

Investigating the Effect of Daily Discharge Sequence in River Flow Forecasting Using Intelligent Algorithms (Case study: Kasilian watershed)

Haniyeh Asadi¹, Mohamadtaghi Dastorani^{2✉}, Kaka Shahedi³

1. Postdoctoral Researcher of Range and Watershed Management, Ferdowsi University of Mashhad, Mashhad, Iran
E-mail: h.asadi@um.ac.ir

2. Professor of Range and Watershed Management, Ferdowsi University of Mashhad, Mashhad, Iran
✉E-mail: dastorani@um.ac.ir

3. Associate Professor of Watershed Management Engineering, Sari Agricultural Sciences and Natural Resources University, Sari, Iran
E-mail: k.shahedi@sanru.ac.ir



How to Cite: Asadi, H; Dastorani, Mt; & Shahedi, K. (2022). Investigating the Effect of Daily Discharge Sequence in River Flow Forecasting Using Intelligent Algorithms (Case study: Kasilian watershed). *Geography and Development*, 20 (68), 163-183.

DOI: <http://dx.doi.org/10.22111/J10.22111.2022.7007>

Received:

14 October 2021

Received in revised form:

28 December 2021

Accepted:

29 January 2022

Published online:

25 August 2022

Keywords:

Forecasting,
Daily discharge,
Kasilian watershed,
Intelligent algorithm.

ABSTRACT

In fact, determination of a reliable model and selection of inputs with proper time lags for river flow forecasting is a key topic for watershed managers, hydrologists, and river engineers. In recent decades use of intelligent algorithms and fuzzy theories for modeling of hydrological phenomena has been noticed by researchers. In this regard, in the present study adaptive neuro-fuzzy inference system (ANFIS) and different input patterns of flow discharge (with 1-7 day time lags) was used in order to river flow forecast of Kasilian watershed. Then in order to further investigate of this process, artificial neural network (ANN) model was used and the results were evaluated using coefficient of determination (R^2) and root mean square error (RMSE). The results showed that river flow prediction were improved using 1-4 day time lags in ANFIS model and 1-5 day time lags in ANN model. Evaluation of standard statistics values of the best input patterns during validation phase indicated that ANFIS with $R^2=0.60$ and $RMSE=0.64$ had higher accuracy than ANN with $R^2=0.51$ and $RMSE=1.74$ in river flow forecasting.



© the Author(s).

Publisher: University of Sistan and Baluchestan

Extended Abstract

1. Introduction

One of the critical concerns in hydrology and water resources management is reliable forecasting of daily flow discharge of rivers. Therefore, researchers constantly attempt to more accurately forecast river flow and improve existing approaches. The employment of statistical, hydraulic and hydrological models has a long history in this field. However, there are weak points in these type of models.

Therefore, the use of fuzzy theory and intelligent algorithms as new technology and powerful instrument in hydrological modeling processes has expanded in recent decades. Short-term forecasting on a daily basis is important because of its direct effect on watershed management and interaction with the flooding risks especially in downstream (El-Shafie et al, 2007) A review of pervious researches denote that the application of intelligent methods in

flow discharge forecasting has grown in recent decades (Moatamednia et al., 2015; Asadi et al., 2019; Hosseini and Mahjouri, 2016). Given the importance of modeling of river daily flow and its role in the management and planning of water resource, as well as, since research in forest catchments in this field has been rarely conducted. Therefore, this study has focused on investigation of the performance of ANFIS and ANN models in forecasting the daily flow discharge of the Kasilian River.

2. Methods and Material

The effect of ANN and ANFIS models in forecasting the daily flow discharge of the Kasilian River were assessed in this study. Daily discharge data (1825 records) at the Velikbon hydrometric station in the Kasilian watershed from 2008 to 2013 were collected for the purposes of this study. Also, the effect of discharge of antecedent days (up to pervious seven days) on forecasting the river flow using ANN and ANFIS models were evaluated. In modeling process, the number of hidden neurons in ANN (Kim and Valdés, 2003) and type and number of membership functions in ANFIS (Jang, 1993) using trial and error were determined. For assessing of results and comparison of the efficiency of the models, the statistical criteria of root mean square error (RMSE) and coefficient of determination (R^2) were used (Asadi et al., 2021).

