز مقطع عرضی نزدیک پی سد و سلول TPC۲۵.۲ در قسمت میانی و در مرکز مقطع عرضی دور از پی سد قرار دارد (شکل ۲).

با توجه به حساسیت پی و بدنه سد کبودوال در خصوص نحوه و سرعت بارگذاری در حین ساخت سد، ارزیابی رفتار پی و بدنه سد به ویژه در بخش میانی بدنه برای تغییر شکل‌پذیری پی در این بخش، از مقطع عرضی ۲۵ (مقطع عرضی بخش میانی بدنه و پی سد) برای بررسی تنش قائم خاک در زمان ساخت استفاده شد. برای انجام پژوهش حاضر از داده‌های ابزار دقیق سد کبودوال در زمان ساخت، اخذ شده از شرکت آب منطقه‌ای استان گلستان [۱۹]، استفاده شده

۲-۲- الگوریتم بهینه‌سازی ازدحام ذرات (PSO)

الگوریتم بهینه‌سازی ازدحام ذرات یکی از مهم‌ترین الگوریتم‌های بهینه‌سازی هوشمند است که در حوزه هوش ازدحامی جای می‌گیرد. این روش یک روش محاسباتی تکاملی است که توسط کندی و ابرهارت [۲۰] ارائه شده است. بهینه‌ساز ازدحام ذرات از رفتار اجتماعی پرندگان الهام گرفته شده است. این روش از تعدادی از ذرات (راه‌حل‌های نامزد) که در فضای جستجو به دنبال یافتن بهترین راه حل هستند، استفاده می‌کند. در همین حال همه ذرات به سوی بهترین ذره‌ای (بهترین راه حل) که در مسیرشان وجود دارد، حرکت می‌کنند. به بیان دیگر، ذرات بهترین راه‌حل‌های خود را به عنوان بهترین راه حل کلی در نظر می‌گیرند. هر ذره در این الگوریتم باید پارامترهایی مانند: موقعیت فعلی، سرعت فعلی، فاصله تا $pbest$ و فاصله تا $gbest$ را به منظور تغییر موقعیت خود در نظر بگیرد. مدل‌سازی ریاضی بهینه‌ساز ازدحام ذرات به صورت روابط (۱) و (۲) است:

$$v_i^{t+1} = wv_i^t + c_1 * rand * (pbest_i - x_i^t) + c_2 * rand * (gbest_i - x_i^t) \quad (1)$$


$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (2)$$

در روابط بالا، v_i^t بیان کننده سرعت ذره i -ام در تکرار t -ام، w بیان کننده تابع وزن، c_1 بیان کننده ضریب شتاب و $rand$ نشان دهنده یک عدد تصادفی بین ۰ و ۱ است. x_i^t بیان کننده موقعیت فعلی ذره i -ام در تکرار t -ام است. همچنین $pbest_i$ بهترین راه حل عامل i -ام در تکرار t -ام است و بهترین راه حلی که تاکنون پیدا شده، $gbest$ است. در رابطه (۱) توانایی اکتشاف بهینه‌ساز ازدحام ذرات را فراهم می‌کند و $c_1 * rand * (pbest_i - x_i^t)$ نشان دهنده فکر خصوصی و $c_2 * rand * (gbest_i - x_i^t)$ همکاری بین ذرات است. بهینه‌ساز ازدحام ذرات کار خود را با قرار دادن تصادفی ذرات در یک فضای مسئله شروع می‌کند. در هر تکرار سرعت ذرات با استفاده از رابطه (۱) محاسبه می‌شود. بعد از محاسبه سرعت ذرات، موقعیت جدید ذرات با استفاده از رابطه (۲) به دست می‌آید. فرآیند تغییر موقعیت ذرات تا دستیابی به معیار نهایی ادامه دارد. این الگوریتم برای انواع مسائل پیوسته و گسسته مناسب است و پاسخ‌های بسیار مناسبی برای مسائل بهینه‌سازی مختلف داده است [۲۰].

۲-۳- الگوریتم ازدحام ذرات- شبکه عصبی مصنوعی

اولین نکته مهم در مدل‌سازی هوش مصنوعی، نوع و تعداد داده‌های ورودی این مدل‌ها است. با بررسی داده‌های سلول‌های منتخب در مقطع ۲۵ در سد کبودوال، تراز خاکریزی (F) بر حسب (m.a.s.l)، تراز آب مخزن (R) بر حسب (m.a.s.l)، زمان ساخت سد (T) بر حسب (day)، سرعت خاکریزی بر حسب ($\frac{m.a.s.l}{day}$) و سرعت آبیگری بر حسب ($\frac{m.a.s.l}{day}$) به عنوان ورودی و تنش قائم خاک (P) بر حسب (kPa) ایجاد شده بر بدنه سد خاکی در زمان ساخت، به عنوان خروجی مدل هیبریدی انتخاب شدند. این ورودی‌ها برای اولین بار در سدهای خاکی برای مدل‌سازی هوش مصنوعی توسط نگارندگان این تحقیق پیشنهاد می‌شود. داده‌های ورودی انتخابی در تمام سدهای ساخته شده و در حال ساخت در ایران توسط طراحان و سازندگان سد اندازه‌گیری می‌شوند، بنابراین به راحتی می‌توان از این ورودی‌ها برای سدهای مشابه در ایران برای مدل‌سازی با هوش مصنوعی استفاده کرد.

انتخاب ویژگی، فنی است که برای انتخاب زیرمجموعه‌ای از ویژگی‌های مرتبط با یک هدف خاص به کار می‌رود و مهم‌ترین اصل در این فرایند، انتخاب ویژگی‌های پایدار و حذف داده‌های اضافی است [۲۱]. سه روش برای کاربرد الگوریتم‌های فرا ابتکاری در بحث بهینه‌سازی شبکه عصبی مصنوعی وجود دارد. یکی بهینه‌سازی ساختار شبکه عصبی و دومی بهینه‌سازی وزن‌های شبکه عصبی است [۲۲]، که از هیچ‌کدام از این روش‌ها در این مقاله استفاده نشده است. در روش سوم که روش انتخاب ویژگی نام دارد، برای انتخاب بهترین ترکیب از ویژگی‌های ورودی در شبکه عصبی ANN-MLP از الگوریتم بهینه‌ساز ازدحام ذرات استفاده می‌شود. از این روش در پژوهش حاضر استفاده شده است، به این صورت که برای اجرای مدل ANN-MLP با ۵ ویژگی مطرح شده اگر بخواهیم با یک ویژگی شبکه عصبی را اجرا کنیم، تعداد پنج ترکیب وجود خواهد داشت و اگر بخواهیم با دو ویژگی این عمل را انجام دهیم، ده ترکیب (ترکیب پنج ویژگی از دو) وجود دارد. در مورد ۳ ویژگی و ۴ ویژگی نیز به ترتیب ۱۰ و ۵ ترکیب وجود خواهد داشت. در مورد ۵ ویژگی فقط یک ترکیب وجود دارد، بنابراین در کل ما ۳۱ ترکیب و ۵ زیرمجموعه داریم، که با مدل ANN-MLP باید مدل‌سازی شوند، که کار بسیار وقت‌گیری است. به جای مدل‌سازی جدا از یک الگوریتم بهینه‌سازی استفاده کرده و بهترین عملکرد مدل ANN-MLP مربوط به ترکیب ویژگی‌هایی است که کمترین MSE یا خطا را دارد. به طور خلاصه الگوریتم PSO یا هر الگوریتم بهینه‌ساز دیگر، ترکیب



شکل ۳. ساختار شبکه عصبی مصنوعی استفاده شده در تحقیق حاضر

Fig.3. The schematic representation of the used ANN model structure in the present study

انتخاب ویژگی، هدف تشخیص ویژگی‌های موثر بر متغیر خروجی است و نه تخمین آن، بنابراین خطای مربوط به داده‌های آموزشی، اهمیت زیادی دارد؛ زیرا رابطه بین ویژگی‌های ورودی و خروجی مدل با استفاده از داده‌های آموزشی به دست می‌آیند.

به منظور مدل‌سازی متغیر هدف (تنش کل) با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه (MLP)، متغیرهای منتخب حاصل از فرایند انتخاب ویژگی، به عنوان متغیرهای ورودی در هر سلول استفاده شده است. تعداد لایه‌های بهینه پنهان و هم‌چنین تعداد نرون‌های بهینه لایه پنهان با سعی و خطا در جهت انتخاب ساختار بهینه برای هر سلول تعیین گردید. در این پژوهش جهت گزینش ساختار بهینه، از شبکه‌های با ۱ تا ۱۰ لایه و ۱ تا ۱۵ نرون استفاده شده است. در تمام سلول‌ها، از روش آزمون و خطا برای تعیین بهترین معماری برای این شبکه، استفاده شده است. تابع انتقال شامل توابع سیگموئید و خطی، به ترتیب برای لایه پنهان و خروجی بوده است (شکل ۳). تابع آموزش تابع Levenberg-Marquardt انتخاب گردید.

