

## مقاله پژوهشی

# شبیه‌سازی فشار آب حفره‌ای در بدنه سدهای خاکی حین ساخت با ترکیب شبکه عصبی مصنوعی و الگوریتم‌های فرا ابتکاری

حسین حکیمی خانسر<sup>۱\*</sup>، علی حسین زاده دلیر<sup>۲</sup>، جواد پارسا<sup>۳</sup>، جلال شیری<sup>۴</sup>

تاریخ دریافت: ۱۳۹۹/۰۶/۱۸ تاریخ پذیرش: ۱۴۰۰/۰۳/۱۸

- ۱- دانشجوی دکترا، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
  - ۲- استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
  - ۳- استادیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
  - ۴- دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
- \*مسئول مکاتبات، پست الکترونیک: hakimi1904@yahoo.com

## چکیده

پیش‌بینی دقیق فشار آب حفره‌ای در بدنه سدهای خاکی حین ساخت، یکی از مهم‌ترین عوامل در مدیریت پایداری سدهای خاکی است. در این تحقیق با استفاده از سه مدل متفاوت شبکه عصبی تکاملی شامل شبکه عصبی پرسپترون چند لایه با الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و الگوریتم رقابت استعماری برای تخمین فشار آب حفره‌ای در بدنه سدهای خاکی کبودال استان گلستان در زمان ساخت مورد مطالعه و مقایسه قرار گرفته است. پنج ویژگی شامل تراز خاک ریزی، زمان ساخت سد، تراز مخزن (آبگیری)، سرعت آبگیری و سرعت خاک ریزی در طول دوره آماری ۱۳۸۸-۱۳۹۹ یا ۴ ساله به عنوان ورودی مدل هیبریدی در پیزومتر EP19.7 انتخاب شدند. ترکیب ورودی‌ها با استفاده از روش انتخاب ویژگی و هیبرید الگوریتم چرخه آب-شبکه عصبی مصنوعی (WCA-ANN) به دست آمده است. با اجرای الگوریتم هیبریدی و آنالیز حساسیت و روش انتخاب ویژگی، تراز خاک ریزی، زمان ساخت سد، تراز آب‌گیری و سرعت آبگیری به عنوان چهار ورودی برتر انتخاب شدند زیرا ترکیب این ۴ ویژگی با مقدار MSE برابر ۱/۱۵۸۷ کمترین خطا را دار بوده است. در این مطالعه وزن‌های شبکه عصبی به کمک سه الگوریتم فرا ابتکاری مذکور به منظور افزایش کارایی بهینه‌شده است. در حالت کلی با توجه به شاخص‌های آماری، نتایج حاکی از دقت قابل‌قبول هر سه مدل هیبریدی است. از لحاظ اولویت نیز مدل هیبرید ANN-GA با بیش‌ترین دقت و کمترین خطا و مقادیر  $R^2$ ، RMSE و MAE به ترتیب برابر با ۰/۹۷۷۳، ۰/۰۴۵۷ و ۰/۰۳۹۹ در اولویت اول و مدل‌های هیبریدی ANN-PSO و ANN-ICA به ترتیب در اولویت‌های بعدی قرار گرفتند.

واژه‌های کلیدی: الگوریتم چرخه آب، الگوریتم ژنتیک، سد خاکی، شبکه عصبی مصنوعی، فشار آب حفره‌ای

## Simulation of Pore Water Pressure in the Body of Earth Dams During Construction by Combining Artificial Neural Network and Meta-Heuristic Algorithms

H Hakimi Khansar<sup>1\*</sup>, A Hosseinzadeh Dalir<sup>2</sup>, J Parsa<sup>3</sup>, J Shiri<sup>4</sup>

Received: September 8, 2020

Accepted: June 8, 2021

1-Ph. D Candidate, Dept. of Water Engineering, University of Tabriz, Iran

2- Prof., Dept. of Water Engineering, University of Tabriz, Iran

3- Assist. Prof., Dept. of Water Engineering, University of Tabriz, Iran

4- Assoc. Prof., Dept. of Water Engineering, University of Tabriz, Iran

\*Corresponding Author, Email: hakimi1904@yahoo.com

### Abstract

Accurate prediction of pore water pressure in the body of earth dams during construction is one of the most important factors in managing the stability of earth dams. In this study, using three different evolutionary neural network models including multilayer perceptron neural network with genetic algorithm, particle swarm optimization and Imperialist Competitive algorithm for estimating the pore water pressure in the body of Kabudwal earth dam at the time of construction, has been studied. Five features including fill level, construction time, reservoir level, impounding rate and fill speed during the 4-year statistical period were selected as the input of the hybrid model in piezometer EP19.7. The composition of the inputs was obtained using the feature selection method and the hybrid water cycle algorithm-artificial neural network. By performing hybrid algorithm and sensitivity analysis and feature selection method, fill level, construction time, reservoir level and dewatering speed were selected as the top four inputs, because the combination of these four features with MSE value of 1.1587 had the least error. In this study, artificial neural network weights are optimized to increase efficiency using the above three meta-heuristic algorithms. In general, according to statistical indicators, the results indicate acceptable accuracy of all three hybrid models. In terms of priority, the ANN-GA hybrid model with the highest accuracy and minimum error and values of  $R^2$ , RMSE and MAE are equal to 0.9773, 0.0457 and 0.0399, respectively, is first priority and ANN-PSO and ANN-ICA hybrid models were given the next priorities, respectively.