3. Results and Discussion

In the ANFIS model, the best input combination for estimating the daily flow discharge during the validation phase, is input pattern 4 ($R^2 = 0.60$, $RMSE = 0.64$), in which flow discharge data (with 1-4 day time lags) were used. In the ANN model, the results indicate superiority of input pattern 5 ($R^2 = 0.51$ and $RMSE = 1.74$) in which flow discharge data (with 1-5 day time lags) for prediction flow discharge were applied. The comparison of observed versus predicted flow discharge in time series plots of based on the best

input patterns during validation phase for ANN and ANFIS models represents that there are a better agreement using the ANFIS than ANN. Moreover, ANFIS model was able to predict peak values more accurately than ANN. Superiority of ANFIS model over ANN model in flow discharge estimation by Nayak et al. (2005), Tayfur and Singh (2006), Firat (2007), Kurtulus and Razack. (2010), Anusree and Varghese (2016) and Roy and Singh (2020) have been confirmed. better performance of ANFIS model than ANN show that the combination of fuzzy logic with neural network result in to more accurately prediction of daily flow discharge.

4. Conclusion

The purpose of this study was investigate of effect of daily flow discharge sequence in river flow forecasting using ANN and ANFIS models in the Kasilian watershed. Despite the fact that both models are efficient at simulating river flow, the ANFIS model is suggested as a more accurate method for forecasting river flow based on daily flow sequence. Furthermore, the use of acceptable input parameters and a proper architectural structure improved the results of flow forecasting using intelligent models. In fact, in addition to modeling tools, optimal design of intelligent networks and selection of relevant input data are beneficial in increasing the accuracy of the results. On the other hand, various methods have presented different results in different hydrological situations. As a result, it is proposed that this study in the other region with various geographical conditions be tested. Moreover, given the impact of climatic, geomorphic, and biophysical parameters in the river flow, assessing these parameters along with the hydrological parameter utilized in this study to accurately estimate of flow discharge was recommended.

Keywords: Forecasting, Daily discharge, Kasilian watershed, Intelligent algorithm.

5. References

- Anusree, K., & Varghese, K. O. (2016). Streamflow prediction of Karuvannur River Basin using ANFIS, ANN and MNL models. *Procedia Technology*, 24, 101-108. <https://doi.org/10.1016/j.protcy.2016.05.015>
- Asadi, H., Dastorani, M. T., Sidle, R. C., & Shahedi, K. (2021). Improving Flow Discharge-Suspended Sediment Relations: Intelligent Algorithms versus Data Separation. *Water*, 13(24), 3650. <https://doi.org/10.3390/w13243650>
- Asadi, H., Shahedi, K., Jarihani, B., & Sidle, R. C. (2019). Rainfall-runoff modelling using hydrological connectivity index and artificial neural network approach. *Water*, 11(2), 212. <https://doi.org/10.3390/w11020212>
- Asadi, H., Shahedi, K., Sidle, R.C., Kalami Heris, M. (2019). Prediction of Suspended Sediment Using Hydrologic and Hydrogeomorphic Data within Intelligence Models, *Iran Water Resources Research*, 15(3), 105-119. [magiran.com/paper/2068726](https://www.magiran.com/paper/2068726). <https://www.magiran.com/paper/2068726>
- Danandeh Mehr, A., Majdzadeh Tabatabai, M.R. (2010). Prediction of Daily Discharge Trend of River Flow Based on Genetic Programming, *Journal of water and soil*, 24(2), 325-333. [magiran.com/p750345](https://www.magiran.com/paper/750345). <https://www.magiran.com/paper/750345>
- Dastorani, M. T. (2007). Evaluation of the Application of Artificial Intelligence Model for Simulation and Real - Time Prediction of Flood Flow, *Journal of Hydrology and Soil Science*, 11(2), 27-37. [magiran.com/p474118](https://www.magiran.com/paper/474118). <https://www.magiran.com/paper/474118>
- Dastorani, M.T., Sharifi Darani, H., Talebi, A., Moghadam Nia, A. (2012). Evaluation of the Application of Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference Systems for Rainfall-Runoff Modelling in Zayandeh_rood Dam Basin, *Journal of Water & Wastewater*, 22(80), 114-125. [magiran.com/p949761](https://www.magiran.com/paper/949761). <https://www.magiran.com/paper/949761>
- El-Shafie, A., Taha, M. R., & Noureldin, A. (2007). A neuro-fuzzy model for inflow forecasting of the Nile river at Aswan high dam. *Water resources management*, 21(3), 533-556. <https://doi.org/10.1007/s11269-006-9027-1>
- Fathabadi, A, Salajegheh, A., Mahdavi, M.(2008). Forecasting river flow using neuro-fuzzy methods & time series models, *Iranian Journal of Watershed Management Science and Engineering*, 2(5), 21-30. [magiran.com/p684437](https://www.magiran.com/paper/686503). <https://www.magiran.com/paper/686503>
- Firat, M. (2007). Artificial intelligence techniques for river flow forecasting in the Seyhan river catchment, Turkey. *Hydrology and Earth System Sciences Discussions*, 4(3), 1369-1406. <https://hal.archives-ouvertes.fr/hal-00298839>
- Hosseini, S. M., & Mahjouri, N. (2016). Integrating support vector regression and a geomorphologic artificial neural network for daily rainfall-runoff modeling. *Applied Soft Computing*, 38, 329-345. <https://doi.org/10.1016/j.asoc.2015.09.049>
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685. <https://doi.org/10.1109/21.256541>
- Karamouz, M., Araghinejad, Sh., *Advanced hydrology* (2018). Amirkabir University of Technology Publications, first edition, 468. <https://www.adinehbook.com/gp/product/9644632745>
- Kim, T. W., & Valdés, J. B. (2003). Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering*, 8(6), 319-328. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2003\)8:6\(319\)](https://doi.org/10.1061/(ASCE)1084-0699(2003)8:6(319))
- Kurtulus, B., & Razack, M. (2010). Modeling daily discharge responses of a large karstic aquifer using soft computing methods: Artificial neural network and neuro-fuzzy. *Journal of Hydrology*, 381(1-2), 101-111. <https://doi.org/10.1016/j.jhydrol.2009.11.029>

