



Short Paper

## Efficiency Comparison of Bayesian and MLP Neural Networks in Predicting Runoff to the Taleghan Dam

Zahra Nafariyeh<sup>1</sup>, Mahdi Sarai Tabrizi<sup>2\*</sup>, Hossein Babazadeh<sup>3</sup> and Hamid Kardan Moghaddam<sup>4</sup>

<sup>1</sup>M.Sc. Student, Department of Water Engineering and Sciences, Faculty of Agricultural Sciences and Food Industries, Science and Research Branch, Islamic Azad University, Tehran, Iran

<sup>2</sup>Assist. Professor, Department of Water Engineering and Sciences, Faculty of Agricultural Sciences and Food Industries, Science and Research Branch, Islamic Azad University, Tehran, Iran

<sup>3</sup>Professor, Department of Water Engineering and Sciences, Faculty of Agricultural Sciences and Food Industries, Science and Research Branch, Islamic Azad University, Tehran, Iran

<sup>4</sup>Assist. Professor, Research Institute of the Ministry of Energy, Tehran, Iran

### Article information

Received: June 03, 2021

Revised: October 05, 2021

Accepted: October 06, 2021

### Keywords:

Bayesian Network  
Perceptron Neural Network  
Runoff Prediction  
Taleghan Dam

\*Corresponding author:

[m.sarai@srbiau.ac.ir](mailto:m.sarai@srbiau.ac.ir)



### Abstract

The importance of regulating the supply and demand regime shows the need for planning in the exploitation of surface water resources. The aim of this study was to compare the performance of two models of Bayesian network (BN) with a probabilistic approach and MLP neural network for flow prediction and selection of the best structural model. Monthly meteorological data including rainfall, monthly average temperature, evaporation, and the volume of water transferred from five hydrometric stations were introduced as input data to the models, and runoff to the dam was considered as predictable. Input data with different layouts were introduced to BN and MLP models. The results were obtained by comparing 17 selected models according to the index criteria: Nash-Sutcliffe coefficient (NS), mean square error (MSE), mean square error root (RMSE), and MEAN absolute prediction error (MAPE). The best model in BN model with 43.3% similarity and index criteria was estimated to be -3.98, 300, 17.3, and 0.06, respectively. The MLP model with 80% similarity and index criteria were introduced as -10.3, -8266, 23.9, and 122.3 in the best model, respectively. As a result, both models performed well in runoff estimation, but the BN model had much better accuracy in forecasting. Finally, a structural pattern with acceptable results in both MLP and BN models was identified.

© 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

The importance of regulating the supply and demand regime on the end hand and meeting the environmental needs of the aquifer for river life has highlighted the need for integrated management of water resources with high

flexibility. Water resources management is a complex matter that involves a high level of uncertainty related to climate, economic, and demographic changes in planning for the exploitation of surface resources. The prediction of runoff to the dam has been a great help for



these plans. The aim of this study was to compare the performance of two models of Bayesian network (BN) with a probabilistic approach and MLP neural network for flow prediction. Selecting the best structural model for flow prediction is another goal of the present study.

**Materials and Methods**

To predict the inflow into the dam, a comparison of two models of Bayesian Network (BN) with a probabilistic approach and MLP neural network was used. Monthly meteorological data including average monthly rainfall, temperature, evaporation as well as the volume of water transferred from five hydrometric stations were

introduced as input data to the models, and runoff to the dam was considered as predictable. In order to model the monthly flow, 80% of the data were considered for training, 15% for validation and 5% of the data for validation based on trial and error. Input data with different layouts were introduced to the models. Table (1) presents the structure of the proposed patterns. Meteorological variables of precipitation (R), evaporation (E) and monthly average temperature (T), and discharge variables of Joostenn ( $Q_1$ ), Joosten Alizan ( $Q_2$ ), Joosten Mehran ( $Q_3$ ), Glink ( $Q_4$ ) and Dehdar (Q) stations also flow entry to the dam with a delay of one month was used as a predictor.