**Keywords:** Artificial neural network, Earth dam, Genetic algorithm, Pore water pressure, Water cycle algorithm.

## مقدمه

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. سدها و مخازن ذخیره آب نقشی اساسی در توسعه مسائل اقتصادی و تأمین آب در کشور دارند (ابراهیم‌زاده و همکاران ۲۰۱۹، نورانی و همکاران ۲۰۱۲). سدهای خاکی در بین انواع مختلف سدها به علت صرفه‌های اقتصادی، آسانی در اجرا، در دسترس بودن مصالح اجرائیه و عملکرد سازه‌ای اهمیت ویژه‌ای دارند (وفائیان ۲۰۱۵). ابزار گذاری در زمان ساخت برای اطمینان از ایمنی، حداقل نمودن هزینه‌های ساخت، کنترل روش و برنامه ساخت، فراهم نمودن محافظت قانونی و فراهم نمودن اطلاعات برای اندازه‌گیری کمیت‌ها مورد استفاده قرار می‌گیرد (سلماسی و همکاران ۲۰۱۹). فشار آب حفره‌ای در بدنه سد خاکی در زمان ساخت به عواملی مثل مدت زمان ساخت سد، تراز و سرعت خاک ریزی، تراز و سرعت آب گیری و ... بستگی دارد که توزیع آن در هر پروژه تصادفی است؛ بنابراین با توجه به پیچیدگی و وجود عدم قطعیت‌های زیاد در این پدیده، به‌کارگیری مدل‌های هوش مصنوعی و جعبه سیاه که ورودی و خروجی مشاهداتی را دریافت نموده و فرایند مورد نظر را تخمین می‌زنند، می‌تواند در بهبود مدل‌سازی این‌گونه پدیده مؤثر باشد (تایفور و همکاران ۲۰۰۵، نورانی و همکاران ۲۰۱۲). امروزه به دلیل گسترش دانش و پیچیده‌تر شدن تصمیم‌گیری، استفاده از دانش‌های نوین از جمله هوش مصنوعی اهمیت بیشتری پیدا کرده است. مدل‌های هوش مصنوعی حاصل تلاش‌های جدید علمی است که مدل‌سازی، تحلیل و در نهایت کنترل سیستم‌های پیچیده را با سهولت و موفقیت زیادتری امکان‌پذیر می‌سازند (نورانی ۲۰۱۲). مدل‌های هوش مصنوعی روش‌هایی مؤثر برای بررسی و مدل‌سازی مقادیر زیادی از داده‌های دینامیک، غیرخطی و دارای خطا ارائه می‌دهند

(شرقی و همکاران ۲۰۲۰). فرایند انتخاب ویژگی برای دو حالت تخمین و طبقه‌بندی ویژگی‌ها کاربرد دارد (ویو و همکاران ۲۰۱۴). تخمین زیرمجموعه همیشه نظارت شده است، درحالی‌که طبقه‌بندی ویژگی‌ها را می‌توان نظارت شده و یا در برخی موارد غیر نظارت شده انجام داد (سوکای و همکاران ۲۰۱۵). با به کار بردن تکنیک‌های انتخاب ویژگی می‌توان محاسبات ضروری و دقت پیش‌بینی را بهبود بخشید و زمان اجرای محاسبات را کاهش داد (چنراشکار و همکاران ۲۰۱۴).

رانوکویچ و همکاران ۲۰۱۴، رفتار یک سد بتنی (فشار آب حفره‌ای) را با استفاده از رگرسیون بردار پشتیبان مدل‌سازی کردند که نتایج بیانگر این بود که مدل‌های محاسبات نرم نتایج دقیقی را ارائه می‌کند. نوکویچ و همکاران (۲۰۱۴) از یک مدل مرحله‌ی-عصبی برای تخمین هد پیزومتریک سد Iron Gate2 استفاده کردند که مقایسه مقادیر پیش‌بینی‌شده توسط مدل شناسایی بر اساس SVR (مدل رگرسیونی ماشین بردار پشتیبان) با داده‌های تجربی حاکی از آن بود که مدل شناسایی SVR نتایج دقیقی ارائه می‌کند. (نورانی و همکاران ۲۰۱۲) برای بررسی هد پیزومتریک 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 FEM مقایسه کردند و به این نتیجه رسیدند که مدل ANN می‌تواند جایگزین نسبتاً مناسبی برای مدل عددی یا FEM باشد. تایفو و همکاران ۲۰۰۵، جریان داخل سد دی در لهستان را به روش المان محدود و شبکه عصبی بررسی کردند. آن‌ها سطح آب در بالادست و پایین‌دست سد را به عنوان ورودی و سطح آب در داخل پیزومتر را به عنوان خروجی مدل عصبی قرار دادند. این محققین نتایج حاصل از مدل‌سازی شبکه عصبی را دقیق‌تر از مدل‌سازی توسط المان 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 و باباخانی

سد کبودال ( قره‌سو زرینگل) در استان گلستان در شمال شرق ایران، در ۴۰ کیلومتری شرق گرگان و در اطراف شهر علی‌آباد و واقع در مسیر گرگان - مشهد قرار دارد. این سد 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 قرار دارد. 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 (بی نام ۲۰۱۳). جهت انجام این تحقیق از داده‌های ابزار دقیق مربوط به مقطع ۱۹ سد کبودال، استفاده شده است. این داده ها طول دوره آماری ۴ ساله دارند و از شرکت آب منطقه‌ای استان گلستان دریافت شده است. در این مقطع از پیرومتر EP19.7 نصب‌شده در بدنه سد و نزدیک مخزن استفاده گردیده است (بی نام ۲۰۱۳). جا نمایی این پیرومتر در شکل ۱ مشاهده می‌شود.

#### الگوریتم بهینه‌سازی چرخه آب (WCA)

مانند همه الگوریتم‌های فرا ابتکاری، الگوریتم چرخه آب نیز با جمعیت اولیه ( اصطلاح قطرات باران ) شروع می‌شود. در ابتدا، فرض بر این است که باران یا دیگر انواع بارش وجود دارند. بهترین فرد (بهترین قطره‌ی آب) به عنوان دریا انتخاب می‌گردد. سپس، برخی از قطرات باران خوب به عنوان رود و مابقی قطرات باران به عنوان نهرها در نظر گرفته می‌شوند که به طرف رودخانه‌ها و دریا جریان دارند.

۲۰۱۳، برای مدل‌سازی نشت از سدها، از ادغام شبکه مصنوعی با روش شبکه با تابع پایه‌ی شعاعی (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 ۲۰۲۰، به تخمین رفتار سد زرینگل در حین ساخت با مدل‌سازی عددی سه بعدی پرداخته و مقادیر حاصل از شبیه‌سازی عددی با تحلیل برگشتی با مقادیر نظیر داده‌های ابزار دقیق سد مقایسه کردند. نتایج نشان داد که بیشینه افزایش فشار آب حفره‌ای، تنش، نشست و جابجایی افقی در بخش مرکزی اتفاق افتاده و مقدار آن در محور و بخش میانی سد بیشتر از طرفین آن است. (کماسی و بیرانوند ۲۰۲۰) 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 از معیار ضریب تعیین استفاده شد که نتایج همخوانی حدود ۸۵ درصدی بین داده‌های مشاهداتی و پیش‌بینی شده را نشان داد.

در پژوهش حاضر از الگوریتم چرخه‌ی آب (WCA) به عنوان یکی از روش‌های فرا ابتکاری به منظور انتخاب ویژگی ( انتخاب بهترین ترکیب از ویژگی‌های ورودی) در مدل شبکه عصبی مصنوعی استفاده شده است. همچنین از آن جا که بر اساس منابع مطالعاتی، تاکنون پژوهشی در خصوص تخمین فشار آب حفره‌ای در زمان ساخت سدهای خاکی با الگوریتم‌های هیبریدی ANN-PSO، ANN-ICA و ANN-GA انجام نشده است، در این تحقیق ورودی‌های جدید در مدل‌سازی هوش مصنوعی برای این منظور پیشنهاد گردید و کارایی مدل‌های هیبریدی فوق مورد مقایسه و مطالعه قرار گرفته است.