- Moatamednia, M., Nohegar, A., Malekian, A., Asadi, H., Tavasoli, A., Safari, M., & Karimi, K. (2015). Daily river flow forecasting in a semi-arid region using twodatadriven. *Desert*, 20(1), 11-21.
<https://dx.doi.org/10.22059/jdesert.2015.54078>
- Nayak, P. C., Sudheer, K. P., Rangan, D. M., & Ramasastri, K. S. (2005). Short-term flood forecasting with a neurofuzzy model. *Water Resources Research*, 41(4). 2517-2530. <https://doi.org/10.1029/2004WR003562>
- Nabizadeh, M., Mosaedi, A. Hesam, M., Dehghani, A.A., Zakerinia, M., Meftah, M. (2012). River Flow Forecasting Using Fuzzy Inference System (FIS) and Adaptive Neuro- Fuzzy Inference System (ANFIS), *Iranian Journal of Watershed Management Science and Engineering*, 5(17),7-14. magiran.com/1083411. <https://www.magiran.com/paper/1083411>
- Noorani, V., Salehi, K. (2008). Rainfall-runoff modeling Adaptive Neuro- Fuzzy network and its comparison with neural network and fuzzy inference System (case study: Liqvan-Chai watershed located in East Azerbaijan province), 4th National Congress of Civil Engineering, Tehran. 8.
<https://civilica.com/doc/38309/>
- Nourani, V., Kaynejad, M.A., Malekani, L. (2010). Using of Adaptive Neuro-Fuzzy Inference System for Rainfall-Runoff Modeling, *Journal of Civil and Environmental Engineering University of Tabriz*, 39(4), 75-81. magiran.com/p880137. <https://www.magiran.com/paper/880137>
- Poustzadeh, N., Samani, J. M. V., Dezfuli, A. K. (2008). River Flow Forecasting using Fuzzy Inference System, *Iran Water Resources Research*, 4(2), 23-34. magiran.com/p897697
<https://www.magiran.com/paper/897697>
- Pahlevani, H. (2009). Evaluating the performance of artificial neural network models in smart estimation of incoming flood hydrograph to Shirin-Dare reservoir dam compared to adaptive neuro-fuzzy models, Master's thesis, Gorgan University of Agricultural Sciences and Natural Resources, 123.
<https://ganj.irandoc.ac.ir/#/articles/ed8982b031f3b29aa2f0b1b7a816d4ab>
- Roy, B., & Singh, M. P. (2020). An empirical-based rainfall-runoff modelling using optimization technique. *International journal of river basin management*, 18(1), 49-67.
<https://doi.org/10.1080/15715124.2019.1680557>
- Salajegheh, A., Fathabadi, A., Mahdavi, M. (2009). Investigation on the efficiency of neuro-fuzzy method and statistical models in simulation of rainfall-runoff process, *Journal of Range and Watershed Management*, 62(1), 65-79. magiran.com/p684437. <https://www.magiran.com/paper/684437>
- Shoja Rastegari, H., Barani, Gh. (2011). The use of adaptive neuro-fuzzy inference system in rainfall-runoff modeling, the first regional conference on water resources development, Islamic Azad University, Abarkuh branch. 13 pages. <https://civilica.com/doc/114808>
- Sadeghi, S.H.R., Asadi, H. (2010). Importance of Travel Time Duration between Isochrones in Estimation of Flood Resulting from Clark Instantaneous Unit Hydrograph, *Journal of water and soil*, 24(4), 625-635. magiran.com/p790598. <https://www.magiran.com/paper/790598>
- Tayfur, G., & Singh, V. P. (2006). ANN and fuzzy logic models for simulating event-based rainfall-runoff. *Journal of hydraulic engineering*, 132(12), 1321-1330.
[https://doi.org/10.1061/\(ASCE\)0733-9429\(2006\)132:12\(1321\)](https://doi.org/10.1061/(ASCE)0733-9429(2006)132:12(1321))
- Zare Abyaneh, H., Bayat Varkeshi, M. (2011). Evaluation of Artificial Intelligent and Empirical Models in Estimation of Annual Runoff, *Journal of water and soil*, 25(2), 365-379. magiran.com/p896584
<https://www.sid.ir/fa/journal/ViewPaper.aspx?id=135206>