Table 1 Selected patterns as the input

Defined Patterns	$Q_{dam(t-1)}$	T	E	R	$Q_5$	$Q_4$	$Q_3$	$Q_2$	$Q_1$
1	✓	✓	✓	✓	✓	✓	✓	✗	✓
2	✓	✓	✓	✗	✓	✓	✓	✓	✓
3	✓	✓	✓	✗	✓	✓	✗	✗	✓
4	✓	✓	✓	✓	✗	✓	✗	✓	✗
5	✓	✗	✗	✓	✓	✓	✓	✓	✓
6	✓	✗	✗	✗	✓	✓	✓	✓	✓
7	✓	✗	✓	✓	✗	✓	✗	✗	✓
8	✓	✓	✓	✓	✓	✓	✗	✓	✓
9	✓	✓	✓	✓	✓	✓	✓	✓	✓
10	✓	✗	✗	✗	✗	✓	✗	✗	✗
11	✓	✗	✗	✗	✓	✓	✗	✗	✓
12	✓	✗	✗	✓	✓	✓	✗	✗	✓
13	✓	✓	✓	✓	✓	✓	✗	✗	✓
14	✓	✗	✗	✓	✓	✓	✓	✗	✓
15	✓	✗	✗	✓	✗	✓	✗	✗	✓
16	✓	✗	✗	✓	✗	✓	✓	✓	✓
17	✓	✗	✗	✓	✓	✗	✓	✓	✓

**Results**

The results of runoff prediction of seventeen patterns are given in Figures (1) and (2). From the comparison of these figures, the accuracy of each pattern of dealing with the models can be seen. According to Fig. (1), patterns 3, 10 and 5 have recorded the most errors. And they are unacceptable patterns for flow prediction.

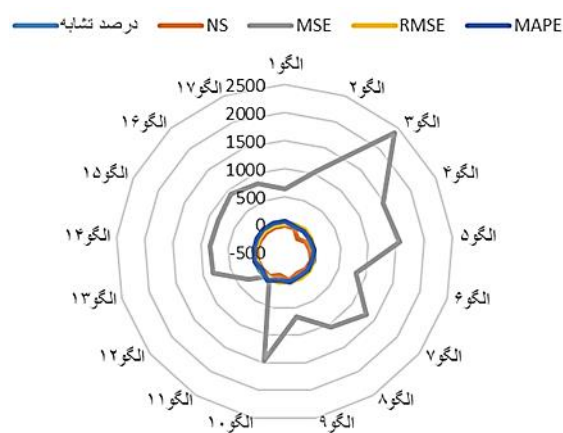


Fig. 1 Results of runoff prediction in BN model

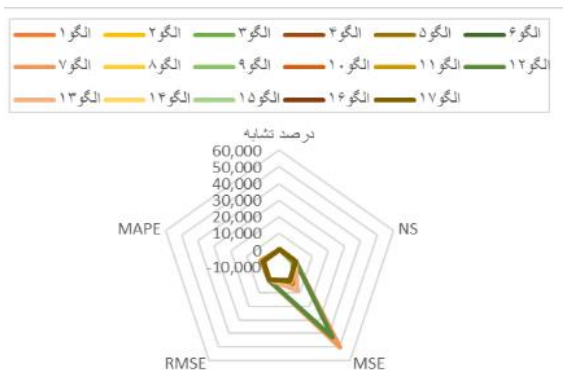


Fig. 2 Results of runoff prediction in MLP model

Comparing the above two forms, it was found that the accuracy of the neural network is lower than the Bayesian network. In pattern No. 2, by introducing all five hydrometric stations and removing the average rainfall data of the three meteorological stations upstream of the dam, the inlet runoff to the dam was predicted. The result showed that the artificial neural network recorded 40% similarity. This pattern has a high accuracy with a Nash coefficient of -3.9 and this pattern has recorded a similarity of 33.3% in the Bayesian network model. This template has a high error rate and a relatively good emission coefficient.

Pattern No. 6 by introducing all five hydrometric stations and deleting the average data of the three meteorological stations upstream of the dam, the inlet runoff to the dam was predicted. The modeling results showed that the artificial neural network recorded a similarity of 66.6. And this pattern has recorded a similarity of 50% in the Bayesian network.