۲-۴- تحلیل حساسیت

در پژوهش حاضر، از روش هیل [۲۳] برای تحلیل حساسیت متغیرهای ورودی، استفاده شده است. در این روش، با تغییر دادن هر یک از متغیرها ورودی، به یک مقدار معلوم (مثلاً ۱۰ درصد)، تأثیر این تغییر بر خروجی مدل محاسبه می‌شود و مقدار حساسیت مدل هوش مصنوعی به متغیر ورودی مورد نظر به دست می‌آید. مقدار حساسیت بیشتر برای یک متغیر ورودی، اهمیت بیشتر آن را بر مدل‌سازی نشان می‌دهد و تأثیر بیشتری بر خروجی و یا متغیر هدف دارد [۲۳]. دلیل انجام تحلیل حساسیت این است که این تحلیل به ترتیب بهترین ویژگی‌ها را نشان می‌دهد ولی در مورد بهترین ترکیب و یا همان بهترین زیرمجموعه ویژگی‌ها اطلاعاتی به ما نمی‌دهد.

ویژگی‌ها را با شبکه عصبی مدل‌سازی نموده و بهترین ترکیب که دارای کمترین خطا (MSE) است را به عنوان مدل بهینه شبکه عصبی ANN-MLP انتخاب می‌کند که به این فرایند روش انتخاب ویژگی گفته می‌شود. در این تحقیق، یک الگوریتم تکاملی با یک روش مدل‌سازی غیرخطی مانند شبکه عصبی مصنوعی ترکیب شده و یک الگوریتم هیبرید به دست آمد که می‌تواند روابط پیچیده و غیرخطی را به خوبی شبیه‌سازی کند و ویژگی‌های موثر بر متغیر هدف را با دقت مناسبی استخراج کند. ابتدا برنامه انتخاب ویژگی با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات و شبکه عصبی برای رگرسیون در محیط متلب ۲۰۱۴ نوشته شد، در ادامه با اجرای الگوریتم PSO-ANN مؤثرترین ویژگی‌ها در مدل‌سازی تنش کل استخراج شده است. انتخاب ویژگی در این روش با تعداد ویژگی مطلوب از پیش تعیین شده و معلوم و با کُدگذاری پیوسته با استفاده تکنیک کلید تصادفی انجام گرفته است. به منظور انتخاب ویژگی در الگوریتم هیبریدی PSO-ANN داده‌ها به صورت تصادفی به دو دسته آموزشی (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم شدند (در مورد تعداد داده‌ها و آمار توصیفی به جدول ۱ مراجعه شود) و از میانگین وزنی خطاهای آموزشی و آزمون به صورت زیر در تمام سلول‌ها، برای محاسبه خطای مدل، استفاده گردید:

$$\text{error}_f = 0.8\text{error}_{tr} + 0.2\text{error}_{te} \quad (3)$$

در رابطه ۳، Error_f ، error_{tr} و error_{te} به ترتیب خطای نهایی مدل به ازای زیرمجموعه‌های متفاوت از ویژگی‌ها، خطای داده‌های آموزشی و آزمون هستند. در اینجا شاخص خطا، میانگین مربعات خطا (MSE) است که در ادامه تحت عنوان رابطه ۱۰ ارائه شده است. از آنجا که در فرایند

۲-۵- سیستم استنتاج عصبی - فازی تطبیقی (ANFIS)

سیستم ANFIS در ابتدا توسط جانگ [۲۴] معرفی گردید. این سیستم از نظر عملکرد مشابه سیستم‌های استنتاج- فازی است. هر یک از سیستم‌های فازی شامل سه بخش اصلی، فازی سازی، پایگاه داده فازی و غیرفازی کردن است. پایگاه داده شامل دو بخش اصلی، قانون پایه فازی و عملگر استنتاج است [۲۴]. ساختار شبکه عصبی- فازی، از ترکیب دو ساختار شبکه‌های عصبی و سیستم‌های فازی تشکیل شده که در این ساختار، از مزایای شبکه‌های عصبی و همچنین از ویژگی توانایی مدل‌سازی استنتاج سیستم‌های فازی که باعث افزایش قدرت تصمیم‌گیری در شرایط عدم قطعیت می‌شود، استفاده شده است [۲۵]. در ساختار ANFIS هر ورودی دو یا چند تابع عضویت دارد که پارامترهای توابع عضویت این سیستم از طریق الگوریتم پس انتشار یا ترکیب آن با روش حداقل مربعات تنظیم می‌شوند. این عملیات تنظیم به سیستم‌های فازی اجازه می‌دهد تا ساختار خود را از مجموعه داده‌ها فرا بگیرد [۲۶].

۲-۶- برنامه‌ریزی بیان ژن (GEP)

یکی از نقاط قوت GEP آن است که معیار تنوع ژنتیکی بسیار ساده بوده و لذا عملگرهای ژنتیک در سطح کروموزوم عمل می‌نمایند. همچنین یکی دیگر از نقاط قوت این روش، عبارت است از طبیعت منحصر به فرد چند ژنی بودن آن که زمینه ارزیابی مدل‌های پیچیده‌ای را که شامل چندین زیرمدل می‌باشند، فراهم می‌آورد [۲۷]. فرآیند مدل‌سازی تخمین تنش قائم خاک در بدنه سد خاکی کبودال در زمان ساخت با استفاده از روش حاضر به شکل زیر صورت گرفت. گام اول، انتخاب تابع برازش مناسب بود که در این مطالعه تابع جذر میانگین مربعات خطا به عنوان تابع برازش انتخاب گردید. گام دوم، انتخاب مجموعه متغیرهای ورودی و مجموعه توابع به منظور تولید کروموزوم‌ها بود. در مسئله حاضر مجموعه ترمینال‌ها متشکل از مقادیر تراز خاکریزی، تراز آب مخزن و زمان ساخت سد و نیز تنش قائم خاک (P_i)، در نظر گرفته شد. در این مطالعه از چهار عملگر اصلی که شامل $\{+, -, *, /\}$ و نیز توابع ریاضی $\{X^2, X^3, e^x, \ln, X^{42}, X^5\}$ و $\{\sin x, \cos x, \tan x, \text{Arctg} x\}$ استفاده گردید. گام سوم، شامل انتخاب ساختار و معماری کروموزوم‌ها بود. اندازه طول هر رأس و تعداد ژن‌ها بر اساس تعداد متغیرهای ورودی انتخاب شد. گام چهارم انتخاب تابع پیوندی بود که در این مطالعه تابع جمع کننده (مجموع) برای ایجاد پیوند بین زیرشاخه‌ها مورد استفاده قرار گرفت. در نهایت، در گام پنجم عملگرهای ژنتیک و نرخ هر یک از آن‌ها تعیین گردید.

۲-۷- ارزیابی مناسب بودن مدل و نرمال‌سازی داده‌ها

در این تحقیق از شاخص‌های آماری جذر میانگین مربعات خطا ($RMSE$)، میانگین مربعات خطا (MSE)، ضریب تبیین (R^2)، میانگین خطای مطلق (MAE)، نش- ساتکلیف (NS) و نیز میانگین هندسی نسبت خطا ($GMER$) برای بررسی و ارزیابی دقت مدل‌ها استفاده شده است. شاخص‌های مذکور با استفاده از روابط زیر قابل محاسبه می‌باشند:

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O}_i)(P_i - \bar{P}_i)}{\sqrt{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \sum_{i=1}^n (P_i - \bar{P}_i)^2}} \right)^2 \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{N}} \quad (5)$$

$$MAE = \exp \left[\frac{1}{N} \sum_{i=1}^n \ln \left(\frac{P_i}{O_i} \right) \right] \quad (6)$$

$$NS = \left| 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \right| \quad (7)$$

$$GMER = \exp \left[\frac{1}{N} \sum_{i=1}^n \ln \left(\frac{P_i}{O_i} \right) \right] \quad (8)$$

$$MSE = \frac{\sum_{i=1}^n (P_i - O_i)^2}{N} \quad (9)$$

در روابط اخیر، به ترتیب P_i مقدار ویژگی محاسبه شده از مدل هیبریدی و O_i مقدار ویژگی واقعی از ابزار دقیق سد و N نمایانگر تعداد داده‌ها است. شاخص نش- ساتکلیف نشان دهنده کارایی مدل است. هر چه این شاخص و ضریب تبیین (R^2) نزدیک‌تر به یک باشند، نشان دهنده کارایی مناسب مدل و تطابق داده‌های ورودی و خروجی از مدل‌ها است. هر اندازه که جذر میانگین مربعات خطا ($RMSE$) و میانگین خطای مطلق (MAE) به صفر نزدیک‌تر باشند، نشان می‌دهد که خروجی‌ها دقیق‌تر بوده و مقادیر واقعی و پیش‌بینی شده به هم نزدیک‌ترند [۲۸]. از شاخص میانگین هندسی نسبت خطا ($GMER$) برای مشخص نمودن بیش برآورد و یا کم