بررسی تأثیر توالی دبی روزانه در پیش‌بینی جریان رودخانه با استفاده از الگوریتم‌های هوشمند (مطالعه موردی: حوزه آبخیز کسلیان)


هانیه اسدی^۱، دکتر محمدتقی دستورانی^{۲*}، دکتر کاکا شاهی^۳

مقاله پژوهشی

چکیده

پیش‌بینی جریان رودخانه در دوره‌های زمانی آینده، از مسائل مهم و کاربردی در مدیریت منابع آب است. در حقیقت تعیین یک مدل قابل اطمینان و انتخاب روی‌ها با تأخیر زمانی مناسب برای پیش‌بینی دبی جریان، یک موضوع کلیدی برای مدیران حوزه آبخیز، هیدرولوژیست‌ها و مهندسان رودخانه است. در چند دهه اخیر استفاده از الگوریتم‌های هوشمند و تئوری مجموعه‌های فازی برای مدل‌سازی پدیده‌های هیدرولوژیکی که دارای پیچیدگی و عدم قطعیت بالایی هستند، مورد توجه محققان قرار گرفته است. در این راستا در پژوهش حاضر به منظور پیش‌بینی جریان در حوزه آبخیز کسلیان، از مدل سیستم استنتاج عصبی - فازی تطبیقی و از ورودی دبی جریان با تأخیر یک روز قبل، دو روز قبل تا هفت روز قبل استفاده شد. سپس برای بررسی بیشتر این فرایند، از مدل شبکه عصبی مصنوعی نیز استفاده شد و نتایج براساس شاخص‌های آماری ضریب تبیین و جذر میانگین مربعات خطا مورد ارزیابی قرار گرفت. نتایج حاکی از این بود که در مدل سیستم استنتاج عصبی - فازی تطبیقی تا گام زمانی چهار روز قبل، پیش‌بینی جریان رو به بهبود بود و بعد از آن رو به نزول گذاشت و در مدل شبکه عصبی مصنوعی تا گام زمانی پنج روز قبل بهترین نتایج را ارائه داد. همچنین مقایسه و ارزیابی نتایج شاخص‌های آماری الگوهای بهینه هر دو مدل در دوره آزمون نشان داد که مدل سیستم استنتاج عصبی - فازی تطبیقی (ضریب تبیین = ۰/۶۰ و جذر میانگین مربعات خطا = ۰/۶۴) نسبت به مدل شبکه عصبی مصنوعی (ضریب تبیین = ۰/۵۱ و جذر میانگین مربعات خطا = ۰/۷۴)، از دقت بیشتری برای پیش‌بینی جریان رودخانه برخوردار بود.

جغرافیا و توسعه، شماره ۶۸، پاییز ۱۴۰۱
تاریخ دریافت: ۱۴۰۰/۰۷/۲۲
تاریخ بازنگری داوری: ۱۴۰۰/۱۰/۰۷
تاریخ پذیرش: ۱۴۰۰/۱۱/۰۹
صفحات: ۱۸۳-۱۶۳



واژه‌های کلیدی:

پیش‌بینی، دبی روزانه، کسلیان، الگوریتم هوشمند.

مقدمه

فرایندهای هیدرولوژیکی بسیار متنوع بوده و اعمال همه این عوامل در این مدل‌ها بسیار مشکل است. همچنین در فرایندهای هیدرولوژیکی، عدم قطعیت‌ها و غیرخطی بودن روابط بین متغیرها، مسئله را پیچیده می‌کند؛ بنابراین در دهه‌های اخیر، کاربرد تئوری فازی و الگوریتم‌های هوشمند به‌عنوان فناوری جدید و ابزاری قوی در مدل‌سازی فرایندهای هیدرولوژیکی بسیار مورد توجه قرار گرفته است. در واقع با استفاده از این مدل‌ها می‌توان مسائلی را که ریاضیات کلاسیک قادر به حل آنها نیست با در نظر گرفتن عدم قطعیت‌های موجود و همچنین درک روابط ذاتی میان داده‌ها مدل‌سازی کرد (پوستی‌زاده و همکاران، ۱۳۸۷: ۲۳).