#### مواد و روش‌ها

#### سد مورد مطالعه

رودخانه‌ها و یا به طور مستقیم به دریا بریزند) با استفاده از رابطه‌ی ۵ محاسبه می‌شوند.

$$N_{SR} = \text{Number of Rivers} + \hat{I}^{Sea} \quad [4]$$

$$N_{Raindrop} = N_{pop} - N_{SR} \quad [5]$$

برای تعیین یا اختصاص قطرات باران به رودها و دریا، بسته به شدت جریان از رابطه‌ی ۶ استفاده خواهد شد:

$$NS_n = \text{round} \left\{ \left| \frac{Cost_n}{\sum_{i=1}^{N_{SR}} Cost_i} \right| \times N_{Var} \right\}, n = 1, 2, 3 \dots N_{SR} \quad [6]$$

که در آن،  $NS_n$  تعدادی از نهرهایی است که به رودهای خاص و یا دریا می‌ریزند. یک نهر جریان تا رسیدن به رودخانه در امتداد خط اتصال بین آن‌ها با استفاده از یک فاصله، که به طور تصادفی انتخاب شده، جریان می‌یابد که این فاصله با رابطه‌ی زیر مشخص می‌شود.

$$X \in (0, c \times d), c > 1 \quad [7]$$


که در آن  $c$  مقداری بین یک و دو (نزدیک به دو) دارد و بهترین مقدار برای  $c$  عدد ۲ است (اسکندر و همکاران ۲۰۱۲).

$d$  فاصله‌ی فعلی بین نهر و رودخانه است. مقدار  $X$  در رابطه ۷ متناظر با یک عدد تصادفی توزیع شده (یکنواخت و یا ممکن است هر توزیع مناسب دیگر) بین صفر و  $(c \times d)$  است. موقعیت جدید نهرها و رودخانه‌ها را می‌توان روابط زیر به دست آورد:

$$X_{Stream}^{i+1} = X_{Stream}^i + rand \times C \times (X_{River}^i - X_{Stream}^i) \quad [8]$$

$$X_{River}^{i+1} = X_{River}^i + rand \times C \times (X_{Sea}^i - X_{River}^i) \quad [9]$$

در این روابط،  $rand$  یک عدد تصادفی یکنواخت توزیع شده بین صفر و یک است. اگر راه حل ارائه شده به وسیله‌ی یک نهر، بهتر از رودخانه متصل به آن باشد، موقعیت رودخانه و نهر باهم عوض می‌شود. این جابه‌جایی می‌تواند برای رودخانه‌ها و دریا نیز اتفاق بیفتد. یکی از مهم‌ترین عواملی که از همگرایی سریع



شکل ۱: مقطع تیپ و جا نمایی ابزار دقیق نصب شده در مقطع عرضی شماره ۱۹.

در الگوریتم GA و PSO اصطلاحاً چنین آرایه‌ای به ترتیب کروموزوم و موقعیت ذرات هستند. در یک مسئله‌ی بهینه‌سازی چندبعدی، یک قطره باران، آرایه‌ای به شکل  $1 * N_{Var}$  است. این آرایه با رابطه ۱ تعریف می‌شود:

$$Raindrop = [X_1, X_2, X_3, \dots, X_{N_{Var}}] \quad [1]$$

که در آن،  $X_1$  تا  $X_{N_{Var}}$  متغیرهای تصمیم هستند. در ابتدا، یک نمونه از ماتریس قطرات باران به اندازه‌ی  $N_{POP} * N_{Var}$  به طور تصادفی ایجاد می‌شود:

$$\text{Population Raindrop} = \begin{bmatrix} Raindrop1 \\ Raindrop2 \\ \vdots \\ Raindrop_{N_{pop}} \end{bmatrix} = \begin{bmatrix} X_1^1 & X_2^1 & \dots & X_{N_{Var}}^1 \\ \vdots & \vdots & \dots & \vdots \\ X_1^{N_{pop}} & X_2^{N_{pop}} & \dots & X_{N_{Var}}^{N_{pop}} \end{bmatrix} \quad [2]$$

که  $N_{POP}$  و  $N_{Var}$  به ترتیب تعداد قطرات باران (جمعیت اولیه) و تعداد متغیرهای طراحی است. مقادیر تابع هدف ( $C$ ) از رابطه‌ی زیر به دست خواهد آمد:

$$C_i = Cost_i = f(X_1, X_2, X_3, \dots, X_{N_{Var}}), i = 1, 2, 3 \dots N_{pop} \quad [3]$$

که در آن،  $C_i$  مقدار تابع هدف هر قطره است. در گام نخست، به تعداد  $N_{POP}$  قطره‌ی باران ایجاد شده و سپس به تعداد  $N_{SR}$  از بهترین قطرات (حداقل ارزش) به عنوان دریا و رود انتخاب می‌شوند. در مسائل کمینه سازی، قطره‌ی باران با حداقل مقدار به عنوان دریا در نظر گرفته می‌شود.  $N_{SR}$  مجموع تعداد رودها و یک دریا از رابطه‌ی ۴ و مابقی جمعیت (نهرهایی که ممکن است به

بهینه‌سازی ساختار شبکه عصبی و دومی بهینه‌سازی وزن‌های شبکه عصبی است. در این مطالعه وزن‌های شبکه عصبی به کمک الگوریتم فرا ابتکاری به منظور افزایش کارایی آن بهینه شده است به عبارت دیگر از روش دوم در این مطالعه استفاده شده است. در روش سوم به منظور انتخاب بهترین ترکیب از ویژگی‌های ورودی در شبکه عصبی از الگوریتم‌ها چرخه آب استفاده شده است. 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 (کومار و همکاران ۲۰۱۴). بر این اساس، الگوریتم چرخه آب انواع ترکیب متفاوت ویژگی‌ها را با شبکه عصبی مدل‌سازی نموده و بهترین ترکیب دارای کمترین خطا (MSE) را به عنوان مدل بهینه شبکه عصبی انتخاب می‌کند. در این مطالعه از روش سوم برای انتخاب ویژگی‌های موثر ورودی در مدل‌سازی فشار آب حفره‌ای در بدنه سد خاکی در زمان ساخت استفاده شده است. برای این منظور از نرم افزار متلب نسخه ۲۰۱۴ استفاده و برنامه شبکه عصبی با الگوریتم‌های فرا ابتکاری ادغام گردیده است. با بررسی داده‌های پیرومتر EP19.7 در این مقطع از سد کبودال، تراز خاک ریزی (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 خاک ریزی بر حسب  $(\frac{m.a.s.l}{day})$  و سرعت آبیگری بر حسب  $(\frac{m.a.s.l}{day})$  به عنوان ورودی و فشار آب حفره‌ای (P) بر حسب (kp) ایجاد شده بر بدنه سد خاکی در زمان ساخت، به عنوان خروجی مدل در روش انتخاب ویژگی، انتخاب شده است. به منظور انتخاب ویژگی در الگوریتم هیبریدی WCA-ANN داده‌ها به طور تصادفی به دو دسته آموزشی (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم شدند و از میانگین وزنی خطاهای آموزشی و آزمون به صورت زیر در این پیرومتر، برای محاسبه خطای مدل، استفاده گردید:

الگوریتم (همگرایی نابالغ)، و به دام افتادن در بهینه‌های محلی جلوگیری می‌کند، فرآیند تبخیر است. این فرآیند باعث خواهد شد که آب دریا با تبخیر به صورت جریان رودها و یا نهرها دوباره به دریا بریزد. رابطه‌ی ۱۰ نشان می‌دهد که آیا رود به دریا می‌ریزد یا نه.

$$\text{If } |X_{Sea}^i - X_{River}^i| < d_{max}, i = 1, 2, 3, \dots, N_{SR} - 1 \quad [10]$$

که در آن،  $d_{max}$  عدد کوچکی (نزدیک به صفر) است، بنابراین، اگر فاصله‌ی بین رود و دریا از  $d_{max}$  کمتر باشد، بیانگر آن است که رود به دریا رسیده است. در این وضعیت، فرآیند تبخیر اثر می‌کند، و همانند طبیعت، بعد از تبخیر کافی، باران (بارش) شروع خواهد شد.  $d_{max}$  شدت جستجو را در نزدیکی دریا (راه حل بهینه) تنظیم می‌کند. مقدار  $d_{max}$  با توجه به رابطه‌ی ۱۱ در هر مرحله کاهش می‌یابد:

$$d_{max}^{i+1} = d_{max}^i - \frac{d_{max}^i}{\max \text{ iteration}} \quad [11]$$

پس از برآورده شدن فرآیند تبخیر، فرآیند بارندگی اعمال خواهد شد. در فرآیند بارندگی، قطرات باران جدید نهرها را در مکان‌های مختلف تشکیل می‌دهند (مانند عملگر جهش در الگوریتم GA). برای تعیین مکان جدید نهرهای تازه شکل‌گرفته، از رابطه‌ی زیر استفاده خواهد شد.

$$X_{Stream}^{new} = LB \times randn \times (UB - LB) \quad [12]$$

در رابطه بالا، LB و UB به ترتیب، کران پایین و بالای مسئله تعریف شده است. بهترین قطرات باران جدید تشکیل شده به عنوان رود، و بقیه‌ی قطرات باران جدید به عنوان نهرهای جدید، که به سمت رودخانه‌ها در جریان‌اند، و یا ممکن است به طور مستقیم به دریا برسند، در نظر گرفته می‌شوند (اسکندر و همکران ۲۰۱۲). معیار همگرایی در الگوریتم مذکور در این مقاله رسیدن به تعداد تکرار برابر، ۱۰۰۰ در نظر گرفته شده است.

### ترکیب شبکه عصبی با الگوریتم‌های فرا ابتکاری

سه راه برای کاربرد الگوریتم‌های فرا ابتکاری در مبحث بهینه‌سازی شبکه عصبی وجود دارد. یکی

### آنالیز حساسیت

در پژوهش حاضر، آنالیز حساسیت به روش هیل (هیل ۱۹۹۸) برای متغیرهای ورودی، انجام گرفته است. در این روش، با تغییر هر یک از متغیرها ورودی، به یک مقدار معین (مثلاً ۱۰ درصد)، تأثیر آن‌ها بر خروجی مدل محاسبه شده و مقدار حساسیت مدل هوش مصنوعی نسبت 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 (هیل ۱۹۹۸). آنالیز حساسیت به ترتیب بهترین ویژگی‌ها را در مدل‌سازی نشان می‌دهد ولی در مورد بهترین ترکیب و یا همان بهترین زیر مجموعه ویژگی‌ها اطلاعاتی به ما نمی‌دهد، بنابراین از فرآیند انتخاب ویژگی استفاده شده است.

### ارزیابی مناسب بودن مدل

در این تحقیق از شاخص‌های آماری جذر میانگین مربعات خطا ( $RMSE$ )، 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 شد. شاخص‌های مذکور با استفاده از روابط زیر قابل محاسبه می‌باشند:

$$R^2 = \left( \frac{\sum_{i=1}^n (O_i - \bar{O}_i)(P_i - \bar{P}_i)}{\sqrt{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \sum_{i=1}^n (P_i - \bar{P}_i)^2}} \right)^2 \quad [14]$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{N}} \quad (14)$$

$$MAE = \exp\left[\frac{1}{N} \sum_{i=1}^n \ln\left(\frac{P_i}{O_i}\right)\right] \quad [15]$$

$$NS = \left| 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \right| \quad [16]$$


$$GMER = \exp\left[\frac{1}{N} \sum_{i=1}^n \ln\left(\frac{P_i}{O_i}\right)\right] \quad [17]$$

در روابط اخیر به ترتیب  $P_i$  مقدار ویژگی محاسبه شده از هوش مصنوعی و  $O_i$  مقدار ویژگی واقعی از ابزار دقیق سد و  $N$  نمایانگر تعداد داده‌ها است. شاخص نش ساتکلیف نشان‌دهنده کارایی مدل است و هر چه نزدیک تر به یک باشد نشان‌دهنده کارایی مناسب مدل و تطابق داده‌های ورودی و خروجی از مدل‌ها است. هر اندازه که جذر میانگین مربعات خطا ( $RMSE$ ) و

$$Error_f = 0.8error_{tr} + 0.2error_{te} \quad [13]$$

در رابطه ۱۳،  $Error_f$ ،  $error_{tr}$  و  $error_{te}$  به ترتیب خطای نهایی مدل به ازای ترکیب‌های متفاوت از ویژگی‌ها، خطای داده‌های آموزشی و آزمون هستند. در اینجا شاخص خطا MSE است. از آنجا که در فرآیند انتخاب ویژگی، هدف تشخیص ویژگی‌های موثر بر متغیر خروجی است و نه تخمین آن، بنابراین خطای مربوط به داده‌های آموزشی اهمیت زیادتری دارد، زیرا رابطه بین ویژگی‌های ورودی و خروجی مدل با استفاده از داده‌های آموزشی به دست می‌آیند.