۳-۲- نتخاب ویژگی با استفاده از الگوریتم هیبریدی PSO-ANN

در فرایند انتخاب ویژگی، ویژگی‌هایی که در مدل‌سازی متغیر هدف، مهم و مؤثر هستند، استخراج می‌شوند [۳۳]. جدول ۴ مقادیر بهینه پارامترهای الگوریتم PSO و شکل ۴، نتایج استفاده از الگوریتم هیبریدی PSO-ANN برای ۴ سلول مقطع ۲۵ را ارائه می‌کند. با توجه به این شکل مشهود است که در سلول‌های TPC۲۵.۱، TPC۲۵.۳ و TPC۲۵.۴ از بین ۵ ویژگی اندازه‌گیری شده، دو ویژگی شامل تراز خاکریزی، زمان ساخت سد، بیش‌ترین تأثیر را در مدل‌سازی تنش کل خاک داراست؛ زیرا بر اساس نتایج ارائه شده مدل‌سازی شاخص تنش کل در شکل ۴، زیرمجموعه دوتایی، کمترین خطا را در مدل‌سازی ویژگی هدف تنش کل دارد. زیرا مقدار خطا (MSE) در سلول TPC۲۵.۱ با توجه به شکل ۴ برابر ۱/۵۲۳ است که مقدار آن از سایر زیرمجموعه‌های مورد مطالعه کمتر است. این مقدار همچنین برای TPC۲۵.۳ و TPC۲۵.۴ نیز با توجه به شکل ۴ برای مقدار دو ویژگی به ترتیب برابر ۲/۷۴۷ و ۰/۷۵۰ است که از سایر زیرمجموعه ویژگی‌ها کمتر است. فقط در سلول TPC۲۵.۲ انتخاب سه ویژگی بیش‌ترین تأثیر را در مدل‌سازی تنش کل خاک داراست. زیرا مقدار خطا (MSE) در این سلول با توجه به شکل ۴ برابر ۵/۲۴۵ است که مقدار آن از سایر زیرمجموعه‌های مورد مطالعه کمتر می‌باشد. البته نتایج نشان داد اختلاف بین زیرمجموعه‌های دو تا پنج تایی بسیار ناچیز بوده است. نتایج با توجه به شکل ۴ هم‌چنین نشان می‌دهد در سلول TPC۲۵.۴ که بعد از فیلتر و زهکش سد قرار دارد انتخاب سه ویژگی باعث بدتر شدن نتایج شده است بدین معنی که با توجه به شکل ۵ مقدار MSE افزایش یافته است ولی در سلول‌های نصب شده قبل از فیلتر و زهکش نتایج تقریباً یکسان است زیرا روند نمودار ویژگی-خطا یکسان است ولی مقدار خطای آن‌ها با هم متفاوت است که این موضوع احتمالاً مربوط به موقعیت نصب سه سلول TPC۲۵.۱، TPC۲۵.۲ و TPC۲۵.۳ مربوط است که قبل از فیلتر و زهکش نصب شده‌اند.

هم‌چنین خطای مدل‌سازی در سلول نصب شده بعد از فیلتر و زهکش (محور Y، نمودار ویژگی-خطا) از سایر سلول‌ها کمتر است. زیرا با توجه به شکل ۵، که نمودار همگرایی الگوریتم PSO برای زیرمجموعه‌های برتر در سلول‌های مختلف را نشان می‌دهد، سلول‌های TPC۲۵.۴، TPC۲۵.۱، TPC۲۵.۲ و TPC۲۵.۳ به ترتیب با مقادیر ۰/۷۵۰۴، ۱/۵۲۳۴، ۲/۷۴۷۷ و ۵/۲۴۵۱ دارای خطای کمتری در مدل‌سازی هستند. بیش‌ترین خطا مربوط

برآورد مدل، استفاده شد. علت استفاده از شاخص GMER ارجحیت آن نسبت به سایر شاخص‌ها است. اگر مقدار GMER کمتر یا بیشتر از یک باشد به ترتیب بیان کننده کم برآورد یا بیش برآورد مدل‌ها است [۲۹]. کن و یردلن [۳۰] در مطالعه خود بیان می‌کنند، چون روش مدل‌سازی به کمک شبکه عصبی، یک روش داده محور است و درک قبلی از روابط بین متغیرها وجود ندارد، یک تحلیل اولیه روی شرایط داده‌ها، نرمال‌سازی و به مقیاس درآوردن متغیرها برای عملکرد بهتر این نوع مدل‌ها بهتر است انجام گیرد. بنابراین با استفاده از رابطه ۱۰ داده‌ها نرمال شدند.

$$x_n = \left(0.8 * \left(\frac{(x - x_{\min})}{(x_{\max} - x_{\min})} \right) \right) + 0.1 \quad (10)$$

در رابطه بالا مقادیر x ، x_{\min} ، x_{\max} به ترتیب داده‌های نرمال شده، داده‌های ورودی و خروجی مدل، کمینه داده‌ها، بیشینه داده‌ها است.

۳- نتایج و بحث

۳-۱- ویژگی‌های عمومی

متغیرهای اندازه‌گیری شده توسط ابزار دقیق سد برای هر یک از سلول‌های فشارسنجی در جدول ۱ آورده شده‌اند. بیش‌ترین ضریب تغییرات (CV)، میانگین، انحراف معیار (SD)، میانگین در مورد متغیرهایی که به عنوان ورودی مدل هوش مصنوعی به کار رفتند در تمام سلول فشارسنجی به ترتیب زمان ساخت سد، تراز خاکریزی، تراز آب مخزن، سرعت خاکریزی و سرعت آبیگری هستند. در مورد چولگی ویژگی‌های ورودی نیز به ترتیب تراز آب مخزن، سرعت خاکریزی، سرعت آبیگری، زمان ساخت سد و تراز خاکریزی، دارای بیش‌ترین مقدارند. تراز خاکریزی به عنوان ویژگی ورودی و تنش کل خاک به عنوان خروجی مدل، دارای چولگی منفی هستند؛ به بیان دیگر، در توزیع نامتقارن آن‌ها با کشیدگی به سمت مقادیر کوچک‌تر وجود دارد. در مورد سایر ویژگی‌های ورودی، چولگی مثبت وجود دارد. به عبارت دیگر، توزیع نامتقارن در این ویژگی‌ها با کشیدگی به سمت مقادیر بالاتر وجود دارد.

در جدول بالا، F تراز خاکریزی، R تراز آبیگری، T زمان ساخت، VF سرعت خاکریزی و VR سرعت آبیگری و P تنش کل خاک است.

جدول ۱. آمار توصیفی متغیرهای اندازه‌گیری شده توسط ابزار دقیق سد

Table 1. Statistical characteristics of the measured data by accurate instruments

جدول ۱. آمار توصیفی متغیرهای اندازه‌گیری شده توسط ابزار دقیق سد

Table 1. Statistical characteristics of the measured data by accurate instruments