امروزه پیش‌بینی دبی روزانه رودخانه‌ها از مباحث مهم در هیدرولوژی و منابع آب است. درحقیقت پیش‌بینی دقیق جریان رودخانه در کارهای عمرانی، ساماندهی رودخانه، طراحی و برنامه‌ریزی منابع آب سطحی و سامانه‌های هشدار سیل بسیار مورد نیاز است (فتح‌آبادی و همکاران، ۱۳۸۷: ۲۱)؛ از این رو متخصصان همواره برای تخمین صحیح جریان رودخانه و دقیق‌تر شدن روش‌های موجود تلاش می‌کنند. در این راستا استفاده از مدل‌های آماری، هیدرولیکی و هیدرولوژیکی از سابقه طولانی برخوردار است. تجربه نشان داده است که این مدل‌ها در کنار نقاط قوت، دارای نقاط ضعف مهمی هستند؛ از جمله اینکه فاکتورهای مؤثر در

۱. محقق پسا دکترا، گروه مرتع و آبخیزداری، دانشگاه فردوسی مشهد، مشهد، ایران

۲. استاد گروه مرتع و آبخیزداری، دانشگاه فردوسی مشهد، مشهد، ایران (نویسنده مسئول)

۳. دانشیار گروه آبخیزداری، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران

۱. محقق پسا دکترا، گروه مرتع و آبخیزداری، دانشگاه فردوسی مشهد، مشهد، ایران
۲. استاد گروه مرتع و آبخیزداری، دانشگاه فردوسی مشهد، مشهد، ایران (نویسنده مسئول)
۳. دانشیار گروه آبخیزداری، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران

شبکه عصبی مصنوعی را در پیش‌بینی سیلاب با سه نوع شبکه عصبی پرسپترون چند لایه، برگشتی و برگشتی با تأخیر زمانی به صورت جداگانه مورد ارزیابی قرار داد. براساس نتایج، هر چند شبکه‌های عصبی مصنوعی به‌طور کلی کارایی مناسبی در پیش‌بینی دبی جریان نشان دادند؛ ولی نوع شبکه عصبی و ورودی‌ها، فاکتورهای مهمی هستند که تأثیر عمده‌ای روی کیفیت خروجی مدل دارند. دستورانی و همکاران (۱۳۹۰) از شبکه عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی به‌منظور برآورد بارش- رواناب در حوزه سد زاینده رود، استفاده کردند. نتایج این مطالعه نشان داد که شبکه عصبی مصنوعی و سیستم عصبی- فازی در شرایط مختلف و با ترکیب‌های مختلف پارامترهای ورودی، نتایج متفاوتی از خود نشان می‌دهند؛ ولی در کل، بردارهای دبی پیشین کمک زیادی به هر دو تکنیک در مدل‌سازی کرد و نتایج را تا حد قابل‌قبولی به مقادیر مشاهده‌شده نزدیک کرد. حسینی و مهجوری (۲۰۱۶) در حوزه قهرود در ایران با استفاده شبکه عصبی مصنوعی، سیستم استنتاج عصبی- فازی تطبیقی، رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی مبتنی بر ژئومورفولوژی و مدل ترکیبی رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی مبتنی بر ژئومورفولوژی به پیش‌بینی رواناب روزانه با استفاده از الگوهای ورودی بارش و رواناب تا سه تأخیر زمانی پرداختند. همچنین در پژوهشی سکن^{۱۲} و کومار^{۱۳} (۲۰۱۷) نیز از بارش و رواناب تا سه روز تأخیر به‌عنوان پارامترهای ورودی در مدل ساده عصبی- فازی و مدل ترکیبی روش‌های تبدیل موجک گسسته و سیستم استنتاج عصبی- فازی تطبیقی برای پیش‌بینی رواناب روزانه استفاده کردند. مقایسه نتایج نشان داد که بهترین مقادیر تأخیر ورودی‌ها، تا دو روز قبل بود و مدل ساده عصبی- فازی با ضریب همبستگی