به منظور مدل‌سازی متغیر هدف (فشار آب حفره‌ای) با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه (MLP)، متغیرهای منتخب حاصل از فرآیند انتخاب ویژگی، به عنوان متغیرهای ورودی استفاده شده‌اند. تعداد لایه‌های بهینه پنهان و همچنین تعداد نرون‌های بهینه لایه پنهان با سعی و خطا در جهت انتخاب ساختار بهینه تعیین گردیده است. در این پژوهش جهت گزینش ساختار بهینه، از شبکه‌های ۱ تا ۱۰ لایه و ۱ تا ۱۵ نرون و 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 ۲). در این مطالعه، به جای استفاده از توابع آموزشی پیش فرض شبکه عصبی از سه الگوریتم فرا ابتکاری به نام‌های الگوریتم ژنتیک، ازدحام ذرات و رقابت استعماری در بهینه کردن وزن های شبکه عصبی استفاده شده است. در حقیقت به علت گسترش روزافزون الگوریتم‌های فرا ابتکاری، استفاده از آن‌ها در بهینه کردن ساختار و وزن‌های شبکه عصبی متداول شده است که این امر باعث شده است که کارایی شبکه های عصبی بهبود یابد.



شکل ۲. ساختار شبکه عصبی مصنوعی در تحقیق.

متغیرهایی که به عنوان ورودی مدل هوش مصنوعی به کار رفتند در پیزومتر فشارسنجی EP19.7 به ترتیب زمان ساخت سد، تراز خاک ریزی و تراز آب مخزن هستند. در مورد چولگی دو ویژگی زمان ساخت و تراز آب مخزن دارای چولگی منفی و مابقی ویژگی‌ها دارای چولگی مثبت هستند. آنالیز همبستگی برای تصمیم‌گیری درباره تأخیر زمانی داده‌ها و همچنین بررسی درستی نتایج مدل هیبریدی با استفاده از نرم افزار SPSS نسخه ۲۰۱۴ انجام شده است. به منظور برآورد تأخیرهای زمانی از تابع خود همبستگی، تأخیر (۰ تا ۱۰) و محدوده اطمینان ۹۵ درصد استفاده شده است (مقادیر منفی، نشان دهنده زمان قبل و مقادیر مثبت، نشان دهنده زمان بعد است. با توجه به شکل ۳ در شکل‌های A تا C واضح است که با تأخیر زمانی در مورد این نمودارها همبستگی بین ویژگی‌ها کاهش یافته یا در شکل D ثابت مانده است، اما در شکل F برای ویژگی سرعت خاکریزی با افزایش تأخیرها، همبستگی افزایش یافته است. در مجموع با توجه به تجزیه و تحلیل داده‌ها می‌توان گفت که شرایط فعلی مقادیر تراز خاکریزی، تراز آبیگری، زمان ساخت، سرعت خاکریزی و سرعت آبیگری می‌توانند به عنوان ورودی برای مدل‌های هوشمند کافی باشند. در جدول ۱، F تراز خاکریزی، R تراز آبیگری، T زمان ساخت، VF سرعت خاکریزی و VR سرعت آبیگری و P فشار آب حفره ای است.

ضریب تبیین ( $R^2$ ) و میانگین خطای مطلق (MAE) به یک نزدیک تر باشند، نشان می‌دهد که خروجی‌ها دقیق‌تر بوده و مقادیر واقعی و پیش‌بینی‌شده به هم نزدیک‌ترند (سلماسی و نورانی ۲۰۱۷). از شاخص میانگین هندسی نسبت خطا (GMER) برای مشخص نمودن بیش برآورد و یا کم 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 بیان‌کننده کم برآورد یا بیش برآورد مدل‌ها است (امیری میجان و همکاران ۲۰۱۹). کن و یردلن ۲۰۰۷، 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، نرمال سازی و به مقیاس در آوردن متغیرها برای عملکرد بهتر این نوع مدل‌ها بهتر است انجام گیرد. بنابراین با استفاده از رابطه ۱۸ داده‌ها بین ۰/۱ تا ۰/۹ نرمال شدند.

$$x_n = \left( 0.8 * \left( \frac{x - x_{min}}{x_{max} - x_{min}} \right) \right) + 0.1 \quad [18]$$

در رابطه بالا مقادیر  $x$ ،  $x_{min}$ ،  $x_{max}$  به ترتیب داده‌های نرمال شده، داده‌های اصلی، کمینه داده‌ها، بیشینه داده‌ها هستند.

## نتایج و بحث

### آمار توصیفی و آنالیز همبستگی

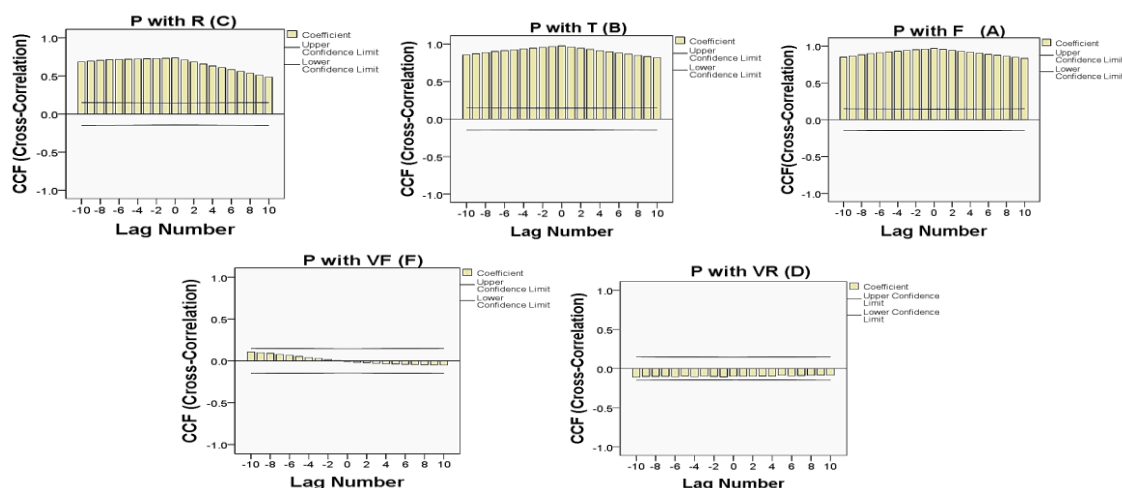
آمار توصیفی متغیرهای اندازه‌گیری شده توسط ابزار دقیق سد برای هر یک از پیزومترهای فشارسنجی در جدول ۱ آورده شده است. بیش‌ترین ضریب تغییرات (CV)، میانه، انحراف معیار (SD)، میانگین در مورد