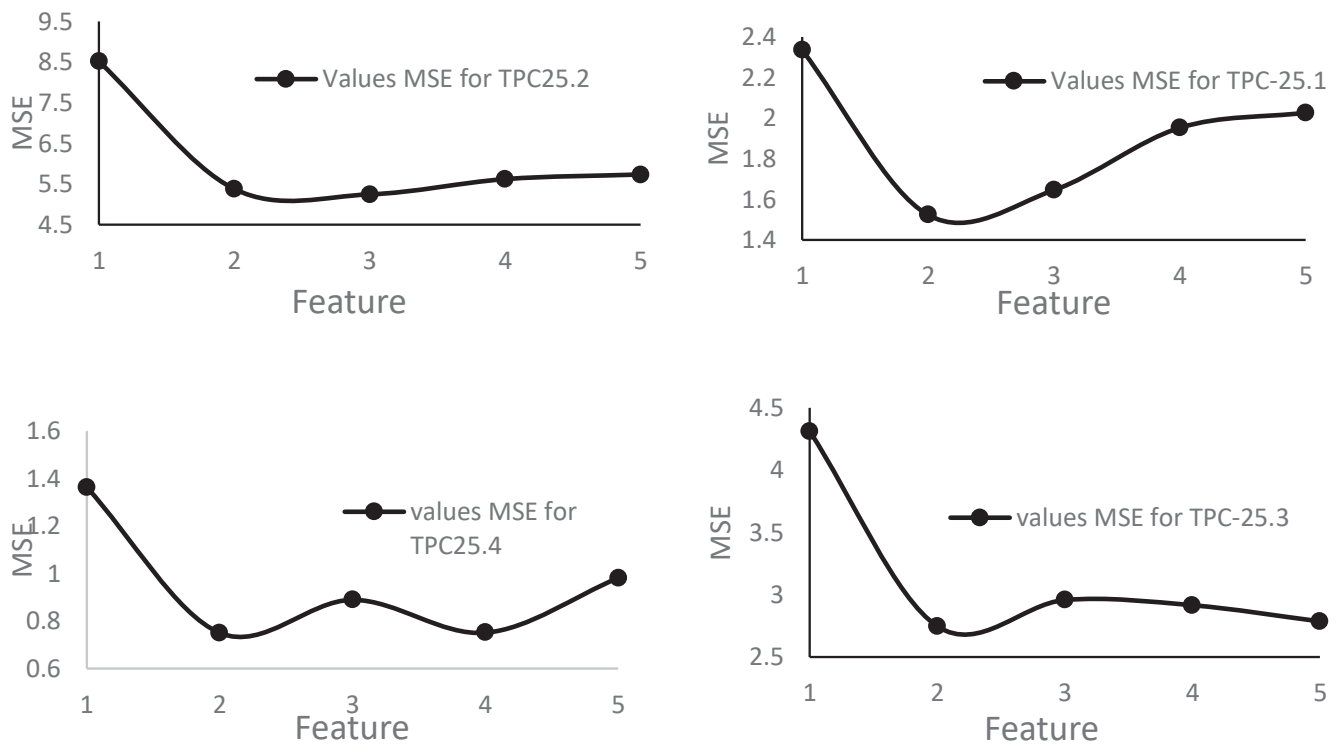
| چولگی | میانگین | SD | میانه | CV | کمینه | بیشینه | تعداد | متغیر (واحد) | سلول |
|--------|----------|---------|----------|-------|--------|--------|-------|---------------------|---------|
| -۱.۳۱۰ | ۱۸۳.۲۰ | ۳.۷۴۳ | ۱۸۵.۳۰۰ | ۱۳ | ۱۷۳ | ۱۷۶ | ۱۲۴ | F (m.a.s.l) | TPC25.1 |
| ۲.۹۷۴ | ۱۷۱.۳۵۰ | ۰.۵۴۳ | ۱۷۱.۲۳۰ | ۳ | ۱۷۱ | ۱۷۴ | ۱۲۴ | R (m.a.s.l) | |
| ۰.۰۲۱ | ۲۴۷۷.۱۳۰ | ۲۶۴.۰۹۱ | ۲۴۷۸.۱۲۰ | ۸۶۳ | ۲۰۳۲ | ۲۸۹۵ | ۱۲۴ | T (day) | |
| ۲.۵۳۶ | ۰.۰۱۱ | ۰.۰۳۱ | ۰ | ۰.۲۵۰ | -۰.۰۵۰ | ۰.۰۲۱ | ۱۲۴ | VF (m.a.s.l/day) | |
| ۲.۰۳۶ | ۰.۰۰۷ | ۰.۰۲۹ | ۰.۰۰۱ | ۰.۲۳۰ | -۰.۰۸۱ | ۰.۱۵۰ | ۱۲۴ | VR (m.a.s.l/day) | |
| -۰.۹۸۹ | ۱۵۴.۲۴۰ | ۴۱.۰۶۱ | ۱۶۷.۲۴۰ | ۱۶۶ | ۳۲ | ۱۹۸ | ۱۲۴ | P (kp) | |
| -۰.۴۲۹ | ۱۷۴.۴۶۰ | ۶.۸۳۰ | ۱۸۵.۸۰۰ | ۲۳ | ۱۷۰ | ۱۹۳ | ۱۳۴ | F (m.a.s.l) | |
| ۲.۶۱۳ | ۱۷۱.۲۹۰ | ۰.۵۶۰ | ۱۷۱.۲۰۰ | ۳ | ۱۷۰ | ۱۷۴ | ۱۳۴ | R (m.a.s.l) | |
| ۰.۰۲۰ | ۲۴۴۰.۹۹۰ | ۲۸۴.۶۴۰ | ۲۴۴۳ | ۹۳۸ | ۱۹۵۷ | ۲۸۹۵ | ۱۳۴ | T (day) | |
| ۱.۹۲۸ | ۰.۰۲۳ | ۰.۰۴۳ | ۰ | ۰.۳۰۰ | -۰.۰۶۶ | ۰.۲۳۴ | ۱۳۴ | VF (m.a.s.l/day) | |
| ۲.۱۳۱ | ۰.۰۰۶ | ۰.۰۲۸ | ۰.۰۰۱ | ۰.۲۳۰ | -۰.۰۸۱ | ۰.۱۵۰ | ۱۳۴ | VR (m.a.s.l/day) | TPC25.2 |
| -۰.۱۲۵ | ۱۴۶.۲۷۰ | ۵۹.۳۲۰ | ۱۵۹.۸۹۰ | ۱۹۵ | ۴۸ | ۲۴۲ | ۱۳۴ | P (kp) | |
| ۰.۳۴۵ | ۱۸۵.۵۱۰ | ۵.۹ | ۱۸۵.۸۰۰ | ۲۰ | ۱۷۳ | ۱۹۳ | ۱۲۴ | F (m.a.s.l) | TPC25.3 |
| ۲.۹۷۴ | ۱۷۱.۳۵۰ | ۰.۵۴۳ | ۱۷۱.۲۳۰ | ۳ | ۱۷۱ | ۱۷۴ | ۱۲۴ | R (m.a.s.l) | |
| ۰.۰۲۱ | ۲۴۷۷.۱۳۰ | ۲۶۴.۰۹۰ | ۲۴۶۸ | ۸۶۳ | ۲۰۳۲ | ۲۸۹۵ | ۱۲۴ | T (day) | |
| ۲.۰۴۶ | ۰.۰۲۲ | ۰.۰۴۲ | ۰ | ۰.۳ | -۰.۰۶۶ | ۰.۲۳۴ | ۱۲۴ | VF (m.a.s.l/day) | |
| ۲.۰۳۶ | ۰.۰۰۷ | ۰.۰۲۹ | ۰.۰۰۱ | ۰.۲۳۰ | -۰.۰۸۱ | ۰.۱۵۰ | ۱۲۴ | VR (m.a.s.l/day) | |
| -۰.۴۳۱ | ۱۷۴.۱۳۰ | ۷۴.۲۸۰ | ۱۸۰.۳۰۰ | ۲۴۴ | ۲۳ | ۲۶۷ | ۱۲۴ | P (kp) | |
| -۱.۰۸۵ | ۱۸۴.۰۲۰ | ۴.۰۶۰ | ۱۸۵.۶۵۰ | ۶ | ۱۷۳ | ۱۸۷ | ۱۲۴ | F (m.a.s.l) | |
| ۲.۹۷۴ | ۱۷۱.۳۵۰ | ۰.۵۴۳ | ۱۷۱.۲۳۰ | ۳ | ۱۷۱ | ۱۷۴ | ۱۲۴ | R (m.a.s.l) | |
| ۰.۰۲۱ | ۲۴۷۷.۱۳۰ | ۲۶۴.۰۹۰ | ۲۴۶۸ | ۸۶۳ | ۲۰۳۲ | ۲۸۹۵ | ۱۲۴ | T (day) | |
| ۲.۰۴۶ | ۰.۰۲۲ | ۰.۰۴۲ | ۰ | ۰.۳ | -۰.۰۶۶ | ۰.۲۳۵ | ۱۲۴ | VF (m.a.s.l/day) | |
| ۲.۰۳۶ | ۰.۰۰۷ | ۰.۰۲۹ | ۰.۰۰۱ | ۰.۲۳۰ | -۰.۰۸۱ | ۰.۱۵۰ | ۱۲۴ | VR (m.a.s.l/day) | TPC25.4 |
| -۱.۰۲۳ | ۹۶.۰۴۰ | ۲۳.۸۹۰ | ۱۰۳.۹۸۰ | ۱۰۲ | ۲۰ | ۱۲۲ | ۱۲۴ | P (kp) | |

ضریب تغییرات (CV)، انحراف معیار (SD)

جدول ۲. مقادیر بهینه الگوریتم PSO

Table 2. Optimal values of PSO algorithm

| سرعت اولیه ذرات | ثابت اجتماعی (C2) | ثابت شناختی (C1) | جانمایی | ثابت محلی (W) | کران پایین و بالا | تعداد جمعیت (Npop) | تعداد تکرار (max_it) |
|-------------------------------|-------------------|------------------|---------------|---------------|-------------------|--------------------|----------------------|
| به طور تصادفی بین ۰ و ۱ | ۲ | ۲ | اتصال کامل | ۱ | LB=0; UB=1 | ۱۰۰ | ۱۰۰۰ |




شکل ۴. مقادیر ویژگی‌ها در روش انتخاب ویژگی‌ها برای سلول‌های مختلف

Fig. 4. Features values in the Features selection method for different cells

از همان ابتدا به علت تأخیر در نصب، روند افزایشی دارد. نکته جالب در مورد نمودار ویژگی و خطا (شکل ۴) این است که سلول‌هایی که قبل از فیلتر و زهکش نصب شده‌اند با وجود ترازهای متفاوت نصب، دارای روند تقریباً یکسانی هستند ولی سلول TPC25.4 که بعد از فیلتر و زهکش نصب شده است، روند متفاوتی دارد که این نشان دهنده تأثیر فیلتر و زهکش بر فرآیند انتخاب ویژگی است.