در سال‌های اخیر تحقیقات زیادی در زمینه کاربرد الگوریتم هوشمند مبتنی بر منطق فازی (سیستم استنتاج عصبی- فازی تطبیقی) و برتری دقت این مدل بر روش‌های کلاسیک (نظیر روش‌های رگرسیون خطی، رگرسیون غیرخطی چندمتغیره، اتورگرسیون- میانگین متحرک و...) و سایر الگوریتم‌های هوشمند (نظیر مدل‌های شبکه عصبی مصنوعی، الگوریتم ژنتیک، ماشین بردار پشتیبان و برنامه‌ریزی بیان ژن، مدل درختی M5^۱ و...) صورت گرفته است که در این زمینه می‌توان به تحقیقات نایاک^۲ و همکاران (۲۰۰۵) در حوزه آبخیز کولار هند، فیرات^۳ (۲۰۰۷) در حوزه آبخیز سیهان ترکیه، نورانی و همکاران (۱۳۸۸) در حوزه آبخیز ليقوان‌چای ایران، سلاجقه و همکاران (۱۳۸۸) در حوزه‌های آبخیز طالقان، کرج و جاجرود در ایران، کورتولوس^۴ و رازاک^۵ (۲۰۱۰) در حوزه آبخیز کارستی در جنوب غرب فرانسه، شجاع رستگاری و بارانی (۱۳۹۰) در حوزه زیارت گرگان در ایران، کیسی^۶ و همکاران (۲۰۱۲) در دریای ازنیک در غرب ترکیه، اینسری^۷ و وارکیس^۸ (۲۰۱۶) در رودخانه کاروونور در ناحیه تریسور هند، ری^۹ و سینگ^{۱۰} (۲۰۲۰) در حوزه آبخیز فال در بریتانیا و عدنان^{۱۱} و همکاران (۲۰۲۱) در حوزه رودخانه ساموجی در ایتالیا اشاره کرد.

از طرفی بررسی پژوهش‌های پیشین نشان می‌دهد که به‌منظور تخمین و پیش‌بینی دبی جریان با استفاده از الگوریتم‌های هوشمند، از پارامترهای ورودی متنوع و زمان‌های تأخیر مختلف برای ورودی‌ها استفاده شده است؛ برای مثال، دستورانی (۱۳۸۶) توانایی مدل‌های

- 1.M5Tree
- 2.Nayak
- 3.Firat
- 4.Kurtulus
- 5.Razack
- 6.Kişi
- 7.Anusree
- 8.Varghese
- 9.Roy
- 10.Singh
- 11.Adnan

حوزه آبخیز و به‌ویژه حوزه‌های پایین‌دست فراهم می‌کند (El-Shafie et al, 2007: 533). از این رو در پژوهش حاضر با توجه به اهمیت بحث الگوبندی جریان روزانه رودخانه در مدیریت منابع آب، به بررسی عملکرد سیستم استنتاج عصبی- فازی تطبیقی براساس مقادیر دبی روزهای قبل در پیش‌بینی جریان روزانه رودخانه کسلیان پرداخته شد و نتایج با روش شبکه عصبی مصنوعی مقایسه شد.

