



## Research Paper

## Development of Hybrid Adaptive Neuro Fuzzy Inference System - Harris Hawks Optimizer (ANFIS-HHO) for Monthly Inlet Flow to Dam Reservoirs Prediction

Seyed Mohammad Enayati<sup>1</sup>, Mohsen Najarchi<sup>2\*</sup>, Osman Mohammadpour<sup>3</sup> and Seyed Mohammad Mirhosseini<sup>4</sup>

<sup>1</sup>Ph.D. Student, Department of Civil Engineering, Faculty of Engineering, Arak Branch, Islamic Azad University, Arak, Iran

<sup>2</sup>Assoc. Professor, Department of Water Engineering, Faculty of Agriculture, Arak Branch, Islamic Azad University, Arak, Iran

<sup>3</sup>Assist. Professor, Department of Water Engineering, Faculty of Agriculture, Mahabad Branch, Islamic Azad University, Mahabad, Iran

<sup>4</sup>Assist. Professor, Department of Civil Engineering, Faculty of Engineering, Arak Branch, Islamic Azad University, Arak, Iran

### Article information

**Received:** January 24, 2022

**Revised:** February 26, 2022

**Accepted:** February 27, 2022

### Keywords:

Evolutionary Algorithms

Mahabad Dam

Machine Learning

Predicting Time Series

Rainfall-Runoff

\*Corresponding author:

[m-najarchi@iau-arak.ac.ir](mailto:m-najarchi@iau-arak.ac.ir)



### Abstract

Nowadays, machine learning models are able to make good predictions based on pattern extraction between data. In this study, a neural-fuzzy network (ANFIS) was used to predict the inflow to the reservoirs of a dam namely, the Mahabad dam located in the northwestern part of Iran. A new Harris Hawk (HHO) optimization algorithm was also used to improve the ANFIS (HHO-ANFIS) structure. Monthly precipitation and temperature and inlet flow data to the reservoir one to three months ago were used as input parameters as 6 different input patterns. About 70% of the data was used for training and 30% to test the models. The results showed that the ANFIS model has good accuracy in training data although, for test data, its accuracy was greatly reduced. The development of the HHO-ANFIS model improved the accuracy of the prediction. The patterns with all input parameters had the highest prediction accuracy. In this pattern, values of Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and Nash Sutcliffe Efficiency coefficient (NSE) for test data were 3.9 MCM, 2.41 MCM, and 0.86, respectively. Due to the good performance of the model used, it can be recommended for time series predictions.

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



### Introduction

Inlet flow to the dam reservoir is one of these important parameters in the balance and hydrological cycle. Because hydrological

processes are influenced by several other processes, it is difficult to discern their general behavior during working time; in other words, a nonlinear relationship governs these processes.



It is essential to predict the correct amount of Inlet flow to the dam reservoir in the management of macro-water resources. There are various models and tools to predict evaporation from the surface of dam reservoirs, among which artificial intelligence and machine learning models have attracted much attention in recent years for various reasons, such as lower cost, being time-effective, and the need for less information.

The HHO-ANFIS hybrid model has been developed in the last two years by various researchers for time-series predictions. The results indicate a very positive performance of the hybrid models developed in the predictions. In this research, an attempt has been made to predict the amount of inflow to the reservoirs of dams using the ANFIS model and its developed model using the HHO algorithm.

### Material and Methods

The Mahabad river catchment basin between  $45^{\circ}25' - 46^{\circ}45' E$ , and  $36^{\circ}23' - 36^{\circ}45' N$  is located in south of Lake Urmia. The area of this basin is

1524.53 km<sup>2</sup>. The Mahabad river is formed by the confluence of the Bitas tributary in the east and the Kotar tributary in the west. On this river, the Mahabad reservoir dam was constructed at the junction of the Bitas and Kotar tributaries in 1967. The height of the structure is 47.5 m with a length of 700 m with a pebble and clay bed. The annual volume of inflow water to the Mahabad dam is 339 MCM. The area of the lake behind the dam is 360 ha. In order to predict the inflow to the reservoir of Mahabad Dam, several variables, including temperature, precipitation, and inflow to the dam reservoir in the previous month, have been used. The time series of these variables during the study period is shown in Fig. 1. It is observed that the trend of precipitation is somewhat similar to that of the inflow to the dam reservoir. In the months when the temperature has increased, the inflow to the dam reservoir has decreased, indicating the inverse relationship between the two variables. In general, the variables considered in this study vary with time significantly.

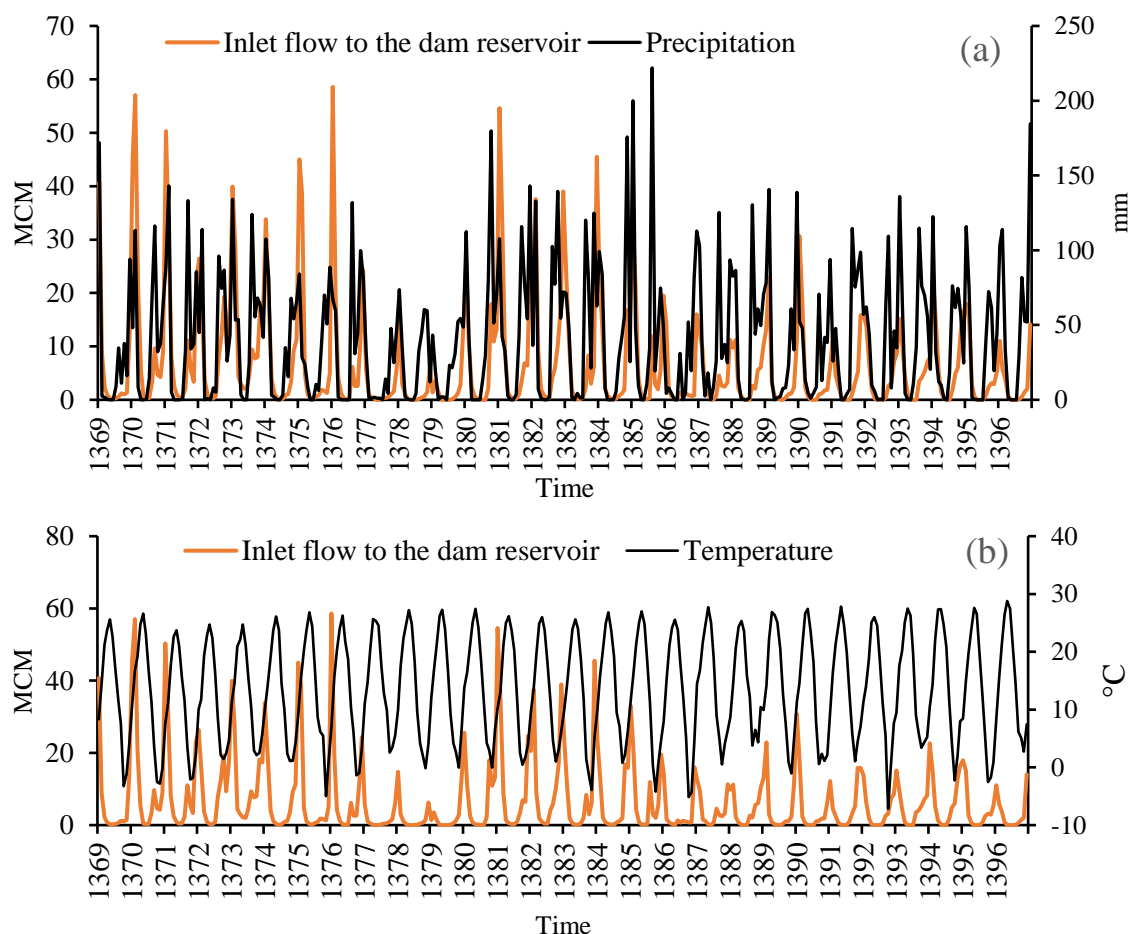


Fig. 1 Time series of input and output parameters, a) Input flow time series to dam reservoir and rainfall, and b) Input flow time series to dam reservoir and temperature

**Adaptive neuro-fuzzy inference system (ANFIS)**

The ANFIS model was developed by combining ANN and fuzzy inference system (FIS) (Jang, 1993). The ANFIS architecture generally includes five main layers. In layer 1, the generalized Gaussian membership function  $\mu$  produces a new output  $Out_{1i}$  from the inputs  $x$  and  $y$  (Eq. 1)

$$\begin{aligned} Out_{1i} &= \mu A_i(x), i = 1, 2 \\ Out_{1i} &= \mu B_{i-2}(y), i = 3, 4 \end{aligned} \tag{1}$$

Where,

$$\mu(x) = e^{-\left(x - \frac{p_i}{\sigma_i}\right)^2} \tag{2}$$

and  $A_i$  and  $B_i$  are the membership values of  $\mu$ , while  $P_i$  and  $\sigma_i$  are the equation parameters. The output of each node is obtained in the second layer using Eq (3).

$$Out_{2i} = \mu A_i(x) * \mu B_{i-2}(y) \tag{3}$$

Afterward, the output of layer 2 is normalized in layer 3 (Eq. 4)

$$X(t + 1) = \begin{cases} X_{rand}(t) - r_1 |X_{rand}(t) - 2r_2 X(t)| & q \geq 0.5 \\ (X_{rabbit}(t) - X_m(t)) - r_3(LB + r_4(UB - LB)) & q < 0.5 \end{cases} \tag{7}$$

Where,  $X(t)$  and  $X(t+1)$  are the position of hawks at iterations  $t$  and  $t+1$ , respectively,  $X_{rabbit}(t)$  is the rabbit's position,  $r_1, r_2, r_3, r_4$ , and  $q$  are random numbers, being updated in each iteration, UB and LB and the lower and upper limits of variables,  $X_{rand}(t)$  is the position of an arbitrary hawk, and  $X_m$  is the average position of the population, which is obtained using Eq. (8).

$$Out_{3i} = \bar{W}_i = \frac{\omega_i}{\sum_{i=1}^2 \omega_i} \tag{4}$$

The output is then used in a linear combination Equation (Eq. 5).

$$Out_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \tag{5}$$

Where,  $p, q$ , and  $r$  are parameters defined for the  $i$ -th node. The model's output is obtained using Eq. (6).

$$Out_{4,i} = \sum_i \bar{w}_i f_i \tag{6}$$

**Harris Hawks Optimization**

The hunting method of Harris hawks includes two stages of soft and hard sieges. In the soft siege, the rabbit still has enough energy and tries to escape with random misleading jumps. The hawks gently surround the prey to make it more tired. However, in the hard siege, the prey is completely tired and has little escape energy. Harris hawks hardly surround the prey to finally deliver the surprise pounce. In this algorithm, the Harris hawks move randomly to find prey, and their position is determined by Eq. (7).

$$X_m(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \tag{8}$$

**Results**

Error evaluation criteria in Table (1) show that different input patterns in ANFIS model have a large error difference between training and test results. However, in this model, the sixth model, which included all input parameters, was more accurate, especially in the training section.