جدول ۱- آمار توصیفی متغیرهای اندازه‌گیری شده توسط ابزار دقیق سد، پیزومتر EP19.7

ویژگی (واحد)	بیشینه	کمینه	CV	چولگی	SD	میانگین
F (m.a.s.l)	188.82	177.30	11.52	0.01	4.02	183.49
R (m.a.s.l)	174.11	164.65	9.46	-1.76	2.18	170.41
T (day)	2899.00	1361.00	1538.00	-0.18	423.83	2233.73
VF(m.a.s.l/day)	0.12	-0.03	0.14	2.87	0.02	0.01
VR(m.a.s.l/day)	0.55	-0.08	0.63	6.29	0.05	0.01
P(kpa)	52.70	-8.42	61.12	-0.30	19.25	25.76

ضریب تغییرات (CV)، انحراف معیار (SD)





شکل ۳- آنالیز همبستگی داده‌های مورد استفاده: شکل (A) همبستگی متقابل بین تراز خاکریزی و فشار آب حفره‌ای، شکل (B) همبستگی متقابل بین زمان ساخت و فشار آب حفره‌ای، شکل (C) همبستگی متقابل بین تراز آب مخزن و فشار آب حفره‌ای، شکل (D) همبستگی متقابل بین سرعت آب گیری و فشار آب حفره‌ای، شکل (E) همبستگی متقابل بین سرعت خاکریزی و فشار آب حفره‌ای.

از بین ۵ ویژگی ورودی، چهار ویژگی شامل زمان ساخت سد، تراز خاک ریزی، تراز آب مخزن و سرعت آبگیری بیشترین تأثیر را در مدل‌سازی فشار آب حفره‌ای خاک داراست. زیرا بر اساس نتایج ارائه شده مدل‌سازی فشار آب حفره‌ای در شکل ۴، زیرمجموعه ۴ تایی در این پیژومترها، کمترین خطا (مقدار MSE برابر ۱/۱۵۸۷) را در مدل‌سازی ویژگی هدف (فشار آب حفره‌ای) دارد.

#### انتخاب ویژگی با الگوریتم هیبریدی WCA-ANN


همان طور که بیان شد، پیژومتر EP19.7 که در این مطالعه بررسی شده است، در تراز ۱۷۰ متر و نزدیک مخزن قرار دارد. جدول ۲ پارامترهای کنترلی بهینه الگوریتم چرخه آب بعد از سعی و خطا را نشان می‌دهد. نتایج به دست آمده از روش انتخاب ویژگی با الگوریتم هیبریدی WCA-ANN و آنالیز حساسیت در شکل ۴ نشان داده شده است. نتایج نشان داد که در این پیژومتر

جدول ۲- پارامترهای کنترلی بهینه الگوریتم چرخه آب

تعداد تکرار	تعداد قطرات باران	تعداد رودخانه‌ها و دریا	کران پایین و بالا	تعداد ترکیب
۱۰۰۰	۵۰	۴	LB=0; UB=1	۱ تا ۵

همگرایی الگوریتم WCA برای ترکیب ویژگی‌های متفاوت در پیژومتر EP19.7 را نشان می‌دهد.

در این مطالعه از ترکیب ۱ تا ۵ ویژگی برای پیژومتر EP19.7 استفاده شده است. شکل ۵ روند



شکل ۴- آنالیز حساسیت ویژگی‌های ورودی (A) و مقادیر ویژگی‌ها در روش انتخاب ویژگی (B).


استفاده از ویژگی‌های حاصل‌شده از فرآیند انتخاب ویژگی، به تفکیک بیان شده است.

#### هیبرید شبکه عصبی مصنوعی با الگوریتم ژنتیک

اندازه‌های متفاوت جمعیت، روش انتخابی و تقاطع‌های متفاوت برای مدل ANN-GA در نظر گرفته شد. دقت مرحله‌های آموزش و آزمون برای مدل ANN-GA در جدول (۵) نشان داده شده است. همچنین در این جدول پارامترهای بهینه در این الگوریتم آورده شده است. روش انتخاب چرخه رولت به طور کلی، دقت بیشتری در تخمین فشار آب حفره‌ای نسبت به روش انتخابی تورنمنت و تصادفی داشته است. جدول ۳، مقادیر بهینه پارامترهای کنترل‌کننده الگوریتم GA در بهینه‌سازی وزن‌های شبکه عصبی مصنوعی را نشان می‌دهد.

همان طور که در شکل ۶ دیده می‌شود مدل هیبریدی ANN-GA به خوبی توانسته در مراحل آموزش و آزمون، فشار آب حفره‌ای در بدن سد کبودوال در زمان ساخت را پیش‌بینی کند.

همان طور که در شکل ۴ دیده می‌شود، انتخاب ترکیب با ۴ ویژگی (زیرمجموعه ۴تایی) دارای خطای کمتری در مدل‌سازی است. زیرا نمودار مربوط به آن در محور Y به صفر نزدیک‌تر است. این محور مقدار MSE را نشان می‌دهد، هر چه این شاخص به صفر نزدیک‌تر باشد نشان‌دهنده کارایی بهتر مدل‌سازی و خطای کمتر بین مقادیر محاسباتی و مشاهداتی است.





شکل ۵: نمودار همگرایی الگوریتم WCA برای ترکیب ویژگی‌های متفاوت.

#### مدل‌سازی فشار آب حفره‌ای

در این قسمت نتایج مدل‌سازی متغیر هدف (فشار آب حفره‌ای) با استفاده از ترکیب شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) و الگوریتم‌های فرا ابتکاری با



جدول ۳- مقادیر بهینه پارامترهای کنترل‌کننده الگوریتم GA.

تعداد تکرار	اندازه جمعیت	تقاطع	کران پایین و بالا	روش انتخاب	dmax
۱۰۰۰	۵۰	۰/۵	LB=0; UB=1	چرخه رولت	1e-16



شکل ۶- نمودار رگرسیونی و مقادیر مشاهداتی و تخمینی فشار آب حفره‌ای مرحله آموزش (سمت راست) و آزمون (سمت چپ) مدل ANN-GA.

مدل ANN-PSO را گزارش می‌دهد. همچنین شکل ۷ نشان می‌دهد مدل هیبریدی ANN-PSO به خوبی توانسته در مراحل آموزش و آزمون، فشار آب حفره‌ای در بدن سد کیودوال در زمان ساخت را پیش‌بینی کند.