Pattern No. 9 also introduced all five hydrometric stations and with the average data of three meteorological stations upstream of the dam, the inlet runoff to the dam was predicted. The results showed that the artificial neural network model recorded a similarity of 46.6%. The results also showed that the Bayesian network model recorded 36.6% similarity. This pattern is more accurate in the Bayesian network.

Pattern No. 12: In this model, by removing the Mehran and Alizan hydrometric stations and also by removing the average temperature and evaporation data of the three meteorological

stations upstream of the dam, the incoming runoff to the dam was predicted. The results showed that the artificial neural network models recorded 40% similarity. This pattern with high NMS coefficient and RMSE error is not a good pattern to predict. The results also showed that the Bayesian network model has recorded 43.3% and this pattern was recognized as the best pattern with the highest accuracy of the Bayesian network and with RMSE 17.3 as the best model with the lowest predicted data.

Pattern No. 13: This pattern was predicted by removing the Mehran and Alizan hydrometric stations to predict the runoff to the dam. The results showed that the MLP model, with 80% similarity, recorded the highest similarity among all models in the artificial neural network, while the RMSE error was 23.9 and the NS coefficient was -10.29. And this pattern in Bayesian model was 43.3% similar to the recorded data.

**Conclusion**


The existence of two definite and probabilistic models together and their simultaneous comparison cover each other’s weaknesses are a good combination for making managerial decisions. Eventually it was found that both models performed well in runoff estimation but the BN model had much better accuracy in forecasting. And the importance of each hydrometric station and meteorological data was determined by comparing the structure of the patterns with the percentage of acceptable similarities; there are three hydrometric stations (Joostan, Glink and Dehdar) and the rainfall parameter are common in BN and MLP models. The best patterns, taking into account the error criteria and the percentage of similarity with the recorded data in the BN model, are patterns No. 12 and 9. And in MLP model, patterns 2 and 13 had the best performance.

**Data Availability**

The data can be sent by email by the corresponding author upon request.

**Conflicts of Interest**

The authors of this article 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 کوتاه

## مقایسه کارایی شبکه‌های بیزین و عصبی MLP در پیش‌بینی رواناب ورودی به سد طالقان

زهرا نفریه<sup>۱</sup>، مهدی سرائی تبریزی<sup>۲\*</sup>، حسین بابازاده<sup>۳</sup> و حمیدکاردان مقدم<sup>۴</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد، گروه علوم و مهندسی آب، دانشکده علوم کشاورزی و صنایع غذایی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران  
<sup>۲</sup> استادیار، گروه علوم و مهندسی آب، دانشکده علوم کشاورزی و صنایع غذایی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران  
<sup>۳</sup> استاد، گروه علوم و مهندسی آب، دانشکده علوم کشاورزی و صنایع غذایی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران  
<sup>۴</sup> استادیار، مؤسسه تحقیقات وزارت نیرو، تهران، ایران

### اطلاعات مقاله

تاریخ دریافت: [۱۴۰۰/۰۴/۱۲]

تاریخ بازنگری: [۱۴۰۰/۰۷/۱۳]

تاریخ پذیرش: [۱۴۰۰/۰۷/۱۴]

### واژه‌های کلیدی:

پیش‌بینی رواناب  
سد طالقان  
شبکه بیزین  
شبکه عصبی پرسپترون

\*نویسنده مسئول:

[m.sarai@srbiau.ac.ir](mailto:m.sarai@srbiau.ac.ir)