به سلول TPC25.3 است که در تراز بالاتری نصب شده است. دلیل این امر احتمالاً به این خاطر است که با توجه به اینکه ساخت سد از ترازهای پایین‌تر شروع شده و به ترازهای بالاتر می‌رسد، سلول‌های نصب شده در ترازهای بالاتر دارای داده‌های کمتری هستند و تأخیر زمانی که در داده‌های ورودی وجود دارد باعث این تأثیر در نتایج می‌شود. زیرا داده‌های تراز آبدگیری و تراز خاکریزی در سلول‌هایی که در تراز پایین‌تر نصب شده‌اند در اواخر طول دوره آماری روند افزایشی دارد، ولی در سلول‌هایی که در تراز بالاتر نصب شده‌اند



شکل ۵. روند همگرایی الگوریتم PSO در سلول‌های مختلف برای ترکیب ویژگی‌های برتر

Fig. 5. Convergence of PSO algorithm in different cells for combination of superior features

واقع در پایین دست محور سد از آب نفوذی در سد است. نکته جالب در این سلول این است که ویژگی سرعت خاکریزی در این سلول تأثیر بیشتری نسبت به ویژگی تراز آب مخزن در مدل سازی تنش خاک بر خلاف سایر سلول‌ها دارد که علت این امر احتمالاً به خاطر دور بودن این سلول از آب نفوذی در سد است.

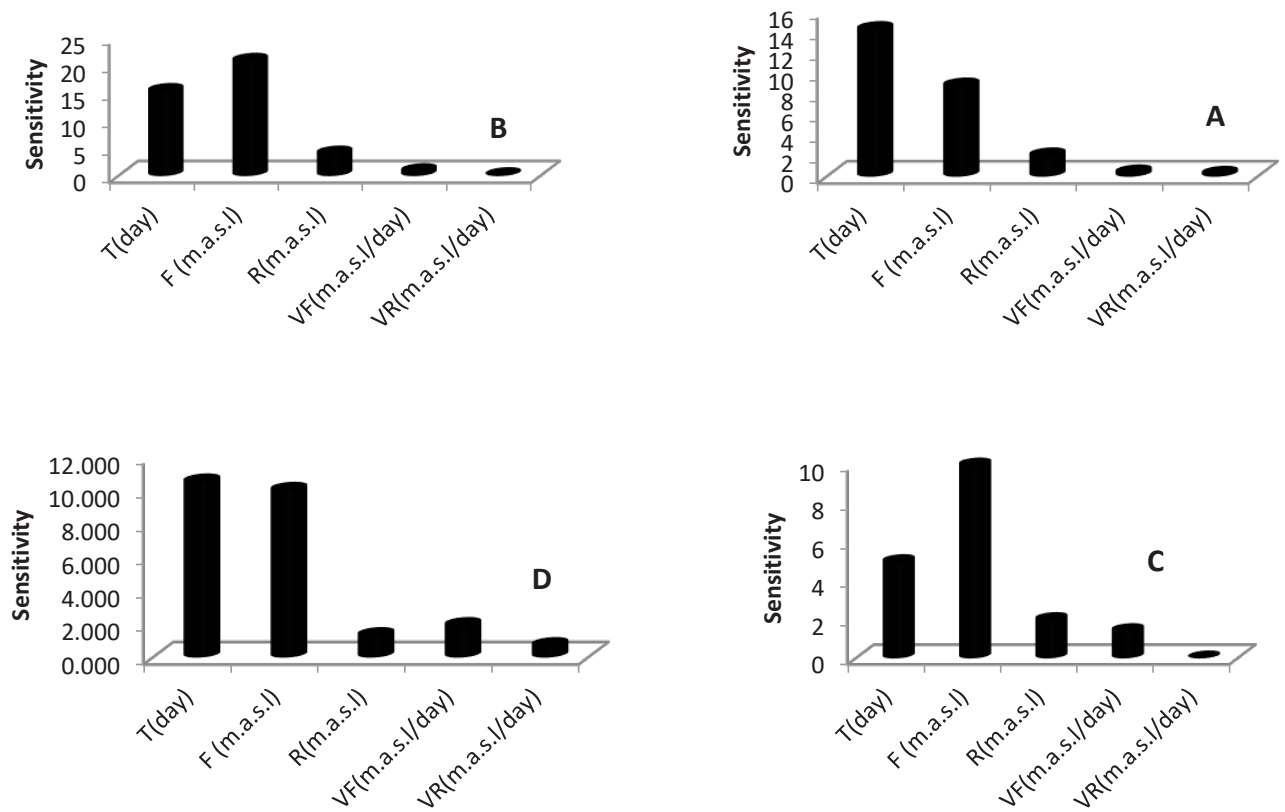
یکی از دلایلی که در اثبات تأثیر یک ویژگی بر مدل سازی متغیر هدف می‌توان ذکر کرد، تغییرپذیری آن ویژگی است. هر چه تغییرپذیری ویژگی بیشتر باشد، اثر آن روی مدل سازی متغیر هدف بیشتر خواهد بود [۵]. از آنجا که تغییرپذیری سه ویژگی تراز خاکریزی، زمان ساخت سد و تراز آب مخزن، بالا است (جدول ۱)، بنابراین نقش مؤثرتری در مدل سازی متغیر هدف تنش کل دارند.

در شکل ۶، F تراز خاکریزی، R تراز آبیگری، T زمان ساخت، VF سرعت خاکریزی و VR سرعت آبیگری است.

اگرچه سرعت خاکریزی و سرعت آبیگری بر تنش خاک تأثیرگذار است، اما نتایج نشان داد که در مقایسه با ویژگی‌های مانند تراز خاکریزی، زمان ساخت سد و تراز آب مخزن در سلول‌های نصب شده قبل از فیلتر و زهکش از اهمیت کمتری در مدل سازی تنش کل در زمان ساخت سدهای خاکی، برخوردار است. در سلول نصب شده در بعد از فیلتر و زهکش (TPC۲۵.۴) تراز آبیگری و سرعت آبیگری دارای اهمیت کمتری در مدل سازی تنش کل

۳-۳- تحلیل حساسیت

به منظور تعیین درجه اهمیت هر کدام از ویژگی‌های استخراج شده از فرایند انتخاب ویژگی، تحلیل حساسیت انجام شد [۵]. بر اساس نتایج حاصل از تحلیل حساسیت (شکل ۶)، در سلول‌های نصب شده در قسمت میانی و نزدیک به محور سد یعنی سلول‌های TPC۲۵.۲ و TPC۲۵.۳، از بین ۵ ویژگی ورودی، به ترتیب تراز خاکریزی، زمان ساخت سد، تراز آبیگری، سرعت خاکریزی و سرعت آبیگری بیش‌ترین تأثیر را در مدل سازی تنش کل خاک داراست. دلیل این تشابهات در این دو سلول احتمالاً به علت قرار گرفتن هر دو سلول در قسمت میانی سد است، که باعث شده است نتایج تقریباً یکسانی داشته باشند. در سلول TPC۲۵.۱ که در نزدیک مخزن قرار دارد نتایج نشان داد که در این سلول از بین ۵ ویژگی ورودی، به ترتیب، زمان ساخت سد، تراز خاکریزی، تراز آبیگری، سرعت خاکریزی و سرعت آبیگری بیش‌ترین تأثیر را در مدل سازی تنش کل خاک داراست. سلول TPC۲۵.۴ بعد از فیلتر و زهکش نصب شده است، در این سلول از بین ۵ ویژگی ورودی، به ترتیب، تراز خاکریزی، زمان ساخت سد، سرعت خاکریزی، تراز آبیگری و سرعت آبیگری بیش‌ترین تأثیر را در مدل سازی تنش کل خاک داراست. نتایج نشان داد که بر خلاف سه سلول قبلی تراز آبیگری و سرعت آبیگری تأثیر کمتری در مدل سازی تنش کل در این سلول دارد. علت این امر احتمالاً به خاطر قرار گرفتن این سلول بعد از فیلتر و زهکش و دور بودن این سلول



شکل ۶. تحلیل حساسیت ویژگی‌های ورودی با استفاده از روش هیل (A (TPC25.1) و B (TPC25.2) و C (TPC25.3) و D (TPC25.4))

Fig. 6. Sensitivity analysis of input features using Hill method; A (TPC25.1), B (TPC25.2), C(TPC25.3) and D (TPC25.4)

است. در سلول‌های نصب شده قبل از فیلتر و زهکش، ویژگی تراز آبیگری و در سلول نصب شده بعد از فیلتر و زهکش، ویژگی سرعت خاکریزی علاوه بر دو ویژگی فوق بر مدل‌سازی تنش کل تأثیر بیشتری دارند. بنابراین در مجموع تنش کل بیش‌ترین حساسیت را در سلول‌های نصب شده در قسمت میانی و نزدیک به محور سد به تراز خاکریزی و در سلول‌های نصب شده در قسمت‌های دورتر از محور میانی به زمان ساخت دارد. احتمالاً این امر به خاطر این است که با افزایش تراز خاکریزی مقدار سربار و حجم خاک بیشتر شده و باعث می‌شود تنش کل افزایش یابد. سلول‌های قسمت میانی و نزدیک به محور سد (TPC۲۵.۲ و TPC۲۵.۳) تغییرات مشابهی با روند بارگذاری بدنه سد دارند؛ در حالی که با دور شدن از محور سد (سلول‌های TPC۲۵.۴ و TPC۲۵.۱) به دلیل انتقال تنش‌ها به صورت مایل (چرخش اجزاء تنش) تأثیرپذیری کمتری از روند خاکریزی دارند.