Table 1 Results of error evaluation criteria in ANFIS and HHO-ANFIS models in different input models

Pattern name	Model	NSE		MAE (MCM)		RMSE (MCM)	
		Test	Train	Test	Train	Test	Train
P1	ANFIS	-0.08	0.55	6.10	4.48	11.80	8.65
	HHO-ANFIS	0.62	0.59	4.70	4.54	8.00	7.75
P2	ANFIS	0.34	0.57	6.00	4.79	10.46	8.31
	HHO-ANFIS	0.72	0.72	4.47	4.38	6.96	6.83
P3	ANFIS	0.00	0.77	4.87	3.10	12.5	5.96
	HHO-ANFIS	0.60	0.80	2.86	3.14	6.60	5.88
P4	ANFIS	0.55	0.85	5.42	2.61	8/59	4.62
	HHO-ANFIS	0.74	0.76	3.77	3.25	5.88	5.90
P5	ANFIS	-0.49	0.97	8.00	1.26	15.0	2.15
	HHO-ANFIS	-0.71	0.87	3.60	2.27	6.25	4.54
P6	ANFIS	-0.26	0.92	6.75	1.40	16.24	3.04
	HHO-ANFIS	0.86	0.90	2.41	2.00	3.90	4.17

The results of the models in the HHO-ANFIS model showed that there is almost a small

difference between the training and test data. Among the various input patterns, the sixth

pattern, which included all input parameters, was selected as the most appropriate pattern. In this model, RMSE, MAE and NSE values for test data were 3.9 MCM, 2.41 MCM and 0.86, respectively. The fifth model was the closest model to the selected model with the participation of all input parameters except the inlet flow to the dam reservoir with a delay of three months. In this model, RMSE, MAE and NSE values for test data were equal to 6.25 MCM, 3.60 MCM and 0.71, respectively.

### Conclusions

In this study, the estimation of the estimated amount of inlet flow to the dam reservoir was performed using the ANFIS model and the ANFIS hybrid model developed by the HHO algorithm. Examining the simulation results in the machine learning approach showed some positive points in the prediction, which can be mentioned as follows:

1. HHO-ANFIS hybrid model compared to its single model (ANFIS) had a good performance

in predicting the amount of input current to the dam reservoir.

2. Analysis of inlet parameters showed that the P6 pattern, which includes parameters of temperature, precipitation and the amount of inlet flow to the dam reservoir with a lag of one, two and three months, provides better results.


3. Meteorological information is also required to predict the amount of inlet flow to the dam reservoirs in addition to the inlet flow data to the reservoir with different lags.

### Data Availability

The data can be sent by corresponding author by email ([m-najarchi@iau-arak.ac.ir](mailto:m-najarchi@iau-arak.ac.ir)) based on the request.

### Conflicts of interest

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



ISSN: 2476-3683

محیط زیست و مهندسی آب

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

مقاله پژوهشی

## توسعه مدل هیبریدی شبکه عصبی - فازی و الگوریتم شکار شاهین هریس جهت پیش بینی جریان ماهانه ورودی به مخازن سدها

سید محمد عنایتی<sup>۱</sup>، محسن نجارچی<sup>۲\*</sup>، عثمان محمد پور<sup>۳</sup> و سید محمد میر حسینی<sup>۴</sup>

<sup>۱</sup>دانشجوی دکترا، گروه مهندسی عمران، دانشکده فنی مهندسی، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران  
<sup>۲</sup>دانشیار، گروه مهندسی آب، دانشکده کشاورزی، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران  
<sup>۳</sup>استادیار، گروه مهندسی آب، دانشکده کشاورزی، واحد مهاباد، دانشگاه آزاد اسلامی، مهاباد، ایران  
<sup>۴</sup>استادیار، گروه مهندسی عمران، دانشکده فنی مهندسی، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران

### اطلاعات مقاله

### چکیده

تاریخ دریافت: [۱۴۰۰/۱۱/۰۴]  
 تاریخ بازنگری: [۱۴۰۰/۱۲/۰۷]  
 تاریخ پذیرش: [۱۴۰۰/۱۲/۰۸]

### واژه‌های کلیدی:

الگوریتم‌های تکاملی  
 بارش - رواناب  
 پیش‌بینی سری‌های زمانی  
 سد مهاباد  
 یادگیری ماشین

### \*نویسنده مسئول:

[m-najarchi@iau-arak.ac.ir](mailto:m-najarchi@iau-arak.ac.ir)



امروزه مدل‌های یادگیری ماشین با تکیه بر استخراج الگوی بین داده‌ها قادر به پیش‌بینی مناسب سری‌های زمانی هستند. در این پژوهش از شبکه عصبی- فازی (ANFIS) برای پیش‌بینی جریان ورودی به مخزن سد مهاباد در شمال غرب ایران استفاده گردید. همچنین از الگوریتم بهینه‌سازی جدید شکار شاهین هریس (HHO) برای بهبود ساختار ANFIS بهره برده شد. از داده‌های هواشناسی مانند بارش ماهانه، دمای ماهانه و جریان ورودی به مخزن یک تا سه ماه قبل به‌عنوان پارامترهای ورودی و در ۶ الگوی مختلف ورودی استفاده شد. حدود ۷۰٪ داده‌ها برای آموزش مدل‌ها و ۳۰٪ برای آزمون آن‌ها در نظر گرفته شد. نتایج نشان داد که مدل ANFIS از دقت خوبی در داده‌های آموزش برخوردار است اما برای داده‌های آزمون از دقت آن بسیار کاسته می‌شود. توسعه مدل HHO-ANFIS موجب بهبود دقت پیش‌بینی شد. در بین الگوهای ورودی، الگویی که شامل تمام پارامترهای ورودی بود (P6) دارای بیش‌ترین دقت پیش‌بینی بود. در این الگو مقادیر جذر میانگین مربعات خطا (RMSE)، میانگین خطای مطلق (MAE) به همراه ضریب ناش ساتکلیف (NSE) برای داده‌های آزمون به ترتیب برابر ۳/۹ MCM، ۲/۴۱ و ۰/۸۶ بود. با توجه به عملکرد خوب مدل مورد استفاده، می‌توان آن را برای پیش‌بینی سری‌های زمانی توصیه کرد.

### ۱- مقدمه

با عدم قطعیت کمتر برای یک حوزه آبخیز یکی از مهم‌ترین مسائلی است که همیشه مهندسی هیدرولوژی با آن مواجه هستند. برآورد رواناب حاصل از بارش در یک حوزه آبخیز از جهات گوناگون از جمله طراحی و مدیریت سدها و مخازن

آگاهی از میزان جریان ورودی به مخزن سدها می‌تواند به تخصیص و رهاسازی از مخازن سدها کمک شایانی نماید. شناخت الگوها و روندهای تغییرات فرآیند بارش- رواناب، برآورد رواناب حاصل از بارش و ارائه مدل پیش‌بینی مطلوب



در استفاده از شبکه بیزین<sup>۳</sup> (BN) و (Abbasi et al. (2019) در استفاده از رگرسیون بردار پشتیبان<sup>۴</sup> (SVR) اشاره کرد. نتایج تحقیقات ذکر شده نشان داده‌اند که مدل‌های یادگیری ماشین، ابزار مناسبی برای پیش‌بینی جریان ورودی به مخزن سدها هستند. استفاده از ANFIS در تحقیقات مختلفی نشانگر که همواره به دام افتادن در نقاط محلی یک مشکل جدی است (Panahi et al. 2021; Mahmoudi et al. 2022). به عقیده محققان مختلف الگوریتم‌های سنتی موجود در ساختار ANFIS نمی‌توانند به خوبی مدل ANFIS را آموزش داده و به همین منظور از الگوریتم‌های تکاملی که قادر به فرار از نقاط بهینه محلی هستند استفاده می‌گردد (Azar et al. 2021; Riahi-Madvar et al. 2021). الگوریتم شکار شاهین هریس<sup>۵</sup> (HHO) یکی از جدیدترین الگوریتم‌های تکاملی جهت حل مسائل بهینه-سازی می‌باشد.

توسعه مدل هیبریدی HHO-ANFIS در دو سال گذشته توسط محققان مختلف انجام شده است. نتایج حاکی از عملکرد بسیار مثبت مدل هیبریدی توسعه داده شده در پیش‌بینی‌ها بوده است. (Ghordoyee Milan et al. (2018) از مدل هیبریدی توسعه داده شده برای پیش‌بینی مقدار برداشت بهینه از آب زیرزمینی استفاده کرد. نتایج تحقیق آن‌ها نشان داد که این مدل دقت مناسب‌تری نسبت به مدل ANFIS داشته است. (Azar et al. (2021) از HHO-ANFIS برای پیش‌بینی ضریب پخشیدگی طولی رودخانه استفاده کرد. نتایج نشان داد عملکرد مناسب‌تری نسبت به مدل واحد ANFIS و حداقل مربعات ماشین بردار پشتیبان<sup>۶</sup> (LSSVM) دارد. (Arya Azar et al. (2021b) در تحقیق دیگری استفاده از مدل مذکور را در پیش‌بینی تبخیر از مخازن سدها مورد ارزیابی قرار دادند. نتایج آن‌ها نشان داد که مدل مذکور عملکرد مناسبی در پیش‌بینی از تبخیر مخازن سدها دارد. اخیراً در پژوهش دیگری نیز (Milan et al. (2021) از الگوریتم HHO برای بهبود ساختار ANFIS در پیش‌بینی ظرفیت تبادل کاتیونی خاک پرداختند. نتایج آن‌ها بیانگر عملکرد مناسب مدل هیبریدی توسعه داده شده در پیش‌بینی بود.