### چکیده

اهمیت تنظیم رژیم عرضه و تقاضا لزوم برنامه‌ریزی در بهره‌برداری از منابع آب سطحی را نشان می‌دهد. هدف پژوهش حاضر، مقایسه عملکرد دو مدل شبکه بیزین (BN) با رویکرد احتمالاتی و شبکه عصبی MLP برای پیش‌بینی جریان و انتخاب بهترین الگوی ساختاری بود. داده‌های ماهانه هواشناسی شامل، بارش، میانگین ماهانه دما، تبخیر و حجم آب انتقالی از پنج ایستگاه هیدرومتری به‌عنوان داده ورودی به مدل‌ها معرفی و رواناب ورودی به سد به‌عنوان پیش‌بینی شونده لحاظ شد. داده‌های ورودی با چیدمان‌های مختلف به مدل‌های BN و MLP معرفی شدند. نتایج حاصل از مقایسه ۱۷ الگوی منتخب با توجه به معیارهای شاخص، ضریب نش-ساتکلیف (NS)، خطای میانگین مربعات (MSE)، جذر خطای میانگین مربعات (RMSE) و متوسط خطای پیش‌بینی مطلق (MAPE) صورت گرفت. بهترین الگو در مدل BN با ۴۳/۳٪ تشابه و معیارهای شاخص به‌ترتیب، ۳/۹۸-، ۳۰۰، ۱۷/۳ و ۰/۰۶ برآورد شد. مدل MLP با ۸۰٪ تشابه و معیارهای شاخص به‌ترتیب ۱۰/۳-، ۸۲۶۶، ۲۳/۹ و ۱۲۲/۳ به‌عنوان برترین الگو معرفی شد. در نتیجه هر دو مدل عملکرد خوبی در برآورد رواناب داشته‌اند لیکن مدل BN دقت به‌مراتب بهتری در پیش‌بینی دارد. در نهایت الگوی ساختاری با نتایج قابل قبول در هر دو مدل MLP و BN مشخص شد.

### ۱- مقدمه

رشد جمعیت و از طرفی به اشباع رسیدن پتانسیل بهره‌برداری‌ها باعث شده حوضه‌ها قابلیت تأمین تقاضاهای جدید را نداشته باشند. به‌علاوه با توجه به تنش‌های مختلف اقلیمی و انسانی نیازهای کنونی نیز افزایش داشته است



حاضر با هدف برآورد رواناب ورودی به سد، به طراحی الگوهای ساختاری بر اساس متغیرهای ورودی پرداخته و عملکرد هر الگو در دو مدل BN و MLP بررسی شد.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش، در استان البرز شهرستان طالقان بین عرض جغرافیایی  $36^{\circ} 5' 30''$  تا  $36^{\circ} 11' 51''$  شمالی و طول جغرافیایی  $50^{\circ} 45' 00''$  تا  $50^{\circ} 11' 12''$  شرقی واقع شده که از شمال با استان مازندران، از غرب با منطقه الموت، از جنوب با شهرستان ساوجبلاغ، از جنوب غربی با فشگلدره و شهرستان آبیگ هم‌جوار است.

### ۲-۲- روش پژوهش

در این پژوهش برای پیش‌بینی رواناب ورودی به سد طالقان از دو مدل MLP و BN استفاده شد. مدل MLP از سه لایه‌ی پیش‌خور، شامل لایه ورودی، لایه پنهان و لایه خروجی تشکیل شد (Haykin 1999). برای آموزش شبکه عصبی از روش پس انتشار خطا، الگوریتم لوبرک-مارکوارت<sup>۶</sup> استفاده شده است. و سپس از روشی دیگر، مدل BN با رویکرد احتمالاتی شرطی اقدام به پیش‌بینی رواناب شد. از این مدل در حیطه یک مسئله دارای عدم قطعیت استفاده می‌شود (Nikoo and Krachian 2009). مدل‌سازی جریان ماهانه رودخانه برای شبکه بیزین شامل تعریف متغیرها و روابط بین آن‌ها به‌عنوان مدل مفهومی می‌باشد (Mohajerani et al. 2010). برای این منظور ۱۷ الگو با سعی و خطا انتخاب و مورد ارزیابی قرار گرفت. ساختار الگوها براساس موقعیت جغرافیایی ایستگاه‌های هیدرومتری و پارامترهای هواشناسی طراحی شدند. سپس برای آموزش شبکه با استفاده از الگوهای تعریف شده، ارتباط بین داده‌ها مشخص و اقدام به تولید داده‌های جدید نمود. ۸۰٪ داده‌ها برای آموزش و ۲۰٪ داده‌ها نیز برای صحت‌سنجی به مدل معرفی شد. نتایج حاصل از برآورد الگوهای پیشنهادی با داده‌های ثبتی براساس شاخص‌های آماری خطا میانگین مربعات پیش‌بینی (MSE<sup>۷</sup>) رابطه (۲)، ریشه میانگین مجذور خطا<sup>۸</sup> (RMSE) رابطه (۳)، معیار درصد میانگین مطلق