شکل ۷- نمودار رگرسیونی و مقادیر مشاهداتی و تخمینی فشار آب حفره‌ای مرحله آموزش (سمت راست) و آزمون (سمت چپ) مدل ANN-PSO.

مدل‌های ANN-ICA آزمون شده است. کارایی مدل‌های ANN-ICA در مرحله آموزش و آزمون در جدول ۲ ارائه شده است. همان‌طور که در شکل ۸ دیده می‌شود مدل هیبریدی ANN-ICA به خوبی توانسته در مراحل آموزش و آزمون، فشار آب حفره‌ای در بدن سد کیودوال در زمان ساخت را پیش‌بینی کند.

همچنین جدول ۴، مقادیر بهینه پارامترهای کنترل‌کننده الگوریتم PSO در بهینه‌سازی وزن‌های شبکه عصبی مصنوعی را نشان می‌دهد.

هیبرید شبکه عصبی مصنوعی با الگوریتم رقابت استعماری

تعداد متفاوت کشورها، ضریب جذب و نرخ انقلاب برای


جدول ۴- مقادیر بهینه پارامترهای کنترل‌کننده الگوریتم PSO.

تعداد تکرار	اندازه ازدحام متفاوت	ثابت اجتماعی $c_1$	کران پایین و بالا ثابت شناختی $c_2$	جانمایی
۱۰۰۰	۵۰	۲	LB=0; UB=1	اتصال کامل


برای بهینه‌سازی وزن‌های شبکه عصبی مصنوعی، موثر بوده است. جدول ۵، مقادیر بهینه پارامترهای کنترل‌کننده

بر اساس نتایج شبیه‌سازی می‌توان گفت که کاربرد الگوریتم‌های فرا ابتکاری به‌کاررفته در تحقیق

نتایج تحقیق نشان داد مدل هیبریدی ANN-GA در دوره آزمون با مقادیر  $R_2$ ، RMSE و MAE به ترتیب برابر با ۰/۹۷۷۳، ۰/۰۴۵۷ و ۰/۰۳۹۹ به عنوان مدل برتر و مدل هیبریدی ANN-PSO در دوره آزمون با مقادیر  $R_2$ ، RMSE و MAE به ترتیب برابر با ۰/۹۵۴۲، ۰/۰۵۷۹ و ۰/۰۴۲۹ به عنوان مدل دوم و مدل هیبریدی ANN-ICA در دوره آزمون با مقادیر  $R_2$ ، RMSE و MAE به ترتیب برابر با ۰/۹۴۵۳، ۰/۰۶۱۰ و ۰/۰۴۴۴ به عنوان ضعیف‌ترین مدل هیبریدی در تخمین فشار آب حفره‌ای در بدنه سدهای خاکی در زمان ساخت، شناخته می‌شوند.



الگوریتم ICA در بهینه‌سازی وزن‌های شبکه عصبی مصنوعی را نشان می‌دهد. از شاخص میانگین هندسی نسبت خطا (GMER) برای مشخص نمودن بیش برآورد و یا کم برآورد مدل، استفاده شد. همان طور که از جدول ۶ استنباط می‌شود، در داده‌های آموزش و آزمون دو مدل هیبریدی ANN-GA و ANN-ICA، بیش برآورد و در مدل هیبریدی ANN-PSO کم برآورد رخ داده است. با توجه به مؤلفه‌های آماری مربوط، ANN-GA در دوره آموزش و آزمون به خوبی توانسته عمل مدل‌سازی متغیر هدف (فشار آب حفره‌ای) را انجام دهد.




شکل ۸- نمودار رگرسیونی و مقادیر مشاهداتی و تخمینی فشار آب حفره‌ای مرحله آموزش (سمت راست) و آزمون (سمت چپ) مدل ANN-ICA.

ترکیب با شبکه عصبی مصنوعی در شبیه‌سازی فشار آب حفره‌ای در بدنه سدهای خاکی در زمان ساخت است.

همان طور که در شکل ۹ مشاهده می‌شود، سرعت همگرایی الگوریتم ژنتیک نسبت به دو مدل دیگر هیبریدی بیشتر است، که نشان‌دهنده کارایی بالای این الگوریتم در

جدول ۵- مقادیر بهینه پارامترهای کنترل‌کننده الگوریتم ICA

تعداد تکرار	تعداد کشورها	ضریب جذب	کران پایین و بالا	نرخ انقلاب	تعداد امپراتوری‌ها
۱۰۰۰	۵۰	۲	LB=0; UB=1	۰/۳	۱۰



شکل ۹- روند همگرایی الگوریتم‌های فرا ابتکاری.

جدول ۶- مؤلفه‌های آماری مدل‌های هیبریدی، پیزومتر EP19.7 در دوره آموزش و آزمون.

آزمون					آموزش					مدل
R <sup>2</sup>	RMSE	MAE	NS	GMRE	R <sup>2</sup>	RMSE	MAE	NS	GMRE	
0.9773	0.0457	0.0399	0.8652	1.0052	0.9641	0.0468	0.0407	0.9395	1.0122	ANN-GA
0.9542	0.0579	0.0429	0.8527	0.9146	0.9616	0.0485	0.0367	0.9336	0.9939	ANN-PSO
0.9453	0.0610	0.0444	0.8451	1.0588	0.9681	0.0442	0.0311	0.9294	1.0090	ANN-ICA

عصبی مصنوعی ضعیف تر بوده است چرا که در فرآیند آموزش شبکه عصبی با روش‌های کلاسیک یک مرحله‌ای است و نیاز به تکرار دوره‌های آموزشی نیست، حال آن که استفاده از الگوریتم بهینه‌ساز در فرآیند آموزش نیازمند انتخاب جمعیت جدید و تکرار در هر مرحله برای رسیدن به نقطه بهینه مطلوب است که زمان بیشتری را می‌طلبد اما بالا رفتن شاخص‌های عملکردی در پیش‌بینی فشار آب حفره‌ای می‌تواند این مورد را خنثی می‌کند. نتایج به دست آمده حاکی از عملکرد مناسب مدل‌های هیبریدی مورد مطالعه در پیش‌بینی فشار آب حفره‌ای در بدنه سدهای خاکی است. بر این اساس از لحاظ اولویت نیز مدل هیبرید ANN-GA با بیشترین دقت در اولویت اول و مدل‌های هیبرید ANN-PSO و ANN-ICA به ترتیب در اولویت‌های بعدی قرار گرفتند.