طراحی سازه‌های کنترل و تنظیم سیلاب، کنترل فرسایش کناره و بستر رودخانه، سامانه‌های هشدار سیل مورد توجه هیدرولوژیست‌ها بوده است. بنابراین ارائه مدل بهینه بارش-رواناب در یک حوزه آبخیز از ضروریات مطالعات هیدرولوژی می‌باشد. در حالت کلی، برای مدل‌سازی جریان رودخانه‌های ورودی به مخزن سدها از دو دسته مدل‌های مفهومی و مدل‌های مبتنی بر داده یا آمار (روش‌های هوش مصنوعی یا یادگیری ماشین) استفاده می‌شوند (Peueot et al. 2003; Di et al. 2014; He et al. 2014). کاربرد مدل‌های مفهومی چندان آسان نیست، چراکه این مدل‌ها پیچیده بوده و به ابزارهای ریاضی پیچیده، مقدار قابل توجهی از داده‌ها برای واسنجی مدل‌ها و درجاتی از تخصص و تجربه (He et al. 2016; Awchi 2014; Zhang et al. 2014). با توجه به وجود چنین مسائل و مشکلاتی در مدل‌های مفهومی، پژوهشگران به استفاده از مدل‌های آماری یا داده محور روی آورده‌اند. این روش‌ها، الگوهای نهفته در داده‌های تاریخی را تشخیص می‌دهند. سپس این الگوها را برای پیش‌بینی سناریوهای آینده به کار می‌گیرند. ارزیابی کاربردهای یادگیری ماشین در هیدرولوژی نشان‌دهنده آن است که این روش‌ها می‌توانند عملکرد مناسب‌تری نسبت به دیگر مدل‌ها داشته باشند (Shafaei et al. 2017; Nikolos et al. 2008; Chu and Chang 2009).

از مزایای مدل‌های یادگیری ماشین برای شبیه‌سازی می‌توان به عدم وجود داده‌های اساسی یک سامانه، کم‌هزینه بودن و زمان کمتر نسبت به مدل‌های مفهومی اشاره نمود (Moghaddam et al. 2021; Kayhomayoon et al. 2021a, b). به همین منظور در چند سال اخیر استفاده از این مدل‌ها در زمینه‌های مختلف پیش‌بینی پارامترهای هیدرولوژی و هیدرولوژیکی به کار گرفته شده‌اند (Milan et al. 2018; Milan et al. 2021; Arya Azar et al. 2021). در زمینه ارزیابی مدل‌های یادگیری ماشین برای پیش‌بینی جریان ورودی به مخازن سدها نیاز تحقیقات نسبتاً زیادی انجام شده است که می‌توان به تحقیقات (Shahkarami et al. (2016) در استفاده از مدل‌های شبکه عصبی<sup>۱</sup> (ANN) و شبکه عصبی-فازی<sup>۲</sup> (ANFIS)، (Misaghi (2016) در استفاده از ANFIS، (Moazami et al. (2020) در استفاده از ANN، (Norbeh et al. (2018)

<sup>۳</sup>Bayesian Network

<sup>۴</sup>Support Vector Regression

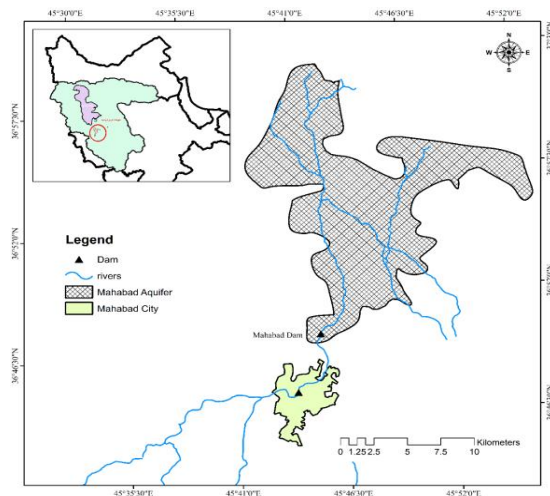
<sup>۵</sup>Harris Hawks Optimization

<sup>۶</sup>Least Squares Support Vector Machine

<sup>۱</sup>Artificial Neural Network

<sup>۲</sup>Adaptive Neuro Fuzzy Inference System

ورودی به مخزن سد در یک، دو و سه ماه قبل به همراه بارش ماهانه، استفاده شده است.



شکل ۱- موقعیت جغرافیایی حوزه آبریز سد مه‌آباد  
Fig.1 Geographical location of Mahabad dam catchment

مشخصات آماری هریک از پارامترهای ورودی و پارامتر خروجی در جدول (۱) آورده شده است. مطابق جدول (۱) مقدار جریان ورودی به مخزن در محدوده ۰ تا ۵۹ MCM در ماه متغیر است. کمترین مقدار آن در ماه‌های گرم سال مانند تیر و مرداد و بیشترین مقادیر نیز مربوط به ماه‌های معتدل و بارانی سال می‌باشد.

جدول ۱- خلاصه مشخصات پارامترهای آماری

Table 1 Summary of statistical parameters

Statistical Parameter	Precipitation (mm)	Temperature (°C)	Inlet flow (MCM)
Minimum	0	0	0
Maximum	222	28.8	58.6
Average	40.6	13.4	6.80
Standard deviation	43.8	9.30	10.4

مقادیر بارش ماهانه در طول دوره مورد بررسی نیز نشان می‌دهد که از صفر تا ۲۲ mm در ماه متغیر است. در مواقعی که بیشترین بارش در ماه صورت می‌گیرد به تبع آن بیشترین جریان ورودی به مخزن نیز افزایش پیدا می‌کند. بیشترین دمای ماهانه حدود ۲۹ °C و مربوط به ماه‌های گرم سال می‌باشد.

همچنین سری زمانی پارامترهای ورودی و خروجی در طول دوره مورد بررسی در شکل (۲) ترسیم شده است. هدف از ترسیم سری زمانی پارامترها، مقایسه تغییرات پارامترهای ورودی با پارامتر خروجی است. از آنجایی که هر پارامتری

در این پژوهش سعی بر آن شده تا میزان جریان ورودی به مخازن سدها به وسیله مدل ANFIS و مدل توسعه داده شده آن به وسیله الگوریتم HHO پیش‌بینی شود. لذا در این رابطه سد مه‌آباد در استان آذربایجان غربی به عنوان محدوده مطالعاتی در نظر گرفته شد. در این پژوهش از پارامترهای هواشناسی مختلفی نظیر بارش و دما در کنار تأخیرهای زمانی مختلف از جریان ورودی به مخزن در قالب الگوهای ورودی به مدل‌ها استفاده شده است. الگوریتم HHO یکی از جدیدترین الگوریتم‌های موجود در مسائل بهینه‌سازی می‌باشد، لذا توسعه مدل هیبریدی HHO-ANFIS برای برآورد میزان جریان ورودی به مخزن سد و مقایسه نتایج آن با مدل واحد ANFIS از تازگی این پژوهش نسبت به سایر تحقیقات مشابه می‌باشد.

## ۲- مواد و روش‌ها

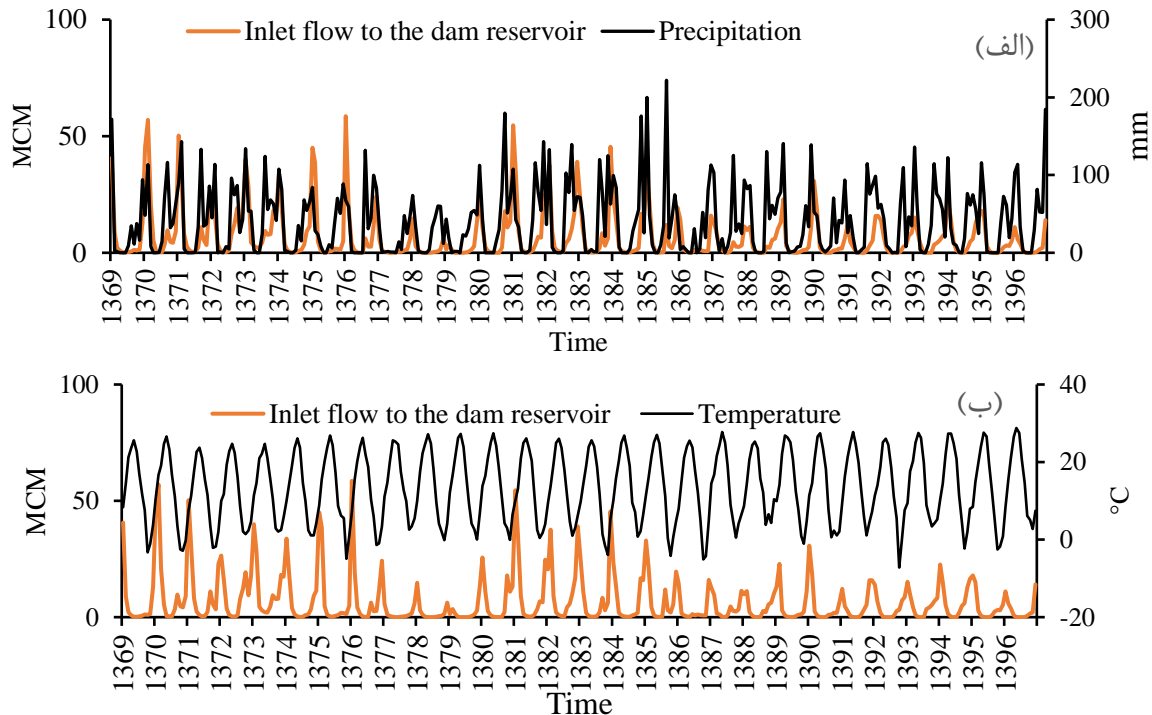
### ۲-۱- محدوده مطالعاتی و داده‌های مورد نیاز