(Speed et al. 2013). از طرفی بررسی تغییرات دبی رودخانه در طول زمان می‌تواند تأثیرات تغییر یافتن یا نیافتن شرایط اقلیمی منطقه را مشخص کند (Babaei-Moghadam et al. 2016).

نتایج بررسی (Dehghani et al. 2017) که به ارزیابی دقت مدل‌های ماشین بردار پشتیبان (SVM)<sup>۱</sup>، برنامه‌ریزی بیان ژن و شبکه بیزین (BN)<sup>۲</sup> در پیش‌بینی روزانه جریان در حوزه آبخیز کشکان پرداخته بودند؛ نشان داد که هر سه مدل با دقت خوب و خطای کم قابلیت پیش‌بینی روزانه جریان را دارند. نتایج حاصل از پیش‌بینی رواناب سالانه سد زاینده‌رود با تعریف سناریوهای مختلف و تعریف الگوهای ساختاری توسط Noorbeh et al. (2018) نشان داد که سناریوهای معرفی‌شده به مدل BN برای پیش‌بینی رواناب ورودی به‌صورت عددی، توانایی خوبی داشته است. Ahmadi (2020) به مقایسه‌ی عملکرد مدل‌های SVM و سیستم استنتاج عصبی فازی تطبیقی (ANFIS)<sup>۳</sup> در پیش‌بینی جریان ماهانه رودخانه پرداخت. نتایج نشان داد مقادیر پیش‌بینی شده در هر دو مدل تا حد زیادی با مقادیر اندازه‌گیری شده مطابقت دارد، اما مدل SVM در مقایسه با مدل ANFIS توانسته مقادیر بهتری برآورد کند. پیش‌بینی بلندمدت و کوتاه‌مدت جریان ورودی به سد کارون ۳ توسط Riahi-Madvar et al. (2021) به مقایسه کاربرد سنتی ANFIS با الگوریتم‌های تکمیلی مدل پرداختند. نتایج نشان داد تمام مدل‌ها عملکرد بهتری نسبت به انفیس دارند. از مطالعات انجام گرفته در خارج از کشور پیش‌بینی جریان ماهانه رودخانه نیل توسط Afan et al. (2020) است که از ادغام الگوریتم ژنتیک (GA)<sup>۴</sup> با شبکه عصبی تابع پایه شعاعی<sup>۵</sup> استفاده کردند. نتایج نشان داد مدل پیشنهادی RBFNN\_GA از دقت بالایی در پیش‌بینی جریان برخوردار است.

مطالعات زیادی جهت پیش‌بینی رواناب رودخانه‌ها انجام گرفته است، که اغلب به مقایسه مدل‌ها پرداخته‌اند، اما کمتر پژوهشی به نقش و اهمیت هر یک از ایستگاه‌ها و پارامترهای اقلیمی در برآورد بهترین الگوها پرداخته است. در پژوهش

<sup>۱</sup>Support Vector Machine

<sup>۲</sup> Bayesian Networks

<sup>۳</sup>Adaptive Neuro-Fuzzy Inference System (ANFIS)

<sup>۴</sup>Genetic algorithm (GA)

<sup>۵</sup>RBFNN (RBF)

<sup>۶</sup>Levenberg-Marquardt

<sup>۷</sup>Mean Squared Error

<sup>۸</sup>Root-Mean-Square Error



(Q<sub>5</sub>) و همچنین از جریان ورودی به سد با یک ماه تأخیر به‌عنوان پیش‌بینی شونده استفاده شد. تعداد ۱۷ الگو طرح شد که در جدول (۱) به شرح زیر قابل مشاهده است. این الگوها به‌عنوان ورودی به نرم‌افزارهای Lite8.9 Hugin و Matlab2018b معرفی شدند. نرم‌افزار Hugin lite با ارائه استدلال‌های منطقی برای تصمیم‌گیری در شرایط عدم قطعیت کاربرد دارد.