مواد و روش‌ها

- منطقه مورد مطالعه

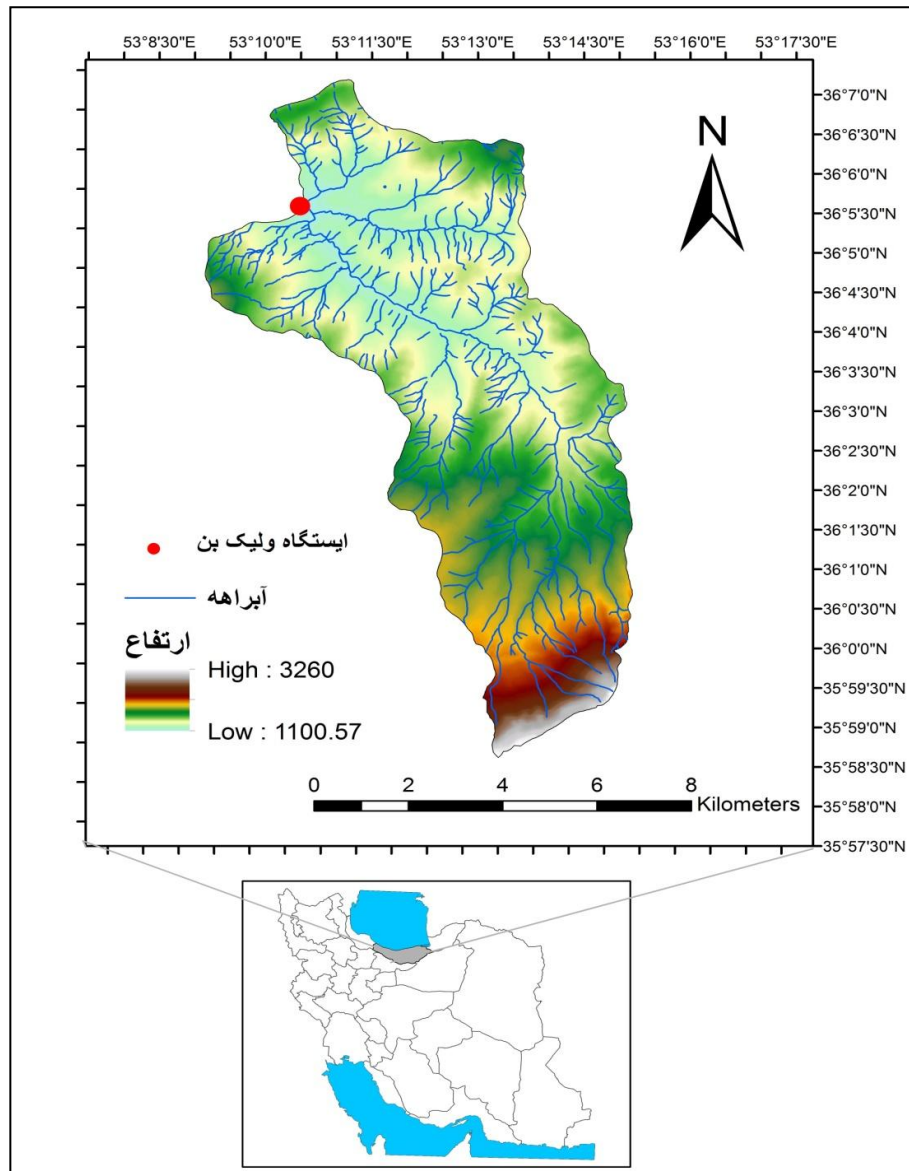
به‌منظور انجام تحقیق حاضر، حوزه آبخیز جنگلی کسلیان در استان مازندران واقع در دامنه شمالی سلسله‌جبال البرز انتخاب شد. حوزه مذکور با مساحت ۶۶/۷۵ کیلومتر مربع، محیط ۴۲/۵ کیلومتر، بین عرض جغرافیایی $30^{\circ} 58' 30''$ و $35^{\circ} 58' 15''$ شمالی و طول جغرافیایی $44^{\circ} 8' 53''$ و $53^{\circ} 15' 42''$ قرار دارد. حداقل، حداکثر و میانگین ارتفاع به‌ترتیب ۱۱۰۰، ۲۷۰۰ و ۱۶۲۰ متر از سطح دریا و میانگین بارندگی ۸۱۳/۸۰ میلی‌متر است. رودخانه کسلیان یکی از شاخه‌های رودخانه تالار است که از دامنه‌های شمالی کوه گلرد سرچشمه می‌گیرد و به دریای خزر وارد می‌شود. از لحاظ پوشش گیاهی، این حوزه به‌دلیل قرارگرفتن در دامنه شمالی البرز دارای پوشش غالب جنگلی است که به‌مرور زمان در اثر افزایش جمعیت روستاها از وسعت جنگل‌ها کاسته شده و بر میزان وسعت کاربری‌های دیگر افزوده شده است (صادقی و اسدی، ۱۳۸۹: ۶۲۵). در شکل ۱ و جدول ۱ به‌ترتیب، شمای کلی حوزه مورد مطالعه و برخی مشخصات جغرافیایی ایستگاه هیدرومتری مورد مطالعه نشان داده شده است. داده‌های موردنیاز برای انجام این تحقیق، داده‌های دبی متوسط روزانه جریان

بالاتر و مقادیر کمتر میانگین مربعات خطا مقادیر رواناب را بهتر از مدل ترکیبی برآورد کرده است. اسدی و همکاران (۲۰۱۹) در پژوهشی به مدل‌سازی رواناب ماهانه رودخانه با استفاده از مدل شبکه عصبی مصنوعی و ورودی‌های اقلیمی، بیوفیزیکی و هیدروژئومورفیک و با در نظر گرفتن زمان تأخیر یک ماه قبل و متوسط یک ماه قبل و دو ماه قبل برای ورودی‌ها در دو حوزه هوگتون و کالیپ در استرالیا پرداختند که نتایج حاکی از تأثیر مقادیر پیشین در برآورد بهتر از رواناب بود. عدنان و همکاران (۲۰۲۱) با به‌کارگیری چهار روش یادگیری ماشین^۱ از جمله ترکیب سیستم استنتاج عصبی- فازی تطبیقی با الگوریتم بهینه‌سازی انبوه ذرات^۲ و با استفاده از پارامترهای ورودی بارش با تأخیر زمانی تا چهار ساعت قبل و رواناب پیشین با تأخیر زمانی تا سه ساعت قبل به مدل‌سازی بارش-رواناب پرداختند. لی^۳ و همکاران (۲۰۲۱) در رودخانه بیرو در استان هنان چین از مدل ترکیبی سیستم استنتاج عصبی- فازی تطبیقی و الگوریتم آتش‌بازی^۴ و فاکتورهای بارش، تبخیر و رطوبت خاک با تأخیر زمانی تا دوازده ماه برای پیش‌بینی رواناب ماهانه استفاده کردند. در این مطالعه ورودی‌ها و تعیین بهترین مقادیر تأخیر ورودی‌های مدل با استفاده از شش روش انتخاب متغیر بررسی شدند. بررسی تحقیقات پیشین در زمینه کاربرد روش‌های هوشمند در مباحث مدل‌سازی و پیش‌بینی جریان در مهندسی منابع آب نشان می‌دهد که مدل‌ها با استفاده از ورودی‌های مختلف و با در نظر گرفتن تأخیرهای زمانی متفاوت در شرایط مختلف هیدرولوژیکی نتایج خاصی ارائه داده‌اند. از طرفی با توجه به این‌که پیش‌بینی کوتاه‌مدت دبی به‌صورت روزانه مستقیماً بر نحوه عملکرد مدیران با خطرات جانی ناشی از سیلاب‌ها اثر می‌گذارد و در واقع این پیش‌بینی نوعی سیستم هشدار سیلاب را برای ساکنان