حوزه آبخیز رودخانه مه‌آباد در شمال غرب ایران و در جنوب دریاچه ارومیه قرار دارد. این حوزه جزو حوزه اصلی دریاچه ارومیه است (شکل ۱). وسعت این حوزه  $1524/53 \text{ km}^2$  است که حدود ۳٪ از مساحت حوزه آبخیز دریاچه ارومیه را شامل می‌شود. رودخانه مه‌آباد از به هم پیوستن شاخه بیطاس در شرق و شاخه کوتر در غرب شکل گرفته است. بر روی این رودخانه یک سد مخزنی در محل اتصال دو شاخه بیطاس و کوتر در سال ۱۳۴۶ احداث و هم‌زمان سد انحرافی دیگری در پایین‌دست سد مه‌آباد جهت انحراف آب به مجاری آبیاری و کنترل سیلاب که هرچند سال یک‌بار در پایین‌دست حوزه اتفاق می‌افتاد، ساخته شده است. سد مه‌آباد یکی از ده سد پر آب کشور است و حجم ورودی سالانه آب در این سد ۳۳۹ MCM می‌باشد. دریاچه این سد یک تالاب دائمی است که در یک کیلومتری شهر مه‌آباد قرار دارد که به طور مستقیم از سوی سازمان آب جهت تأمین آب شرب و کشاورزی شهر و روستاهای اطراف، مورد بهره‌برداری قرار می‌گیرد. مساحت دریاچه پشت سد ۳۶۰ ha است.

مهم‌ترین نکته در استفاده از مدل‌های یادگیری ماشین انتخاب پارامترهای ورودی مناسب است. در انتخاب این پارامترها همواره باید دو ویژگی تأثیر گذار بودن بر روی عامل خروجی و متغیر بودن نسبت به زمان را مورد توجه قرار داد. به همین منظور در تحقیق پیش رو جهت پیش‌بینی تبخیر جریان ورودی به مخزن سد مه‌آباد از پارامترهای دما، جریان

مخزن سد نیز کاهش یافته است. این موضوع نشان از رابطه عکس بین دو پارامتر مذکور می‌باشد. در حالت کلی پارامترهای در نظر گرفته شده نسبت به زمان متغیر هستند. ترکیب آن‌ها به عنوان الگوی ورودی می‌تواند در نتایج دقت مدل‌ها مؤثر واقع شود. به همین منظور نیاز است الگوهای مختلف از ترکیبات پارامترهای ورودی در نظر گرفته شود.

رفتار و تغییرات مشابهی با پارامتر خروجی داشته باشد بیشترین تأثیر را در تعیین مقدار خروجی دارد. لذا مشاهده روند تغییرات و مقایسه آن با پارامتر خروجی می‌تواند مفید واقع شود. ملاحظه می‌شود که روند تغییرات بارش تا حدودی مشابه با پارامتر جریان ورودی به مخزن سد است. در ماه‌هایی که دمای بیشتری اتفاق افتاده، دبی ورودی به



شکل ۲- سری زمانی پارامترهای ورودی و خروجی، الف- سری زمانی جریان ورودی به مخزن سد و بارندگی، ب- سری زمانی جریان ورودی به مخزن سد و دما

Fig. 2 Time series of input and output parameters, a) Input flow time series to dam reservoir and rainfall, b) Input flow time series to dam reservoir and temperature

آن‌ها پیشنهاد شد. در ادامه نیز به تشریح مدل‌های به کاررفته به همراه معیارهای ارزیابی خطا در نظر گرفته شده پرداخته شده است (شکل ۳).

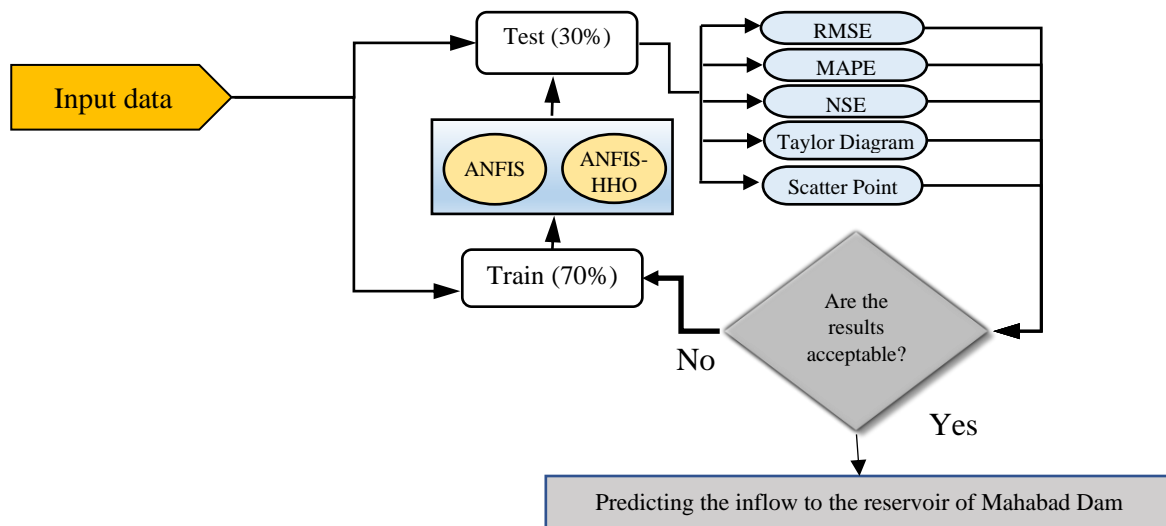
### ۲-۲-۱- تدوین الگوهای ورودی

جهت پیش‌بینی جریان ورودی به سد ترکیب و انتخاب پارامترهای مناسب برای رسیدن به بیشترین دقت پیش‌بینی نیازمند تدوین الگوهایی ورودی است که در آن پارامترهای ورودی مختلفی مشارکت داشته باشند. به همین منظور برای ایجاد چنین الگوهایی در ابتدا ضریب همبستگی پارامترهای ورودی نسبت به پارامتر خروجی و همدیگر محاسبه شد تا بتوان بر اساس ضریب همبستگی الگوهای ورودی مختلفی تدوین نمود.

### ۲-۲-۲- روش پژوهش و تدوین الگوهای ورودی

هدف از این پژوهش تدوین مدل پیش‌بینی کننده جریان ورودی به سدهاست. ابتدا پارامترهای مؤثر بر مقدار جریان ورودی تعیین شده است. در این پژوهش متغیرهای هواشناسی مانند دما، بارش و جریان یک ماه، دو ماه و سه ماه قبل به عنوان پارامترهای ورودی در نظر گرفته شد. در ادامه الگوهای ورودی مختلفی از ترکیب پارامترها تدوین شد. مناسب‌ترین ترکیب از پارامترهای ورودی را برای پیش‌بینی مناسب جریان ورودی به مخزن سد تعیین نمود. هر یک از این الگوها توسط مدل ANFIS و مدل توسعه داده شده آن (HHO-ANFIS) اجرا و توسط معیارهای ارزیابی خطا که به صورت روابط آماری و گرافی هستند تحلیل شدند. در نهایت مناسب‌ترین مدل پیش‌بینی کننده به همراه الگوی مناسب





شکل ۳- روش انجام این پژوهش

Fig. 3 Research flowchart

پارامتر جریان ورودی به مخزن سد با یک ماه تأخیر و بارش تشکیل شده است (جدول ۳). اگر به همین ترتیب و بر اساس ارزش‌های ضریب همبستگی الگوها را تدوین کرد جدولی کامل شده از ترکیبات مختلف پارامترهای ورودی تشکیل می‌گردد. بدین صورت می‌توان هر الگو را به‌طور جداگانه به-وسیله مدل‌های در نظر گرفته‌شده اجرا و نتایج را تحلیل نمود.

در جدول (۲) نتایج ضریب همبستگی نشانگر آن است که جریان ورودی به مخزن سد با یک ماه تأخیر و بارش بیشترین همبستگی را با پارامتر خروجی دارند. با این وجود می‌توان جدول (۳) را با الگوی اول که فقط شامل پارامتر ورودی جریان ورودی به مخزن سد با یک ماه تأخیر را انتخاب کرد. الگوی دوم نیز شامل پارامتر ورودی بارش می-باشد. الگوی سوم نیز با توجه به ضریب همبستگی از دو

جدول ۲- ضریب همبستگی بین پارامترهای ورودی و خروجی

Table 2 Correlation coefficient between input and output parameters

Parameters	Qn	T	P	Qn-1	Qn-2	Qn-3
Qn	1					
T	-0.28	1				
P	0.55	-0.57	1			
Qn-1	0.56	-0.01	0.17	1		
Qn-2	0.15	0.27	-0.12	-0.56	1	
Qn-3	-0.06	-0.50	-0.33	-0.14	-0.56	1

\*Inlet flow to the reservoir dam (Qn), Inlet flow to the dam a month's lag (Qn-1), Inlet flow to the dam two months lag (Qn-2), Inlet flow to the dam three months lag (Qn-3), Temperature (T), and Precipitation (P)

جدول ۳- تدوین الگوهای مختلف ورودی

Table 3 Compilation of different input patterns

Pattern name	Input patterns	Output parameter
P1	Inlet flow to the dam a month lag	Inlet flow to the dam reservoir at the end of the month
P2	Precipitation	
P3	Inlet flow to the dam a month lag + precipitation	
P4	Inlet flow a month lag + precipitation + inlet flow to the dam two months lag	
P5	Inlet flow a month lag + precipitation + inlet flow to the dam two months lag + temperature	
P6	Inlet flow a month lag + precipitation + inlet flow to dam two months lag + Temperature + inlet flow to dam three months lag	

الگوهای تدوین شده توسط مدل‌های در نظر گرفته‌شده به‌صورت مجزا اجرا شدند.