#### ۴-۲- روش کار

مقادیر ده نمونه ورودی و ده نمونه خروجی از پارامترهای pH، کدورت، COD، BOD<sub>5</sub>، نیترات، کلی‌فرم کل و کلی‌فرم گرماپای به‌عنوان مهم‌ترین شاخص‌های ارزیابی براساس استانداردهای آزمایشگاهی نمونه‌برداری شد و براساس میزان تصفیه‌ای که انجام گرفته و استانداردهای موجود برای استفاده در مصارف موردنظر، امکان استفاده از آن در آبیاری و توسعه فضای سبز شهری موردبررسی قرار گرفت.

جدول ۱- الگوهای منتخب به‌عنوان ورودی

Table 1 Selected patterns as the input

Defined patterns	Q <sub>1</sub>	Q <sub>2</sub>	Q <sub>3</sub>	Q <sub>4</sub>	Q <sub>5</sub>	R	E	T	Q <sub>dam (t-1)</sub>
1	✓	X	✓	✓	✓	✓	✓	✓	✓
2	✓	✓	✓	✓	✓	X	✓	✓	✓
3	✓	X	X	✓	✓	X	✓	✓	✓
4	X	✓	X	✓	X	✓	✓	✓	✓
5	✓	✓	✓	✓	✓	✓	X	X	✓
6	✓	✓	✓	✓	✓	X	X	X	✓
7	✓	X	X	✓	X	✓	✓	X	✓
8	✓	✓	X	✓	✓	✓	✓	✓	✓
9	✓	✓	✓	✓	✓	✓	✓	✓	✓
10	X	X	X	✓	X	X	X	X	✓
11	✓	X	X	✓	✓	X	X	X	✓
12	✓	X	X	✓	✓	✓	X	X	✓
13	✓	X	X	✓	✓	✓	✓	✓	✓
14	✓	X	✓	✓	✓	✓	X	X	✓
15	✓	X	X	✓	X	✓	X	X	✓
16	✓	✓	✓	✓	X	✓	X	X	✓
17	✓	✓	✓	X	✓	✓	X	X	✓

#### ۳- یافته‌ها و بحث

تشابهات برآورد شده با داده‌های ثبتی بدترین عملکرد را داشته‌اند. نتایج حاصل از برآورد الگوها در مدل MLP نشان می‌دهد این مدل دقت کمی در برآورد رواناب داشته است. لیکن دبی‌های برآورد شده از مدل BN به‌طور میانگین دقت خوبی داشته‌اند. شکل (۲) نتایج حاصل از برآوردهای ۱۷ الگوی پیشنهادی را نشان می‌دهد.

خطاهای پیش‌بینی (MAPE)<sup>۱</sup> رابطه (۴) و ضریب نش-ساتکلیف (NASH) رابطه (۵) ارزیابی گردید.

$$MSE = \sum_{t=1}^n \frac{(Q_{oi} - Q_{pi})^2}{n} \quad (2)$$

$$RMSE = \sqrt{\sum_{t=1}^n \frac{(Q_{oi} - Q_{pi})^2}{n}} \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Q_{oi} - Q_{pi}}{Q_{oi}} \right| * 100 \quad (4)$$