پیشنهاد می‌شود برای سایر کمیت‌های سد خاکی مثل نشست و تراوش و فشار قائم خاک نیز مدل‌سازی با ویژگی‌های مذکور انجام شود. در پژوهش‌های آتی از دیگر الگوریتم‌های فرا ابتکاری نیز جهت آموزش ANN استفاده‌شده و نتایج حاصل با نتایج به دست آمده از این مطالعه، مقایسه شود. همچنین به علت نزدیکی پیزومتر مورد مطالعه به مخزن سد و تراز نصب آن، از دیگر پیزومترها دورتر و در تراز نصب متفاوت نیز در فرآیند انتخاب ویژگی استفاده‌شده و نتایج با این پیزومتر مقایسه شود.

### نتیجه‌گیری کلی

با توجه به نیازمند بودن به تخصص، محاسبات طولانی و وقت‌گیر و تعیین دقیق شرایط اولیه مسئله در مدل‌سازی عددی در پیش‌بینی فشار آب حفره‌ای در بدنه سدهای خاکی در زمان ساخت، باعث شده است که در این مطالعه از مدل‌های هوشمند و الگوریتم‌های فرا ابتکاری برای این منظور استفاده شود. نتایج به دست آمده از روش انتخاب ویژگی با الگوریتم هیبریدی WCA-ANN و آنالیز حساسیت نشان داد که در پیزومتر مورد مطالعه از بین ۵ ویژگی ورودی، چهار ویژگی شامل زمان ساخت سد، تراز خاک ریزی، تراز آب مخزن و سرعت آبیگری بیشترین تأثیر را در مدل‌سازی فشار آب حفره‌ای خاک داراست. در شبیه‌سازی فشار آب حفره‌ای در بدنه سدهای خاکی در زمان ساخت در این مطالعه، از سه الگوریتم متفاوت تکاملی شامل الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و الگوریتم رقابت استعماری در آموزش شبکه عصبی پرسپترون چند لایه استفاده شده است. آموزش ساختار شبکه عصبی مصنوعی با الگوریتم‌های فرا ابتکاری مذکور نشان داد که فرآیند آموزش برای هر دور بسیار کند و وقت‌گیر است ولی شاخص‌های عملکردی سیستم طراحی‌شده را نیز بهبود

داده است. لازم به ذکر است که مدل‌های هیبریدی در این مقاله از نظر سرعت از روش آموزش کلاسیک شبکه

## منابع مورد استفاده

- Amiri Mijan F, Shirani H, Esfandiarpouri I, Besalatpour A and Shekofteh H, 2019. Identifying the determinant factors influencing S index in calcareous. *Water and Soil Science* 23(3): 381-394. (In Persian with English abstract).
- Anonymous, 2013. Reporting the Behavior of Kabudwal Dam Golestan. Golestan: Kabudwal Dam Behavior Report (In Persian).
- Can I and Yerdelen IC, 2007. Stochastic modeling of Karasu River (Turkey) using the methods of Artificial Neural Networks. *Hydrology Days* 2: 138-144.
- Chandrashekar G and Sahin F, 2014. A survey on feature selection methods. *Computers and Electrical* 40: 16-28. (In Persian with English abstract)
- Cucci G, Lacolla G, Pagliai M and Vignozzi N, 2015. Effect of reclamation on the structure of silty-clay soils. *International Agrophysics Journal* 29: 23-30.
- Dawson CW and Wilby R, 1998. An artificial neural network approach to rainfall-runoff modeling. *Hydrological Sciences Journal* 1: 47-66.
- Ebrahimzadeh A, Zarghami M and Nourani V, 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 with English abstract)
- Eskandar H, Sadollah A and Bahreininejad A, 2012. Water cycle algorithm -A novel metaheuristic optimization method for solving constrained engineering optimization problems. *Computers and Structures* 110(111): 151-166.
- Hill MC, 1998. *Methods and Guidelines for Effective Model Calibration*. U.S. Geological Survey Water .
- Karunanithi N, Grenney WJ, Whitley D and Bovee K, 1994. Neural networks for river flow prediction. *Journal of Computing in Civil Engineering* 2: 201-220.
- Komasi M and Beiranvand B, 2020. Study of vertical and horizontal displacements of eyvashan earth dam using instrumentation and numerical analysis. *Iranian Journal of Soil and Water Research* 51(1): 245-256. (In Persian with English abstract).
- Kumar V and Minz S, 2014. Feature selection, a literature review. *Smart Computing Review* 4(3): 211-229.
- Masters T, 1993. *Practical Neural Network Recipes in C++*. Academic Press.
- Moghaddamnia A, Ghafari Gousheh M, Piri J, Amin S and Han D, 2009. Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources* 32: 88-97(In Persian with English abstract).
- Nourani V, 2015. *Basics of Hydroinformatics*. Tabriz University Press, 636p.
- Nourani V and Babakhani A, 2013. Integration of artificial neural networks with radial basis function interpolation in earthfill dam seepage modeling. *Journal of Computing in Civil Engineering* 27(1): 183-195. (In Persian with English abstract).
- Nourani V, Kisi O and Komasi M, 2011. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology* 402: 41-59.
- Nourani V, Sharghi E and Aminfar MH, 2012. Integrated ANN model for earthfill dam's seepage analysis: Sattarkhan dam in Iran. *Artificial Intelligence Research* 1(2): 22-37. (In Persian with English abstract)
- Nouri M and Salmasi F, 2017. Predicting seepage of earth dams using Artificial Intelligence Techniques. *Irrigation Sciences and Engineering* 42(1): 83-97. (In Persian with English abstract)
- Novakovic A, Rankovic V, Grujovic N, Divac D and Milivojevic N, 2014. Development of neuro-fuzzy model for dam seepage analysis. *Annals of the Faculty of Engineering Hunedoara* 12(2): 133-136.
- Rankovic V, Grujovic N, Divac D and Milivojevic N, 2014. Development of support vector regression. *Structural Safety* 48: 33-39.
- Salmasi F and Hakimi Khansar H, 2020. Simulation of behavior the Kabudval dam during construction with 3D numerical modeling. *Amirkabir Journal of Civil Engineering* 2(1): 25-39. (In Persian with English abstract)
- Salmasi F, Hakimi Khansar H and Norani B, 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). *Water and Soil Science* 22(4): 155-171. (In Persian with English abstract)

- Sharghi E, Norani V and Behfar N, 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 with English abstract)
- Tayfure G, Swiatek D, Wita A and Singh VP, 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.
- Vafaeian M, 2015. *Earth Dams and Rockfill Dams*. Isfahan: Arkan Danesh. 464p.
- Wu K, Soci C, Shum PP and Zheludev I, 2014. Computing matrix inversion with optical networks. *Optics Express* 22(1): 295-304.