## ۲-۳- مدل ANFIS

تدوین قوانین بهره می‌برد. به مانند سامانه استنتاج فازی از دو نوع استنتاج فازی Mamdani و Sugeno می‌توان برای مشخص کردن خروجی در ANFIS استفاده کرد که استفاده از روش سوگنو ارجح‌تر می‌باشد (Jang 1993). برای دو نوع پارامتر ورودی مانند  $x_1$  و  $x_2$  از نوع سوگنو و با قوانین If-Then فازی، با خروجی  $y$ ، ساختار ANFIS را می‌توان به صورت رابطه‌های (۱) و (۲) توصیف کرد:

$$\text{If } (x_1 \text{ is } A_1) \text{ and } (x_2 \text{ is } B_1) \text{ then } f_1 = p_1x_1 + q_1x_2 + r_1 \quad (1)$$

$$\text{If } (x_1 \text{ is } A_2) \text{ and } (x_2 \text{ is } B_2) \text{ then } f_2 = p_2x_1 + q_2x_2 + r_2 \quad (2)$$

را محاسبه می‌کند. این لایه نتایج هر قانون فازی را طی فرآیند غیرفازی سازی به خروجی غیرفازی تغییر شکل می‌دهد.

## ۲-۴- الگوریتم HHO

یکی از جدیدترین و قوی‌ترین الگوریتم‌های بهینه‌سازی است که در سال ۲۰۱۹ مطرح گردید (Heidari et al. 2019). این الگوریتم الهام گرفته از طبیعت و مبتنی بر جمیعت است که برگرفته از شکار خرگوش توسط شاهین هریس می‌باشد. این الگوریتم نسبت به سایر الگوریتم‌های مشابه کمی پیچیده‌تر و از مراحل مختلفی برای رسیدن به همگرایی استفاده می‌کند.

## ۲-۴-۱- مراحل انجام الگوریتم HHO

در HHO، شاهین‌های هریس به‌طور تصادفی در برخی مکان‌ها طعمه‌ای را بر اساس دو استراتژی شناسایی می‌کند. موقعیت این مکان‌ها از رابطه (۳) به دست می‌آید (Heidari et al. 2019).

$$X(t+1) = \begin{cases} X_{rand}(t) - r_1 | X_{rand}(t) - 2r_2 X(t) | \\ (X_{rabbit}(t) - X_m(t)) - r_3 (LB + r_4 (UB - LB)) \end{cases} \quad (3)$$

در معادله بالا  $X_i(t)$  محل قرارگیری هر شاهین را با تکرار  $t$  نشان می‌دهد و  $N$  تعداد کل شاهین‌ها را نشان می‌دهد. انرژی طعمه در طی رفتار فراری به میزان قابل توجهی کاهش می‌یابد. برای مدل‌سازی این واقعیت، انرژی یک طعمه به صورت رابطه (۵) مدل می‌شود (Heidari et al. 2019):

$$E = 2E_0 \left( 1 - \frac{t}{T} \right) \quad (5)$$

که،  $E$  نشان‌دهنده فرار انرژی از طعمه است،  $T$  حداکثر تعداد تکرار است و  $E_0$  حالت اولیه انرژی آن است. در HHO،  $E_0$  به‌طور تصادفی در داخل بازه (۱ تا -۱) در هر تکرار تغییر می‌کند. برای مدل‌سازی محاصره سخت، از پارامتر  $E$

مدل ANFIS از تلفیق دو مدل شبکه عصبی مصنوعی و سامانه استنتاج فازی به وجود آمد. این مدل به‌منظور استفاده از عملکرد مدل شبکه عصبی مصنوعی و سامانه استنتاج فازی برای بهبود دقت شبیه‌سازی ارائه شد (Jang 1993). این مدل همانند شبکه عصبی از لایه‌های مختلف تشکیل شده است و از طرفی همانند سامانه استنتاج فازی از

که،  $A$  و  $B$  به ترتیب مجموعه‌های فازی هستند،  $p$  و  $q$  و  $r$  پارامترهای بعدی مدل هستند که در مرحله آموزش ارزیابی می‌شوند. ساختار ANFIS از پنج لایه مختلف بهره می‌برد. در لایه اول، ورودی‌ها از توابع عضویت مختلف عبور کرده و درجه عضویت گره‌های ورودی به بازه‌های مختلف فازی مشخص می‌گردد. توابع مثلثی، ذوزنقه‌ای، گوسی و تابع زنگوله‌ای از انواع توابع عضویت فازی هستند که در تحقیقات مختلف مورد استفاده قرار می‌گیرد. در لایه دوم یا گره قاعده که در آن مقادیر ورودی به هر گره در هم ضرب شده و حاصل که وزن قانون‌ها می‌باشد به دست می‌آید. در این لایه می‌توان از عملگرهای AND یا OR استفاده کرد. در این تحقیق از عملگر "AND" استفاده شده است. لایه سوم، گره‌های این لایه وزن قانون‌ها را نرمال‌سازی می‌کند. گره‌های نتیجه که لایه قوانین نامیده می‌شود و در این لایه قانون‌ها به دست می‌آیند. در نهایت لایه پنجم یک تک گره بوده که با جمع کردن همه مقادیر ورودی به آن، خروجی کلی سیستم  $q \geq 0.5$   $q < 0.5$   $(3)$

که،  $X(t+1)$  بردار موقعیت شاهین‌ها در تکرار بعدی  $t$  است،  $X_{rabbit}(t)$  موقعیت خرگوش است،  $X(t)$  بردار موقعیت فعلی شاهین‌ها است،  $r_1, r_2, r_3, r_4$  و  $q$  اعداد تصادفی بین (۰-۱) هستند، که در هر تکرار به‌روز می‌شوند،  $UB$  و  $LB$  مرزهای بالا و پایین متغیرها را نشان می‌دهند،  $X_{rand}(t)$  یک شاهین است که به‌طور تصادفی از جمعیت فعلی انتخاب شده است و  $X_m$  موقعیت متوسط جمعیت فعلی شاهین‌ها است. موقعیت متوسط شاهین‌ها با استفاده از رابطه (۴) به دست می‌آید (Heidari et al. 2019):

$$X_m(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \quad (4)$$

که در آن  $u$  و  $\hat{1}$  مقادیر تصادفی در بازه  $(0-1)$  هستند،  $\beta$  یک عدد ثابت پیش‌فرض  $1/5$  است. از این‌رو استراتژی نهایی برای به‌روزرسانی موقعیت شاهین‌ها در مرحله محاصره نرم می‌تواند به‌وسیله رابطه  $(12)$  انجام شود (Heidari et al. 2019).

$$X(t+1) = \begin{cases} Y & \text{if } F(Y) < F(X(t)) \\ Z & \text{if } F(Z) < F(X(t)) \end{cases} \quad (12)$$

که،  $Y$  و  $Z$  با استفاده از رابطه‌های  $(9)$  و  $(10)$  به‌دست می‌آیند. در این پژوهش از الگوریتم HHO برای آموزش و بهبود ساختار ANFIS استفاده شده است. بنابراین در این ساختار تابع هدف، به حداقل رساندن اختلاف بین مقادیر مشاهده‌شده و پیش‌بینی شده است. در ساختار بهبود داده‌شده، نحوه تدوین قوانین و توابع عضویت فازی توسط الگوریتم مذکور در تکرارهای مختلف به مقدار بهینه نزدیک می‌گردد. در نهایت میزان جریان ورودی به مخزن توسط مدل آموزش‌دیده پیش‌بینی شده است.

## ۲-۵- معیارهای ارزیابی خطا

برای ارزیابی الگوها و مدل‌های مورداستفاده از چندین معیارهای ارزیابی خطا از جمله جذر میانگین مربعات خطا<sup>۱</sup> (RMSE) (رابطه ۱۳)، میانگین خطای مطلق<sup>۲</sup> (MAE) (رابطه ۱۴) به همراه ضریب ناش ساتکلیف<sup>۳</sup> (NSE) (رابطه ۱۵) استفاده شده است (Kayhomayoon et al. 2021a).

$$RMSE = \left( \frac{1}{n} \sum_{i=1}^n (x_p - x_o)^2 \right)^{1/2} \quad (13)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_p - x_o| \quad (14)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (x_p - x_o)^2}{\sum_{i=1}^n (x_o - \bar{x}_o)^2} \quad (15)$$

که در آن  $X_o$  مقادیر مشاهده‌شده،  $X_p$  مقادیر پیش‌بینی شده و  $n$  تعداد نمونه‌ها است. هر چه RMSE و MAE کمتر و NSE بالاتر باشد، عملکرد مدل بهتر است.

الگوریتم HHO استفاده شده است. در این رابطه، هنگامی که  $E \geq 0.5$ ، محاصره نرم رخ می‌دهد و هنگامی که  $E < 0.5$  محاصره سخت رخ می‌دهد. در محاصره نرم اگر  $r \geq 0.5$  باشد خرگوش هنوز انرژی کافی دارد و سعی می‌کند با پرش‌های گمراه‌کننده تصادفی فرار کند. شاهین‌های هریس آن را به آرامی محاصره می‌کنند تا خرگوش بیشتر خسته شود و سپس پرش غافلگیرانه را انجام دهد. این رفتار با رابطه‌های  $(6)$  و  $(7)$  الگوبرداری می‌شود (Heidari et al. 2019):

$$X(t+1) = \Delta X(t) - E |JX_{rabbit}(t) - X(t)| \quad (6)$$

$$\Delta X(t) = X_{rabbit}(t) - X(t) \quad (7)$$

که،  $\Delta X(t)$  تفاوت بین بردار موقعیت خرگوش و مکان فعلی در تکرار  $t$  است،  $J = 2(1-r_5)$  قدرت پرش تصادفی خرگوش را در تمام مراحل فرار نشان می‌دهد و  $r_5$  یک عدد تصادفی در بازه  $(0-1)$  می‌باشد اما در محاصره سخت اگر  $r \geq 0.5$  باشد طعمه بسیار خسته شده و انرژی فرار کمی دارد و شاهین‌های هریس به‌سختی طعمه موردنظر را محاصره می‌کنند تا سرانجام ضربه شگفت‌آور را انجام دهند. در این وضعیت، موقعیت‌های فعلی با استفاده از رابطه  $(8)$  به‌روز می‌شوند (Heidari et al. 2019).