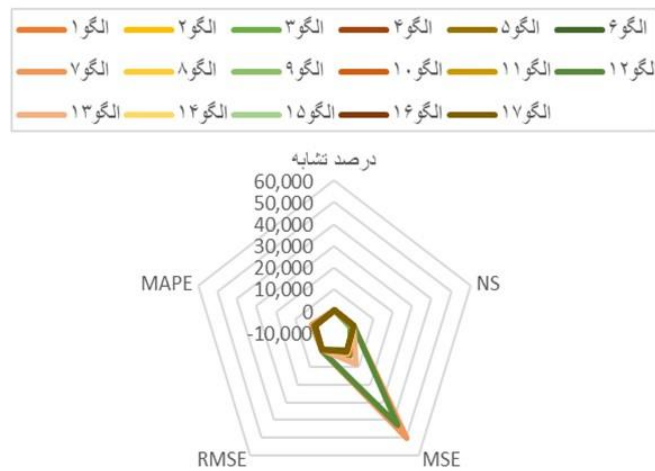
$$NASH = 1 - \frac{\sum (Q_{oi} - Q_{pi})^2}{\sum ((Q_{oi} - \bar{Q})^2)} \quad (5)$$

در روابط فوق Q<sub>oi</sub> و Q<sub>pi</sub> به ترتیب مقدار جریان مشاهداتی و شبیه‌سازی شده و  $\bar{Q}$  میانگین جریان مشاهداتی و n تعداد داده‌های شبیه‌سازی شده است.


#### ۳-۲- معرفی سناریوها

در این پژوهش با توجه به آمار اطلاعات موجود، از متغیرهای هواشناسی بارش (R)، تبخیر (E) و میانگین ماهانه دما (T) و متغیرهای آبدی ایستگاه‌های جویستان (Q<sub>1</sub>)، جویستان علیزان (Q<sub>2</sub>)، جویستان مهران (Q<sub>3</sub>)، گلینک (Q<sub>4</sub>) و دهر

<sup>1</sup> Mean Absolute Predictable Error



شکل ۱- نتایج حاصل از پیش‌بینی رواناب در مدل MLP  
Fig. 1 Results of runoff prediction in MLP model



شکل ۲- نتایج حاصل از پیش‌بینی رواناب در مدل BN  
Fig. 2 Results of runoff prediction in BN model

الگو شماره ۱۲ در این الگو با حذف ایستگاه هیدرومتری مهران و علیزان و همچنین با حذف میانگین داده‌های دما و تبخیر سه ایستگاه هواشناسی بالادست سد، اقدام به پیش‌بینی رواناب ورودی به سد شد. نتایج نشان داد مدل‌های شبکه عصبی MLP و شبکه BN، در صد تشابه ۴۰ و ۴۱/۴٪ را ثبت کرده‌اند و این الگو با بالاترین دقت شبکه BN و با بهترین RMSE ۱۷/۳ در کمترین داده‌های پیش‌بینی شده پرت شناخته شد

#### ۴- نتیجه‌گیری

وجود دو مدل قطعی و احتمالاتی در کنار هم و مقایسه هم‌زمان آن‌ها ضعف‌های یکدیگر را پوشش می‌دهند تا تصمیمات مدیریتی مناسب اتخاذ شود. از پژوهش حاضر در این خصوص نتایج زیر شایان توجه است.

۱- هر دو مدل عملکرد خوبی در برآورد رواناب داشته‌اند.

الگو شماره ۶ با معرفی تمام پنج ایستگاه هیدرومتری و با حذف داده‌های میانگین سه ایستگاه هواشناسی بالادست سد، اقدام به پیش‌بینی رواناب ورودی به سد شد. نتایج مدل‌سازی نشان داد شبکه MLP و شبکه BN، درصد تشابه ۶۶/۶ و ۵۰٪ را ثبت کرده‌اند. و این الگو در شبکه بیزین با مقدار ضریب NS برابر با ۱۳/۵-، دقت بالاتری دارد.

الگو شماره ۹ نیز با معرفی تمام پنج ایستگاه هیدرومتری و با میانگین داده‌های سه ایستگاه هواشناسی بالادست سد، اقدام به پیش‌بینی رواناب ورودی به سد شد. نتایج نشان داد مدل‌های شبکه MLP و شبکه BN، در صد تشابه ۴۶/۶ و ۳۶/۶٪ را ثبت کرده‌اند. این الگو در شبکه بیزین با ثبت مقادیر ضریب NS و MAPE ۵/۶- و ۱۸/۱- دقت بالاتری دارد.