در این سلول است که دلیل آن دور بودن سلول از مخزن سد و هم چنین وجود فیلتر و زهکش است که باعث می‌شود آب نفوذی زهکشی شود. دلیل تأثیر ویژگی تراز آبیگری نیز این است که با افزایش تراز آب مخزن، میزان آب در خاک افزایش بیشتری می‌یابد که این مطلب باعث افزایش تنش کل خواهد شد. ویژگی سرعت آبیگری هم به این دلیل بر مدل‌سازی تنش کل موثر است که هر چه قدر سرعت آبیگری بیشتر باشد، آب با سرعت بیشتری وارد خاک می‌شود که این امر باعث افزایش بیشتر تنش کل خواهد شد. تأثیر ویژگی‌های تراز آب مخزن (آبیگری) و سرعت آبیگری بر سلول‌های نزدیک مخزن بیشتر است و هر چه از مخزن دور شویم تأثیر این ویژگی بر مدل‌سازی تنش کل کمتر می‌شود. ویژگی سرعت خاکریزی در سلول نصب شده بعد از فیلتر و زهکش تأثیر بیشتری بر مدل‌سازی تنش کل دارد. دو ویژگی تراز خاکریزی و زمان ساخت در همه سلول‌ها دارای ضریب حساسیت بیشتر

جدول ۳. مشخصه‌های آماری خطای مربوط به سلول‌های مختلف در تخمین تنش قائم خاک در دوره آموزش و آزمون مدل ANN

3. Statistical error measures of different cells in estimating soil vertical stress in training and testing stages of ANN model

| پارامتر | آزمون | | | | | آموزش | | | | | ورودی‌ها | سلول |
|-----------|----------------|--------|--------|--------|--------|----------------|--------|--------|--------|--------|----------|---------|
| | R ² | RMSE | MAE | NS | GMER | R ² | RMSE | MAE | NS | GMER | | |
| MLP 2-2-1 | ۰/۹۹۳۹ | ۰/۰۲۰۶ | ۰/۰۱۲۱ | ۰/۴۷۲۵ | ۱/۰۰۰۷ | ۰/۹۹۸۰ | ۰/۰۱۰۵ | ۰/۰۰۸۱ | ۰/۷۹۰۲ | ۱/۰۰۰۸ | T,F | TPC25.1 |
| MLP 3-3-1 | ۰/۹۹۶۰ | ۰/۰۲۰۵ | ۰/۰۱۳۷ | ۰/۶۸۰۰ | ۰/۹۸۰۹ | ۰/۹۹۶۹ | ۰/۰۱۶۸ | ۰/۰۱۲۱ | ۰/۹۴۳۳ | ۱/۰۰۱۲ | T,F,R | TPC25.2 |
| MLP 2-2-1 | ۰/۹۹۷۹ | ۰/۰۱۲۱ | ۰/۰۰۹۶ | ۰/۶۱۴۷ | ۱/۰۰۰۷ | ۰/۹۹۸۵ | ۰/۰۱۲۷ | ۰/۰۰۸۹ | ۰/۹۰۶۱ | ۱/۰۱۸۵ | T,F | TPC25.3 |
| MLP 2-2-1 | ۰/۹۹۲۱ | ۰/۰۲۴۹ | ۰/۰۱۸۹ | ۰/۷۲۸۵ | ۰/۹۹۲۴ | ۰/۹۹۱۱ | ۰/۰۲۸۶ | ۰/۰۲۰۳ | ۰/۸۹۶۹ | ۱/۰۰۱۶ | T,F | TPC25.4 |

در جدول بالا، F تراز خاکریزی، R تراز آبیگری و T زمان ساخت است.

آزمون توابع عضویت متعدد (مثلثی، دوزنقه‌ای و گوسی)، بهترین تابع با توجه به مقدار حداقل مربعات خطاها برای هر یک از سلول‌ها انتخاب گردید. بر مبنای مراحل سعی و خطای انجام یافته در این تحقیق، تعداد توابع عضویت در هر مورد و برای هر یک از متغیرهای ورودی ۳ تا ۱۰ در نظر گرفته شد. شکل ۷ و جدول ۴ ساختار مناسب و تعداد توابع عضویت و نوع بهینه آن آورده شده است.

برای اجرای مدل GEP، در مورد مدل‌سازی تنش قائم خاک در مطالعه حاضر، ترکیبی از کلیه عملگرها نظیر جهش، برگشت، سه نوع مختلف ترانهش و سه نوع عملگر ترکیب مجدد مورد استفاده قرار گرفت. بر اساس مقایسه R² حاصل از کاربرد توابع مختلف ریاضی، بهترین تابع عملگر برای سلول‌های مختلف انتخاب گردید. جداول ۳ و ۴ مقادیر مربوط به هر یک از شاخص‌های آماری مربوط به مدل‌های مختلف تنش قائم خاک را در دوره آموزش و آزمون در تمام سلول‌های مورد مطالعه مقطع ۲۵ نشان می‌دهد. همانطور که قبلاً اشاره شد برای ارزیابی مدل‌ها از شاخص‌های آماری جذر میانگین مربعات خطا (RMSE)، ضریب تبیین (R²)، میانگین خطای مطلق (MAE)، نش-ساتکلیف (NS) و نیز میانگین هندسی نسبت خطا (GMER)، بهره برده شده است.

با بررسی این شاخص‌ها برای مدل‌های مورد مطالعه و نتایج جدول‌های ۲، ۳ و ۴ در سلول‌های مختلف ملاحظه می‌شود هر چند که اختلاف در دقت مدل‌ها بسیار ناچیز است، می‌توان گفت هر سه مدل جواب قابل قبول و نزدیک به هم داشته و قابل استفاده برای تخمین تنش کل خاک در زمان ساخت سدهای خاکی هستند. در مجموع مدلی را به عنوان مدل برتر نمی‌توان برگزید؛ زیرا هیچ‌کدام از مدل‌ها در تمام سلول‌های منتخب مدل


۳-۴- مدل‌سازی تنش کل با استفاده از ویژگی‌های برتر با ANN

در این قسمت مدل‌سازی با مدل ANN صورت پذیرفت. همه سلول‌ها با توجه به فرایند انتخاب ویژگی، به جز سلول TPC25.2 دارای دو ورودی (ویژگی) می‌باشند. همانطور که در جدول ۲ مشاهده می‌کنید با توجه به مؤلفه‌های آماری مربوط، مدل ANN در دوره آموزش و آزمون به خوبی توانسته عمل مدل‌سازی متغیر هدف (تنش کل) را انجام دهد.

همانطور که از جدول ۲ و با توجه به شاخص میانگین هندسی نسبت خطا (GMER) استنباط می‌شود، در داده‌های آموزشی همه سلول‌ها، بیش برآورد جزئی و در داده‌های آزمون در سلول‌های TPC25.1 و PC25.3، بیش برآورد جزئی و در سلول‌های TPC25.2 و TPC25.4 کم برآورد جزئی رخ داده است.