$$(t+1) = X_{rabbit}(t) - E |\Delta X(t)| \quad (8)$$

برای انجام یک محاصره نرم، شاهین‌ها می‌توانند حرکت بعدی خود را براساس قانون زیر در رابطه  $(9)$  ارزیابی کنند (Heidari et al. 2019):

$$Y = X_{rabbit}(t) - E |JX_{rabbit}(t) - X(t)| \quad (9)$$

آن‌ها براساس الگوی مبتنی بر LF با استفاده از رابطه  $(10)$  تبعیت می‌کنند (Heidari et al. 2019):

$$Z = Y + S \times LF(D) \quad (10)$$

که در آن  $D$  بعد مسئله و  $S$  یک بردار تصادفی با اندازه  $D$  و LF تابع پرواز دریافتی است که با استفاده از معادله  $(11)$  محاسبه می‌شود (Heidari et al. 2019):

$$LF(x) = 0.01 \times \frac{u \times \sigma}{|v|^{1/\beta}}, \sigma = \left( \frac{\Gamma(1+\beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \times \beta \times 2^{\left(\frac{\beta-1}{2}\right)}} \right)^{1/\beta} \quad (11)$$

<sup>۱</sup>Root Mean Square Error

<sup>۲</sup>Mean Absolute Error

<sup>۳</sup>Nash-Sutcliffe Efficiency Coefficient



## ۳- یافته‌ها و بحث

ANFIS مشاهده گردید که اختلاف خطای زیادی بین نتایج آموزش و آزمون در اکثر الگوهای ورودی وجود دارد. به نوعی مدل مذکور به خوبی آموزش داده شده است اما در تخمین مقادیر داده‌های به جز داده‌های آموزش دچار خطای زیادی شده است. به اصطلاح به هنگام آموزش در نقاط محلی بهینه‌سازی به دام می‌افتد.

جدول ۴- پارامترهای بهینه‌شده مدل ANFIS و HHO-

## ANFIS

Table 4 Optimized parameters of ANFIS and HHO-ANFIS models

Model	Parameter	value
	Fuzzy structure	Sugeno-type
	Initial FIS for training	Genfis3
	The type of membership functions	Gaussian
ANFIS	The membership function of output	Linear
	Optimization method	Hybrid
	Number of fuzzy rules	10
	The maximum number of epochs	2000
	Number of search agent	40
	Iteration number	2000
HHO	$\beta$	1.5
	Range partitions (weights and biases)	[3,-3]
	Population size	30

هر یک از مدل‌های مورداستفاده نیاز به تنظیم برخی پارامترهای خود می‌باشند. مقادیر تنظیمی این مدل‌ها در واقع ساختار مدل را تکمیل و موجب عملکرد بهتر مدل‌ها در پیش‌بینی می‌شوند. ساختار مناسب مدل ANFIS و مقادیر بهینه برای پارامترهای آن توسط آموزش مدل تعیین گردید. این مقادیر در جدول (۴) قابل مشاهده می‌باشد. مطابق جدول تابع عضویت گوسی مناسب‌ترین تابع عضویت فازی انتخاب گردید. از آنجایی که در ANFIS از نوع فازی سوگنو استفاده شده و خروجی آن به صورت تابع می‌باشد، در نتیجه بهترین نوع تابع خروجی، خطی مرتبه اول انتخاب شد. بقیه پارامترهای بهینه در جدول (۴) قابل مشاهده می‌باشند. در الگوریتم HHO رسیدن به مقادیر مناسب برای هر پارامتر نیازمند اجرای مدل با مقادیر متفاوت بوده به مشخص شدن مقادیر مناسب پارامترها برای مسئله موردنظر ختم می‌گردد. جمعیت در نظر گرفته شده برای HHO حدود ۳۰ نفر و حداکثر تکرار در نظر گرفته شده نیز ۲۰۰۰ تکرار می‌باشد. مقدار  $\beta$  نیز برابر ۱/۵ در نظر گرفته شد ( Heidari et al. 2019).

معیارهای ارزیابی خطا در جدول (۵) نشان می‌دهد که نتایج دو مدل به کار گرفته شده بسیار متفاوت از هم هستند. همچنین در بررسی نتایج الگوهای ورودی مختلف در مدل

جدول ۵- نتایج معیارهای ارزیابی خطا در مدل ANFIS و HHO-ANFIS در الگوهای ورودی مختلف\*

Table 5 Results of error evaluation criteria in ANFIS and HHO-ANFIS models in different input models

Pattern name	Model	NSE		MAE (MCM)		RMSE (MCM)	
		Test	Train	Test	Train	Test	Train
P1	ANFIS	-0.08	0.55	6.10	4.48	11.80	8.65
	HHO-ANFIS	0.62	0.59	4.70	4.54	8.00	7.75
P2	ANFIS	0.34	0.57	6.00	4.79	10.46	8.31
	HHO-ANFIS	0.72	0.72	4.47	4.38	6.96	6.83
P3	ANFIS	0.00	0.77	4.87	3.10	12.5	5.96
	HHO-ANFIS	0.60	0.80	2.86	3.14	6.60	5.88
P4	ANFIS	0.55	0.85	5.42	2.61	8/59	4.62
	HHO-ANFIS	0.74	0.76	3.77	3.25	5.88	5.90
P5	ANFIS	-0.49	0.97	8.00	1.26	15.0	2.15
	HHO-ANFIS	-0.71	0.87	3.60	2.27	6.25	4.54
P6	ANFIS	-0.26	0.92	6.75	1.40	16.24	3.04
	HHO-ANFIS	0.86	0.90	2.41	2.00	3.90	4.17

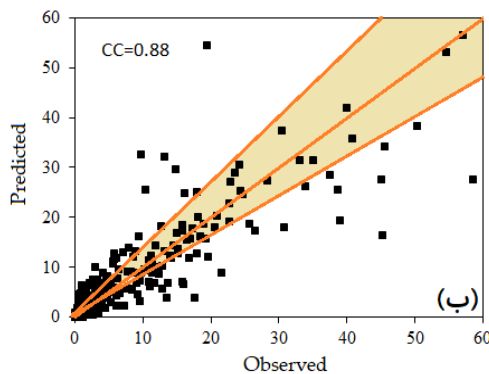
\*مدل و سناریوی برتر با خطوط پررنگ (بولد) مشخص شده است.

توانایی پیش‌بینی مناسب این مدل و قابل اعتماد بودن آن می‌باشد. از بین الگوهای ورودی مختلف، الگوی ششم که شامل تمام پارامترهای ورودی بود مناسب‌ترین الگو انتخاب شد. در این الگو مقادیر RMSE، MAE و NSE برای داده‌های آزمون به ترتیب برابر ۳/۹ MCM، ۲/۴۱ MCM و

با این وجود در این مدل الگوی ششم که شامل تمام پارامترهای ورودی بود از دقت بهتری خصوصاً در قسمت آموزش برخوردار بوده است. نتایج الگوها در مدل HHO-ANFIS نشان داد که تقریباً اختلاف کمی بین داده‌های آموزش و آزمون وجود دارد. لذا این امر بیانگر دو نکته مهم،




نمودار مربوط به مدل ANFIS وجود دارد (شکل ۴-الف). پراکندگی چند نقطه در این نمودار که حکایت از تخمین غیرمنطقی مقدار جریان ورودی به مخزن سد را دارد، موجب شده است تا تراکم نقاط نسبت به خط  $y = x$  کاهش یافته و ضریب همبستگی آن به مقدار قابل‌توجهی کاهش داشته باشد به طوری که به مقدار  $0.67$  برسد. متراکم‌ترین نقاط نسبت به خط رگرسیون به HHO-ANFIS تعلق داشته است که نشان می‌دهد مقدار تخمین با مقادیر بهینه‌شده بیشترین همخوانی را دارد. همچنین در شکل (۴-ب) موقعیت نقاط کمی خارج از خط‌های  $y = 1.25x$  و  $y = 0.75x$  قرار دارند. اما موقعیت بیشتر نقاط در شکل (۴-الف) خارج از دو محدوده دو خط مذکور هستند. بنابراین نتایج این نمودار حاکی از عملکرد ضعیف مدل ANFIS بوده که در برخی گام‌ها مقادیر غیرقابل قبول را تخمین می‌زند.




۰/۸۶ بود. الگوی پنجم با مشارکت همه پارامترهای ورودی به‌جز جریان ورودی به مخزن سد با سه ماه تأخیر نزدیک‌ترین الگو به الگوی منتخب بود. در این الگو مقادیر RMSE, MAE و NSE برای داده‌های آزمون به ترتیب برابر  $6/25$  MCM,  $3/60$  و  $0/71$  به دست آمد. در هر دو مدل و در الگوهای P1 تا P3 دقت پیش‌بینی ضعیف‌تری نسبت به الگوهای ورودی با پارامترهای ورودی بیشتر برخوردار بودند. این نکته نشان می‌دهد که برای پیش‌بینی جریان ورودی به مخزن سد بهتر آن است تا پارامترهای هواشناسی نیز در نظر گرفته شده صرفاً با داشتن جریان ورودی به مخزن در تأخیر ماه‌های مختلف نمی‌توان به دقت پیش‌بینی مناسبی دست یافت.