### دسترسی به داده‌ها

داده‌ها حسب درخواست، از طرف نویسنده مسئول از طریق ایمیل قابل ارسال می‌باشد.

### تضاد منافع نویسندگان

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

۲- شبکه عصبی MLP بیش‌ترین تشابه را با داده‌های مشاهداتی دارد.

۳- دقت شبکه BN در برآوردها بهتر بوده است. حال آنکه ساختار مشترک بین برترین‌الگوها وجود دارد.

با توجه به مطالب ذکرشده و نتایج به‌دست‌آمده پیشنهاد می‌شود میزان رواناب ورودی به سد طالقان همه‌ساله برآورد شود تا مدیریت آورد رودخانه به منظور به حداقل رساندن آسیب‌های محیط‌زیستی ارتقا داد شود.

## References

- Afan, H. A., Allawi, M. F., El-Shafie, A., Yaseen, Z. M., Ahmed, A. N., Malek, A. M., Koting, S. B., Salih, S. Q., Mohtar, W. H. M. W., Lai, S. H., Sefelnasr, A., Sheirf, M. and El-Safie, A. L. (2020). Input attributes optimization using the feasibility of genetic ninspired algorithm: application of river flow forecasting. *Water Recour. Manag. Sci. Rep.*, 10(1),1\_15.
- Ahmadi, F. (2020). Evaluation of support vector machine and adaptive neuro-fuzzy inference system performance in prediction of monthly river flow (case study: Nazlu chai and Sezar Rivers). *Iran. J. Soil Water Res.*, 51(3), 673-686. DIO: 10.22059/ijswr.2019.290994.668356 [In Persian].
- Babaei Moghadam, A., Khaledian, M., Shahnazari, A. and Morteza Pour, M. (2016). Investigation and forecast of Ghezal Ozan and Shahroud rivers. *J. Eco. Hydrol.*, 3(2), 195 - 204 [In Persian].
- Dehghani, R., Yonesi, H. and Torabi Pode, H (2017). Comparing the performance of support vector machines, gene expression programming and bayesian networks in predicting river flow (case study: Kashkan River). *J. Water Soil Conserv.*, 4(24), 161-177. [magiran.com/p1774763](http://magiran.com/p1774763) [In Persian].
- Haykin, S. (1999). *Neural networks: A comprehensive foundation*. NJ. Prentice-Hall Inc. Englewood Cliffs.
- Mohajerani, H., Mosaedi, A., Kholgh, M., Meftah Halgh, M. and Saddin, A. (2010). Introduction of Bayesian decision networks and their application in water resources management. The first national conference on coastal land water resources management [In Persian].
- Nikoo, M. and Krachian, R. (2009). Evaluating the efficiency of bayesian networks in river water quality management: application of trade-ratio system. *Water Wastewater*, 1(20), 23-33 [In Persian].
- Noorbeh, P., Roozbahani, A. and Kardan Moghaddam, H. (2018). Prediction of Zayandeh Rood Dam inflow and hydrological wet and dry periods using bayesian networks. *J. Water Soil*, 32(3), 633-646. DIO: 10.22067/jsw.v32i3.72084 [In Persian].
- Riahi\_Madvar, H., Dehghani, M. and Memarzadeh, R. and Gharabaghi, B. (2021). Short to long-teem forecasting of rivwr flows by heuristic optimization algorithms hybridized with ANFIS. *Water Recour. Manage.*, 35(4), 1149-1166. DIO: 10.1007/s11269-020-02756-5
- Speed, R., Yuanyuan, L., Quesne, T. L., Pegram, G. and Zhiwei, Z. H. (2013). *Basin water allocation planning*. United Nations, Educational, Scientific and Culture Organization. PP144.

### How to cite this paper:

Nafariyeh, Z., Sarai Tabrizi, M., Babazadeh, H. and Kardan Moghaddam, H. (2022). Efficiency comparison of Bayesian and MLP neural networks in predicting runoff to the Taleghan Dam. *Environ. Water Eng.*, 8(2), 530-537. DOI: 10.22034/JEWE.2021.293381.1594