۴- مقایسه مدل ANN با ANFIS و GEP

در ادامه از مدل‌های سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) و برنامه‌نویسی بیان ژن (GEP) جهت تخمین تغییرات تنش قائم خاک در بدنه سد خاکی کبودال در طول ساخت، استفاده گردید تا معایب و مزایای هر کدام از این مدل‌ها تبیین شده و مقایسه‌ای بین مدل‌های مذکور با مدل ANN صورت گیرد. همان‌طور که مشاهده شد، با بررسی ترکیب‌های متفاوت ورودی بر اساس روش انتخاب ویژگی، سه ویژگی تراز خاکریزی و تراز آب مخزن و زمان ساخت سد، بیش‌ترین تأثیر را بر مدل ANN دارند. بنابراین از همان ویژگی‌های به کار رفته در مدل ANN برای ورودی مدل‌های ANFIS و GEP نیز استفاده گردید. در مورد مدل ANFIS از الگوریتم هیبرید آموزشی استفاده به عمل آمد و در هر مرحله، پس از



شکل ۷. ساختار ANFIS با سه ورودی (سمت راست) برای سلول TPC25.2 و دو ورودی (سمت چپ) برای سایر سلول‌ها

Fig.7. ANFIS structure with three inputs (right) for cell no.TPC25.2 and two inputs (left) for other cells

جدول ۴. مشخصه‌های آماری خطای مربوط به سلول‌های مختلف در تخمین تنش قائم خاک در دوره آموزش و آزمون مدل ANFIS

Table 4. Statistical error measures for different cells in estimating the soil vertical stress for training and testing stages in ANFIS model

| تعداد توابع عضویت | پارامتر | آزمون | | | | | آموزش | | | | | مدل ANFIS |
|-------------------|----------|---------|----------------|--------|--------|--------|--------|----------------|--------|--------|--------|-----------|
| | | MF Type | R ² | RMSE | MAE | NS | GMER | R ² | RMSE | MAE | NS | |
| ۳ | Gauss2mf | ۰/۹۹۸۰ | ۰/۰۰۸۷ | ۰/۰۰۵۹ | ۰/۹۶۶۶ | ۰/۹۹۹۶ | ۰/۹۹۹۹ | ۰/۰۰۲۳ | ۰/۰۰۱۵ | ۰/۹۸۵۹ | ۱/۰۰۰۰ | TPC25.1 |
| ۴ | Gaussmf | ۰/۹۹۵۵ | ۰/۰۲۲۹ | ۰/۰۱۱۸ | ۰/۹۶۶۸ | ۰/۰۱۲۰ | ۰/۹۹۹۷ | ۰/۰۰۵۹ | ۰/۰۰۳۲ | ۰/۹۸۵۶ | ۰/۰۰۱۰ | TPC25.2 |
| ۳ | psagmf | ۰/۹۹۷۲ | ۰/۰۱۶۹ | ۰/۰۱۰۹ | ۰/۹۶۰۵ | ۰/۹۹۲۶ | ۰/۹۹۹۹ | ۰/۰۰۲۴ | ۰/۰۰۱۶ | ۰/۹۸۵۲ | ۰/۹۹۹۸ | TPC25.3 |
| ۳ | Gaussmf | ۰/۹۹۵۵ | ۰/۰۲۲۷ | ۰/۰۱۸۵ | ۰/۹۶۶۶ | ۰/۹۹۱۱ | ۰/۹۹۹۷ | ۰/۰۰۴۵ | ۰/۰۰۳۲ | ۰/۹۸۵۷ | ۰۰۰۰/۱ | TPC25.4 |

، RMSE ، MAE و NS به ترتیب برابر مقادیر ۰/۹۹۷۲، ۰/۰۱۶۹، ۰/۰۱۰۹ و ۰/۹۶۰۵ مدل ANFIS در دوره آزمون دارای عملکرد بهتری نسبت به دو مدل دیگر دارد. در سلول TPC25.2 با توجه به شاخص‌های آماری R² ، RMSE ، MAE و NS به ترتیب برابر مقادیر ۰/۹۹۵۵، ۰/۰۲۲۷، ۰/۰۱۸۵ و ۰/۹۶۶۶ مدل ANFIS در دوره آزمون دارای عملکرد بهتری نسبت به دو مدل دیگر دارد. از سوی دیگر مدل‌های مبتنی بر برنامه‌ریزی ژنتیک دارای برتری نسبی در مقایسه با سایر مدل‌ها می‌باشند؛ زیرا برنامه‌ریزی ژنتیک قادر به ارائه معادله تقریبی موجود بین ورودی‌ها و خروجی مدل است.

برتر نیستند. در مورد مدل ANFIS، با توجه به امکان دست‌یابی به توابع عضویت پس از واسنجی، می‌تواند در فهم تأثیر ویژگی‌های موثر در تنش قائم خاک سد خاکی و تهیه مدل مفهومی موثر باشد. در سلول TPC ۲۵.۱ با توجه به جداول ۳، ۴ و ۵ شاخص‌های آماری R² ، RMSE ، MAE و NS به ترتیب برابر مقادیر ۰/۹۹۸۰، ۰/۰۰۷۸، ۰/۰۰۵۹ و ۰/۹۶۶۶ مدل ANFIS در دوره آزمون دارای عملکرد بهتری نسبت به دو مدل دیگر دارد. در سلول TPC25.2 با توجه به شاخص‌های آماری R² ، RMSE ، MAE و NS به ترتیب برابر مقادیر ۰/۹۹۵۵، ۰/۰۲۲۹، ۰/۰۱۱۸ و ۰/۹۶۶۸ مدل ANFIS در دوره آزمون دارای عملکرد بهتری نسبت به دو مدل دیگر دارد. در سلول TPC25.2 با توجه به شاخص‌های آماری R²

جدول ۵. مشخصه‌های آماری خطای مربوط به سلول‌های مختلف در تخمین تنش قائم خاک در دوره آموزش و آزمون مدل GEP

Table 5. Statistical error measures for different cells in estimating the soil vertical stress for training and testing stages in GEP model

| آزمون | | | | | آموزش | | | | | مدل GEP |
|----------------|--------|--------|--------|--------|----------------|--------|--------|--------|--------|---------|
| R ² | RMSE | MAE | NS | GMER | R ² | RMSE | MAE | NS | GMER | |
| ۰/۹۹۵۰ | ۰/۰۱۳۵ | ۰/۰۱۰۹ | ۰/۹۶۸۶ | ۰/۹۹۹۹ | ۰/۹۹۴۵ | ۰/۰۱۷۸ | ۰/۰۱۲۲ | ۰/۹۸۵۹ | ۱/۰۰۰۶ | TPC25.1 |
| ۰/۹۷۰۲ | ۰/۰۵۲۷ | ۰/۰۴۳۴ | ۰/۹۶۳۳ | ۱/۰۴۱۰ | ۰/۹۶۴۲ | ۰/۰۵۷۴ | ۰/۰۴۵۳ | ۰/۹۸۴۴ | ۱/۰۵۳۲ | TPC25.2 |
| ۰/۹۹۷۶ | ۰/۰۱۷۲ | ۰/۰۰۹۵ | ۰/۹۶۰۵ | ۱/۰۲۴۱ | ۰/۹۹۷۰ | ۰/۰۱۸۵ | ۰/۰۱۱۴ | ۰/۹۸۵۱ | ۰/۹۹۵۵ | TPC25.3 |
| ۰/۹۸۳۲ | ۰/۰۴۳۷ | ۰/۰۳۲۲ | ۰/۹۶۶۶ | ۰/۸۶۵۵ | ۰/۹۸۱۱ | ۰/۰۳۴۶ | ۰/۰۲۷۵ | ۰/۹۸۵۸ | ۱/۰۰۰۲ | TPC25.4 |

جدول ۶. روابط حاصل شده از هر زیر درخت برای پیش‌بینی تنش قائم خاک برای سلول‌های مختلف

Table 6. Relationships obtained from each subtree to predict soil vertical stress for different cells

| R ² | روابط حاصل شده از هر زیر درخت | سلول |
|----------------|---|---------|
| ۰/۹۹ | $P = \frac{(((F) - (T)^5))^3}{(1.0/(1.28)) + (-4.23)) + \frac{((((((T)^5) * (R)) + (-0.91)^3)^2)}{6.56} + (F)}$ | TPC25.1 |
| ۰/۹۷ | $P = (T) + ((R) / -9.38) + ((F) / -6.87)^2$ | TPC25.2 |
| ۰/۹۹ | $P = \frac{(((F)^4 - (T))^2)^2 + (((R) - (F))^5)^5}{(F)}$ | TPC25.3 |
| ۰/۹۸ | $P = ((F) - (R)^5) + ((F) - (T))^4 + ((R)^5)$ | TPC25.4 |

۵- نتیجه‌گیری

از بین پنج ویژگی شامل تراز خاکریزی، زمان ساخت سد، تراز مخزن (آبگیری)، سرعت آبگیری و سرعت خاکریزی به عنوان ورودی مدل هیبریدی PSO-ANN تراز خاکریزی، زمان ساخت سد و تراز آبگیری مؤثرترین ویژگی‌ها در مدل‌سازی تنش کل در سلول‌های منتخب بودند و سرعت آبگیری و سرعت خاکریزی تأثیری کمتری در مدل‌سازی تنش کل دارند. نتایج نشان داد که افزایش تعداد ویژگی‌ها در مدل ANN باعث

بر این اساس، معادله مربوط به تخمین تنش قائم خاک (P) در سلول‌های مقطع ۲۵ به صورت جدول ۵ خواهد بود. با این حال، این مدل در سلول‌های TPC25.۲ و TPC25.۴ با توجه به شاخص‌های آماری دارای عملکرد ضعیف‌تری در پیش‌بینی تنش کل خاک نسبت به دو مدل دیگر است. در جدول ۶، F تراز خاکریزی، R تراز آبگیری، T زمان ساخت و P تنش خاک است.