شکل (۴) نمودار نقطه‌ای مقادیر مشاهداتی در مقابل مقادیر پیش‌بینی شده نشانگر آن است که موقعیت غیرمنطقی در



شکل ۴- نمودار نقطه‌ای داده‌های مشاهداتی در مقابل داده‌های پیش‌بینی شده، الف- ANFIS، و ب- HHO-ANFIS

Fig. 4 Diagram of observational data vs predicted data, a) ANFIS, and b) HHO-ANFIS



شکل ۵- دیاگرام تیلور

Fig. 5 Taylor diagram

مقدار RMSD برای مدل HHO-ANFIS بسیار نزدیک‌تر به داده‌های مشاهداتی می‌باشد. موقعیت مدل ANFIS به

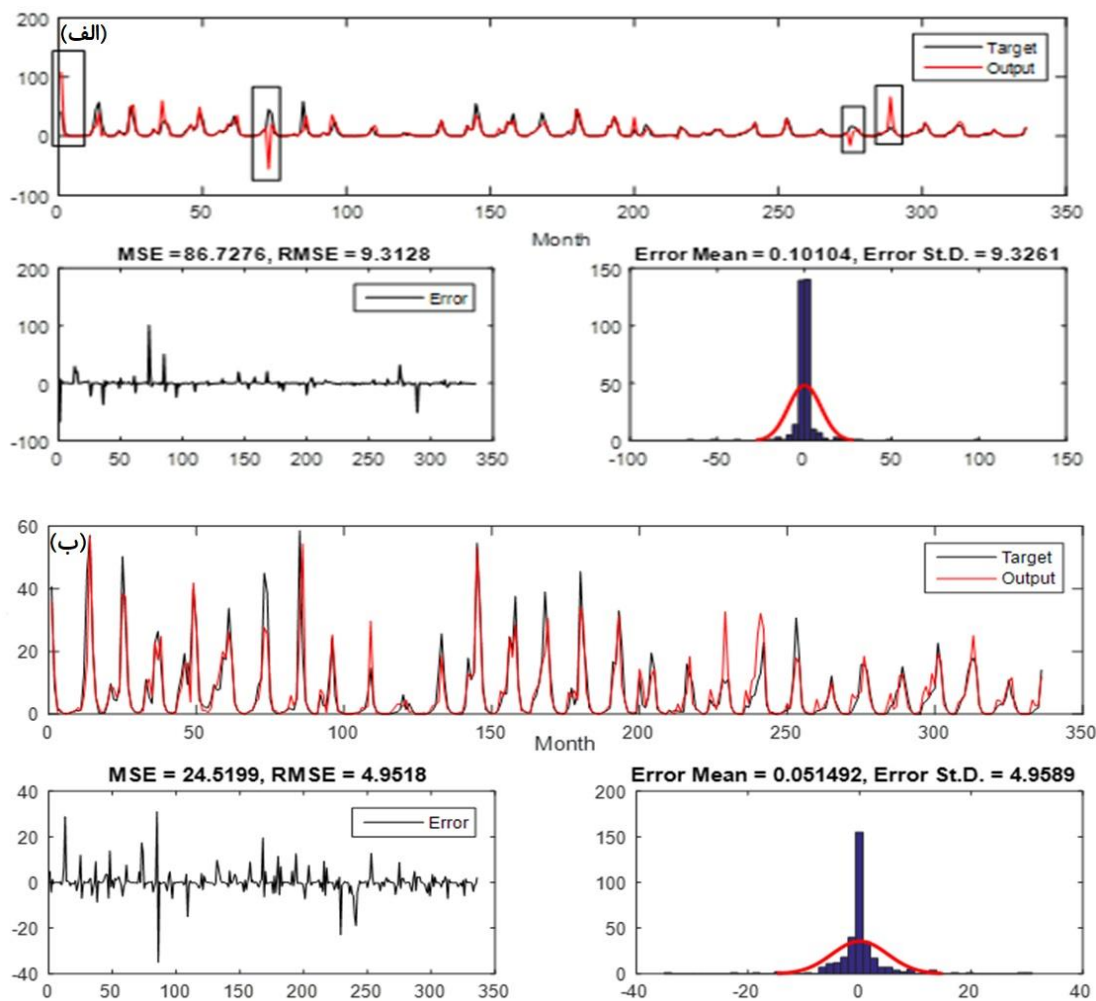
برای بررسی دقیق‌تر پیش‌بینی‌های صورت گرفته از دیاگرام تیلور استفاده گردید. مطابق شکل (۵) در دیاگرام تیلور محور افقی و عمودی بیانگر مقدار ضریب تغییرات و کمان ربع دایره نیز بیانگر ضریب همبستگی می‌باشد. کمان‌هایی که در داخل ربع دایره کشیده شده‌اند نیز بیانگر مقدار جذر میانگین مربعات انحراف معیار (RMSD)<sup>۱</sup> می‌باشد. هرچه قدر که مقادیر این شاخص‌ها برای هر یک از مدل‌ها به مقادیر داده‌های مشاهداتی نزدیک‌تر باشد بیانگر مناسب بودن مدل است. نتایج نشان می‌دهد HHO-ANFIS نسبت به روش ANFIS در اولویت و کارایی بهتری قرار دارد. مقدار ضریب همبستگی بین مقادیر مشاهداتی و مدل HHO-ANFIS در حدود  $0/9$  است. مقدار ضریب تغییرات ANFIS-HHO در حدود  $0/7$  می‌باشد که بسیار به مقدار ضریب تغییرات داده‌های مشاهداتی نزدیک‌تر است.

<sup>1</sup>Root Mean Square Deviation

دلیل تخمین داده‌های خارج از محدوده در برخی گام‌ها متفاوت از موقعیت داده‌های مشاهداتی است. در این مدل ضریب همبستگی در حدود ۰/۷ بوده که اختلاف نسبتاً زیادی با موقعیت مدل HHO-ANFIS دارد. بدین صورت همانند سایر پارامترها ارزیابی صورت گرفته مدل هیبریدی HHO-ANFIS از دقت بسیار بالایی نسبت به ANFIS برخوردار می‌باشد.

در نهایت سری زمانی پیش‌بینی و مشاهده‌شده کل داده‌های دوره مورد بررسی توسط الگو و مدل منتخب ترسیم گردید (شکل ۶). در مدل ANFIS (شکل ۶- الف) وجود اختلاف زیاد بین مقادیر مشاهداتی و تخمین زده شده مشهود است. همچنین این مدل توانسته این مقادیر جریان پایه را به خوبی تخمین زند اما در برخی گام‌ها مقادیر تخمین خارج از محدوده معقول است. همین اختلاف زیاد در برخی گام‌ها به دست آمده است تا این مدل عملکرد ضعیف‌تری نسبت به

در نهایت سری زمانی پیش‌بینی و مشاهده‌شده کل داده‌های دوره مورد بررسی توسط الگو و مدل منتخب ترسیم گردید (شکل ۶). در مدل ANFIS (شکل ۶- الف) وجود اختلاف زیاد بین مقادیر مشاهداتی و تخمین زده شده مشهود است. همچنین این مدل توانسته این مقادیر جریان پایه را به خوبی تخمین زند اما در برخی گام‌ها مقادیر تخمین خارج از محدوده معقول است. همین اختلاف زیاد در برخی گام‌ها به دست آمده است تا این مدل عملکرد ضعیف‌تری نسبت به



شکل ۶- سری زمانی ترسیم‌شده داده‌های واقعی و داده‌های پیش‌بینی‌شده، الف- مدل ANFIS، ب- مدل HHO-ANFIS

Fig. 6 Drawn time series of real data and predicted data, a) ANFIS model, b) HHO-ANFIS model

یادگیری ماشین حاکی از موارد مثبتی در پیش‌بینی بود که می‌توان به موارد ذیل اشاره کرد:

۱- مدل هیبریدی HHO-ANFIS نسبت به مدل واحد آن (ANFIS) در پیش‌بینی مقدار جریان ورودی به مخزن سد عملکرد مناسب‌تری داشت.

۲- تحلیل پارامترهای ورودی نشان داد که الگوی P6 با پارامترهای دما، بارش و میزان جریان ورودی به مخزن سد با تأخیر یک تا سه ماهه نتایج بهتری را ارائه می‌دهد.

۳- مدل ANFIS در برخی گام‌های مقادیر تخمین غیرمنطقی در داده‌های بخش آزمون داشت و به همین دلیل نتایج بخش آزمون آن همواره با خطای قابل‌توجهی همراه است.

۴- برای پیش‌بینی مناسب میزان جریان ورودی به مخازن سدها علاوه بر داده‌های جریان ورودی به مخزن با تأخیرهای مختلف، اطلاعات هواشناسی نیز موردنیاز می‌باشد.

استفاده از مدل منفرد ANFIS با توجه به نتایج این پژوهش برای سایر پژوهش‌های مشابه توصیه نمی‌گردد. با توجه به نتایج به‌دست‌آمده هنگام استفاده از ANFIS برای پیش‌بینی سری‌های زمانی ترکیب آن با الگوریتم‌های تکاملی پیشنهاد می‌گردد. در نظر گرفتن عدم قطعیت مدل‌های مورد استفاده، استفاده از پارامترهای ورودی بیش‌تر مانند تبخیر، میزان ذوب برف، بررسی اثرات تغییر اقلیم بر میزان ورودی جریان به مخازن سدها از جمله پیشنهادهایی هست که جهت تکمیل این پژوهش توصیه می‌گردد.

#### دسترسی به داده‌ها

داده‌ها حسب درخواست، از طرف نویسنده مسئول از طریق ایمیل (m-najarchi@iau-arak.ac.ir) قابل‌ارسال است.

#### تضاد منافع نویسندگان

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

ارزیابی پیش‌بینی جریان ورودی به مخزن سد با استفاده از روش‌های یادگیری ماشین براساس الگوهای مختلف پارامترهای ورودی مورد آنالیز قرار گرفت. نتایج رویکردهای مختلف حاکی از دقت مناسب نتایج HHO-ANFIS بوده و پیش‌بینی‌های انجام‌شده نشان‌دهنده نقش پارامترهای مختلف و کاهش عدم قطعیت نتایج این مدل است. به‌طورکلی مقادیر حداکثرهای سری زمانی شبیه‌سازی‌شده همواره دارای خطای بیشتری نسبت به حداقل‌ها بوده است. بررسی مطالعات انجام‌شده در استفاده از مدل هیبریدی پیشنهادی نیز حاکی از دقت مناسب این مدل و توانایی الگوریتم HHO در بهبود ساختار ANFIS در سایر موضوعات مشابه بوده که بر اساس مطالعات (Azar et al. 2021) et al. مدل‌های یادگیری ماشین HHO-ANFIS عملکرد بسیار مناسبی را نسبت به ANFIS در پیش‌بینی مقدار ضریب پخشیدگی طولی رودخانه داشته است.

مطالعات (Milan et al. 2021) و (2021a,b)

Kayhomayoon et al. نیز حاکی از برتری مدل هیبریدی پیشنهادی به ترتیب در پیش‌بینی برداشت بهینه از آبخوان و کسری حجم مخازن آبخوان‌ها بوده است که هر دو تحقیق ذکرشده تأیید کننده نتایج این تحقیق می‌باشند. چراکه در تحقیقات (Arya Azar et al. 2021b) نیز الگوریتم‌های تکاملی توانستند دقت ANN را در پیش‌بینی تبخیر به‌صورت قابل‌توجهی بهبود ببخشند. در این تحقیق از دو پارامتر ورودی هواشناسی برای پیش‌بینی استفاده‌شده بود، علیرغم نتایج قابل‌قبول اما برای نتایج بهتر و ارزیابی تأثیر سایر پارامترهای هواشناسی نیز مورد ارزیابی قرار گیرد.

#### ۴- نتیجه‌گیری

در این پژوهش بررسی و ارزیابی تخمین مقدار جریان ورودی به مخزن سد با استفاده از مدل ANFIS و مدل هیبریدی توسعه داده شده ANFIS توسط الگوریتم HHO انجام شد. برای پیش‌بینی شش الگوی مختلف و پنج پارامتر بارش ماهانه، دمای ماهانه و جریان ورودی به مخزن سد با تأخیر یک تا سه ماهه به عنوان پارامترهای ورودی تعریف و مورد استفاده قرار گرفت. بررسی نتایج شبیه‌سازی در رویکرد

## References

Abbasi, M., Araghinejad, S. and Ebrahimi, K. (2019). Evaluation of Moving Average Pre-processing Approach to Improve the Efficiency of Support Vector Regression

Model for Inflow Prediction. Iran. J. Soil Water Res., 50(1), 247-258. [In Persian] DOI: 10.22059/ijswr.2018.250803.667838

Arya Azar, N., Ghordoyee Milan, S., and



- Kayhomayoon, Z. (2021a). Predicting monthly evaporation from dam reservoirs using LS-SVR and ANFIS optimized by Harris hawks optimization algorithm. *Environ. Monit. Assess.*, 193(11), 1-14. DOI: 10.1007/s10661-021-09495-z
- Arya Azar, N., Kardan, N., and Ghordoyee Milan, S. (2021b). Developing the artificial neural network–evolutionary algorithms hybrid models (ANN–EA) to predict the daily evaporation from dam reservoirs. *Eng. Comput.*, 1-19. DOI: 10.1007/s00366-021-01523-3
- Awchi, T. A. (2014). River discharges forecasting in Northern Iraq using different ANN techniques. *Water Resour. Manag.*, 28 (3), 801–814. DOI: 10.1007/s11269-014-0516-3
- Azar, N. A., Milan, S. G. and Kayhomayoon, Z. (2021). The prediction of longitudinal dispersion coefficient in natural streams using LS-SVM and ANFIS optimized by Harris hawk optimization algorithm. *J. Contam. Hydrol.*, 240, 103781. DOI: 10.1016/j.jconhyd.2021.103781
- Chu, H. J. and Chang, L. C. (2009). Application of optimal control and fuzzy theory for dynamic groundwater remediation design. *Water Resour. Manag.*, 23(4), 647–660. DOI: 10.1007/s11269-008-9293-1
- Di, C., Yang, X., and Wang, X. (2014). A four-stage hybrid model for hydrological time series forecasting. *PLoS ONE* 9 (8), e104663. DOI: 10.1371/journal.pone.0104663
- Ghordoyee Milan, S., Bahmani, S., Salimi, H., and Gorbani, M. A. (2021). Development of a hybrid adaptive neuro fuzzy inference system-harris hawks optimizer (ANFIS-HHO) model to predict soil cation exchange capacity. *Environ. Water Eng.*, 7(2), 304-317. [In Persian] DOI: 10.22034/jewe.2021.254271.1447
- Ghordoyee Milan, S., Roozbahani, A., Banihabib, M. E., and Javadi, S. (2018). Developing fuzzy optimization model for conjunctive use of surface and ground water, case study: Astaneh-Koch Esfahan Plain. *Iran. J. Ecohydrol.*, 5(3), 891-905. [In Persian] DOI: 10.22059/ije.2018.250098.807
- He, Z., Wen, X., Liu, H. and Du, J. (2014). A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semi arid mountain region. *J. Hydrol.*, 509, 379-386. DOI: 10.1016/j.jhydrol.2013.11.054
- Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M. and Chen, H. (2019). Harris hawks optimization: Algorithm and applications. *Fut. Generat. Comput. Syst.*, 97, 849-872. DOI: 10.1016/j.future.2019.02.028
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Trans. Syst. Man. Cybernet.*, 23(3), 665-685. DOI: 10.1109/21.256541
- Kayhomayoon, Z., Azar, N. A., Milan, S. G., Moghaddam, H. K. and Berndtsson, R. (2021a). Novel approach for predicting groundwater storage loss using machine learning. *J. Environ. Manag.*, 296, 113237. DOI: 10.1016/j.jenvman.2021.113237
- Kayhomayoon, Z., Ghordoyee Milan, S., Arya Azar, N. and Kardan Moghaddam, H. (2021b). A new approach for regional groundwater level simulation: clustering, simulation, and optimization. *Nat. Resour. Res.*, 30(6), 4165-4185. DOI: 10.1007/s11053-021-09913-6
- Mahmoudi, N., Majidi, A., Jamei, M., Jalali, M., Maroufpoor, S., Shiri, J. and Yaseen, Z. M. (2022). Mutating fuzzy logic model with various rigorous meta-heuristic algorithms for soil moisture content estimation. *Agri. Water Manag.*, 261, 107342. DOI: 10.1016/j.agwat.2021.107342
- Milan, S. G., Roozbahani, A. and Banihabib, M. E. (2018). Fuzzy optimization model and fuzzy inference system for conjunctive use of surface and groundwater resources. *J. Hydrol.*, 566, 421-434 DOI: 10.1016/j.jhydrol.2018.08.078
- Milan, S. G., Roozbahani, A., Azar, N. A. and Javadi, S. (2021). Development of adaptive neuro fuzzy inference system–Evolutionary algorithms hybrid models (ANFIS-EA) for prediction of optimal groundwater exploitation. *J. Hydrol.*, 598, 126258. DOI: 10.1016/j.jhydrol.2021.126258
- Misaghi, F. (2016). Forecasting of the alavian dam inflow water using optimized adaptive neuro-fuzzy inference system (Oanfis). *Iran. J. Soil Water Res.*, 47(3), 439–448 [In Persian]





- Persian]. DOI: 10.22059/IJSWR.2016.59314
- Moazami, S., Noori, R., Vesali Naseh, M. and Akbarzadeh, A. (2020). Proper orthogonal decomposition performance to determine the inputs to the artificial neural network for prediction of inflow into Alavian Dam. *J. Environ. Sci. Technol.*, 22(7), 375-387. DOI: 10.22034/jest.2019.21920.3101
- Moghaddam, H. K., Milan, S. G., Kayhomayoon, Z. and Azar, N. A. (2021). The prediction of aquifer groundwater level based on spatial clustering approach using machine learning. *Environ. Monit. Assess.*, 193(4), 1-20. DOI: 10.1007/s10661-021-08961-y
- Nikolos, I. K., M. Stergiadi, M. P. Papadopoulou, and G. P. Karatzas (2008), Artificial neural networks as an alternative approach to groundwater numerical modelling and environmental design. *Hydrol. Proces.*, 22(17), 3337– 3348. DOI: 10.1002/hyp.6916
- Noorbeh, P., Roozbahani, A., Kardan Moghaddam, H. (2018). Prediction of Zayandeh Rood Dam inflow and hydrological wet and dry periods using Bayesian networks. *Water Soil*, 32(3), 633-646. [In Persian] DOI: 10.22067/jsw.v32i3.72084
- Panahi, M., Khosravi, K., Ahmad, S., Panahi, S., Heddami, S., Melesse, A. M., and Lee, C. W. (2021). Cumulative infiltration and infiltration rate prediction using optimized deep learning algorithms: A study in Western Iran. *J. Hydrol: Region. Stud.*, 35, 100825. DOI: 10.1016/j.ejrh.2021.100825
- Peueot, C., Cappelaere, B., Vieux, B.E., Seguis, L. and Maia, A., (2003). Hydrologic process simulation of a semiarid, endorheic catchment in Sahelian West Niger. 1. Modelaided data analysis and screening. *J. Hydrol.*, 279, 224–243. DOI: 10.1016/S0022-1694(03)00181-1
- Riahi-Madvar, H., Dehghani, M., Memarzadeh, R., & Gharabaghi, B. (2021). Short to long-term forecasting of river flows by heuristic optimization algorithms hybridized with ANFIS. *Water Resour. Manag.*, 35(4), 1149-1166. DOI: 10.1007/s11269-020-02756-5
- Shafaei, M. and Kisi, O. (2017). Predicting river daily flow using wavelet-artificial neural networks based on regression analyses in comparison with artificial neural networks and support vector machine models. *Neur. Comput. Appl.*, 28(1), 15-28. DOI: 10.1007/s00521-016-2293-9
- Shahkarami, N., Sanikhani, H. and Moradi, M. (2016). Forecasting of Inflow to Kamal Saleh Reservoir using Soft Computing. *Irrig. Water Eng.*, 6(2), 48-61 [In Persian]. DOI: 10.22059/IWE.2016.47322
- Zhang, H., Singh, V.P., Wang, B., and Yu, Y., (2016). CEREF: A hybrid data-driven model for forecasting annual streamflow from a socio-hydrological system. *J. Hydrol.*, 540, 246-256. DOI: 10.1016/j.jhydrol.2016.06.029

### How to cite this paper:

Enayati, S. M., Najarchi, M., Mohammadpour, O. and Mirhosseini, S. M. (2022). Development of a hybrid adaptive neuro fuzzy inference system - harris hawks optimizer (ANFIS-HHO) for inlet flow to the dam reservoir prediction. *Environ. Water Eng.*, 8(4), 891–907. DOI: 10.22034/jewe.2022.325678.1716