Investigation of the Structure of the Dam Body during Construction and its Comparison with the Analytical Results Using PLAXIS Software (the Case Study of Kaboodvall Dam). JWSS, 22(4), 155-171. (In Persian)

- [5] M.A. Zomoredian, H. Chochi. (2013). Numerical analysis of soil-gravel dam behavior during construction and first dewatering (Case study: Masjed Soleiman Dam). JWSS, 16(62), 229-242. (In Persian)
- [6] M. Vafaeian. (2015). Earth dams & rockfill dams. Isfahan: Arkan Danesh. 464p.
- [7] M. Komasi, B. Beiranvand. (2019). Study of Hydraulic Failure Mechanism in Core of Earth Dam (A Case Study: Taj-Amir Norabad Dam). Tectonics Journal, 9(3), 57-69(In Persian).
- [8] H. Hakimi Khansar, S.H. Golmai, M. Sheydaiyan. (2015). Kaboodval behavior earthen dam during construction of the finite element method with software PLAXIS and compared with data from instrumentation. Journal of water science engineering, 5(11), 77-92. (In Persian)
- [9] G. Tayfure, D. Swiatek, A. Wita, VP. Singh. (2005). Case study: finite element method and artificial neural network models for flow through Jeziorsko earthfill dam in Poland. Journal of Hydraulic Engineering, 131(6), 431-440.
- [10] V. Nourani. (2015). Basics of hydroinformatics ANFIS model for multi-station modelling of rainfall-runoff process. Journal of Hydrology, 490, 41-55(In Persian).
- [11] E. Sharghi, V. Norani, N. Behfar. (2020). Implementation of Data Jittering Technique for Seepage Analysis of Earth fill Dam Using Ensemble of AI Models. Water and Soil Science- University of Tabriz, 30(1), 29-41. (In Persian)
- [12] K. Wu, C. Soci, P.P. Shum, I. Zheludev. (2014). Computing matrix inversion with optical networks. Optics Express, 22(1), 295-304.
- [13] G. Cucci, G. Lacolla, M. Pagliai and N. Vignozzi. (2015). Effect of reclamation on the structure of silty-clay soils. International Agrophysics Journal, 29, 23-30.

افزایش دقت مدل سازی نشد، بنابراین کاهش ویژگی های ورودی به دلیل کاهش هزینه و زمان انجام پژوهش مقرون به صرفه تر است. همچنین خطای مدل سازی در سلول نصب شده بعد از فیلتر و زهکش از سایر سلول ها کمتر است. بیشترین خطا، مربوط به سلولی بود که در تراز بالاتری نصب شده است. ویژگی هایی که از الگوریتم هیبریدی PSO-ANN به عنوان ویژگی های مؤثر بر تنش خاک در هر کدام از سلول ها به دست آمد، قابل تفسیر و منطقی هستند. به علاوه، نتایج تحلیل حساسیت در مدل ANN نشان داد تراز خاکریزی و زمان ساخت سد با بالاترین ضریب حساسیت، مهم ترین ویژگی در مدل سازی تنش کل در اکثر سلول های منتخب به حساب می آید. موقعیت نصب سلول در قبل و بعد از فیلتر و زهکش و همچنین تراز نصب سلول، در مدل سازی تنش کل خاک و انتخاب ویژگی های ورودی موثر است. مقایسه بین مدل های سیستم استنتاج عصبی- فازی تطبیقی (ANFIS)، برنامه نویسی بیان ژن (GEP) و شبکه عصبی مصنوعی با شاخص های آماری، نشان داد که مدل ANFIS در مورد سلول هایی که دارای پراکندگی داده های ورودی بیشتری بودند دارای توانایی بیشتری در مدل سازی است. در نهایت با استفاده از مدل GEP، برای هر سلول رابطه ریاضی بر اساس ویژگی های برتر ارائه شد. در پایان می توان گفت که فرآیند واسنجی و تأیید مدل های شبکه عصبی مصنوعی، سیستم استنتاج عصبی- فازی تطبیقی و برنامه ریزی بیان ژن نسبت به مدل عددی کم هزینه تر و مستلزم صرف زمان کمتری است.

پیشنهاد می شود برای سایر کمیت های سد خاکی مثل نشست و تراوش و فشار آب حفره ای نیز مدل سازی با ویژگی های پیشنهادی انجام شود.

منابع

- [1] V. Nourani, E. Sharghi, MH. Aminfar. (2012). Integrated ANN model for earthfill dams seepage analysis: Sattarkhan dam in Iran. Artificial Intelligence Research, 1(2), 22-37. (In Persian)
- [2] A. Ebrahimzadeh, M. Zarghami and V. Nourani. (2019). Evaluation of Earth Dam Overtopping Risk by System Dynamics, Monte-Carlo Simulation and Latin Hypercube Sampling Methods (Case Study: Hajilarchay Dam, Iran). Iran-Water Resources, 15(1), 14-31. (In Persian)
- [3] M. Vafaeian. (2015). Earth dams & rockfill dams. Isfahan: Arkan Danesh. 464p.
- [4] F. Salmasi, H. Hakimi Khansar B. Norani, (2019).

- Effect of Wind Units' Generation. Scientific Journal of Computational Intelligence in Electrical Engineering, 5(4), 105-122. (In Persian)
- [23] M. C. Hill. (1998). Methods and Guidelines for Effective Model Calibration. U.S. Geological Survey Water.
- [24] JSR. Jang, C.T. Sun, E. Mizutani. (1997). Neurofuzzy and Software Computing: a Computational Approach to Learning and Machine Intelligence. New Jersey. Prentice-Hall.
- [25] V. Nourani, o. Kisi, M. Komasi. (2011). Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. Journal of Hydrology, 402, 41-59. (In Persian)
- [26] M. Kia. (2012). Soft computing in Matlab. ehan: Kian Publication.
- [27] C. Ferreira, (2001). Gene expression programming: a new adaptive algorithm for solving problems. 13, 87-129.
- [28] M. Nouri, and F. Salmasi. (2017). Predicting Seepage of Earth Dams using Artificial Intelligence Techniques. Irrigation Sciences and Engineering (JISE), 42(1), p. 83-97. (In Persian)
- [29] F. AmiriMijan, H. Shirani, I. Esfandiarpour1, A. Besalatpour and H. Shekofteh. (2019). Identifying the Determinant Factors Influencing S Index in Calcareous. Journal of Water and Soil Science, 23(3), 381-394 (In Persian).
- [30] I. Can, I.C. Yerdelen. (2007). Stochastic modeling of Karasu River (Turkey) using the methods of Artificial Neural Networks. Hydrology Days, 138-144.
- [14] G. Chandrashekar, and F. Sahin. (2014). A survey on feature selection methods. Computers and Electrical, 40, 16-28.
- [15] V. Rankovic, N. Grujovic, D. Divac, N. Milivojevic. (2014). Development of support vector regression. Structural Safety, 48, 33-39.
- [16] A. Novakovic, V. Rankovic, N. Grujovic, D. Divac, N. Milivojevic. (2014). Development of neuro-fuzzy model for dam seepage analysis. Annals of the Faculty of Engineering Hunedoara, 12(2), 133-136.
- [17] V. Nourani, and A. Babakhani. (2013). Integration of Artificial Neural Networks with Radial Basis Function Interpolation in Earthfill Dam Seepage Modeling. Journal of Computing in Civil Engineering, 27(1), pp.183-195. (In Persian)
- [18] F. Salmasi, H. Hakimi Khansar. (2020). Simulation of behavior the Kabudval Dam during construction with 3D numerical modeling. Amirkabir Journal of Civil Engineering, doi: 10.22060/ceej.2020.18172.6790. (In Persian)
- [19] Regional Water Company of Golestan. (2013). Reporting the Behavior of Kabudwal Dam Golestan. Golestan: Kabudwal Dam Behavior Report. 32-52.
- [20] J. Kennedy. (2010). Particle Swarm Optimization. Encyclopedia of Machine Learning, 760-766.
- [21] V. Kumar, and S. Minz. (2014). Feature selection, a literature review. Smart Computing Review, 4(3), 211-229.
- [22] M. R. Aghaebrahimi, H. Taherian, I. Nazer-Kakhki, M. Farshad, S. R. Goldani. (2014). Short Term Price Forecasting in Electricity Market Considering the

چگونه به این مقاله ارجاع دهیم

H. Hakimi Khansar, J. Parsa, A. Hosseinzadeh Dalir, J. Shiri, Simulation of soil stress in earth dams using artificial intelligence models and determination of effective features, Amirkabir J. Civil Eng., 54(1) (2022) 247-262.

DOI: 10.22060/ceej.2021.18682.6925