1. Machine learning
2. Particle swarm optimization
3. Liu
4. Freworks algorithm


جریان در و برخی پارامترهای آماری داده‌های مورد استفاده در تحقیق است.

رودخانه مذکور در محل ایستگاه آسنجی ولیک بن طی سال‌های ۱۳۹۲-۱۳۸۷ (داده ۱۸۲۵) است. شکل ۲ و جدول ۲ به ترتیب، نمودار نوسانات دبی



شکل ۱: شمای کلی و ایستگاه هیدرومتری حوزه آبخیز کسلیان

تهیه و ترسیم: نگارندگان، ۱۴۰۰



شکل ۲: مقادیر مشاهداتی دبی روزانه ایستگاه آبسنجی ولیک بن تهیه و ترسیم: نگارندگان، ۱۴۰۰

جدول ۱: ویژگی‌های جغرافیایی ایستگاه مورد مطالعه

ایستگاه	رودخانه	طول جغرافیایی	عرض جغرافیایی	ارتفاع از سطح دریا (m)
ولیک‌بن	کسیلیان	۵۳° ۱۰' ۲۴"	۳۶° ۰۵' ۴۶"	۱۱۰۶

مأخذ: اسدی، ۱۳۸۷

جدول ۲: پارامترهای آماری داده‌های مورد استفاده در حوزه مورد مطالعه

مشخصه آماری	تعداد داده‌ها	مقدار حداکثر	مقدار حداقل	میانگین	واریانس	انحراف معیار
دبی جریان (m ³ /s)	۱۸۲۵	۶/۹۱	۰/۰۰۳	۰/۴۱	۰/۳۱	۰/۵۵

مأخذ: نگارندگان، ۱۴۰۰

- شبکه عصبی مصنوعی^۱

یک شبکه عصبی مصنوعی ایده‌ای است برای پردازش اطلاعات که با الگوبرداری از سیستم کارکرد مغز انسان به پردازش اطلاعات می‌پردازد. در واقع این نوع شبکه‌ها، با پردازش داده‌های تجربی و بدون توجه به فیزیک مسئله روابط پیچیده غیرخطی میان بردارهای ورودی و خروجی را می‌توانند شناسایی کنند (Haykin, 1999: 10).

در دهه‌های اخیر کاربرد شبکه‌های عصبی مصنوعی به‌عنوان یک ابزار مدل‌سازی برای فرایندهای هیدرولوژیکی از جمله پیش‌بینی سری‌های زمانی، مورد توجه زیادی قرار گرفته است (Kumar et al, 2016: 78). یک ساختار شبکه عصبی معمولاً از سه لایه تشکیل شده

است: ورودی، میانی و خروجی که در هر لایه تعدادی نرون در نظر گرفته می‌شود که به نرون‌های لایه‌های مجاور وصل می‌شوند. در این شبکه‌ها، نرون‌های لایه اول انتقال‌دهنده اطلاعات ورودی به نرون‌های لایه میانی هستند. در لایه میانی پس از محاسبه ورودی مؤثر هر نرون، این ورودی از یک تابع محرک گذرانده می‌شود. آخرین لایه یا لایه‌های خروجی شامل مقادیر پیش‌بینی شده توسط شبکه است. در این مدل الگوریتم‌های مختلفی نیز برای محاسبه وزن‌های بهینه شبکه وجود دارند که الگوریتم آموزش پس انتشار خطا پرکاربردترین آن‌ها هستند (Hagan & Menhaj, 1994: 989). به‌طور کلی، مقدار خروجی مدل شبکه عصبی مصنوعی با استفاده از رابطه (۱) به‌دست می‌آید (Kim & Valdés, 2003: 319):

معادله ۱:

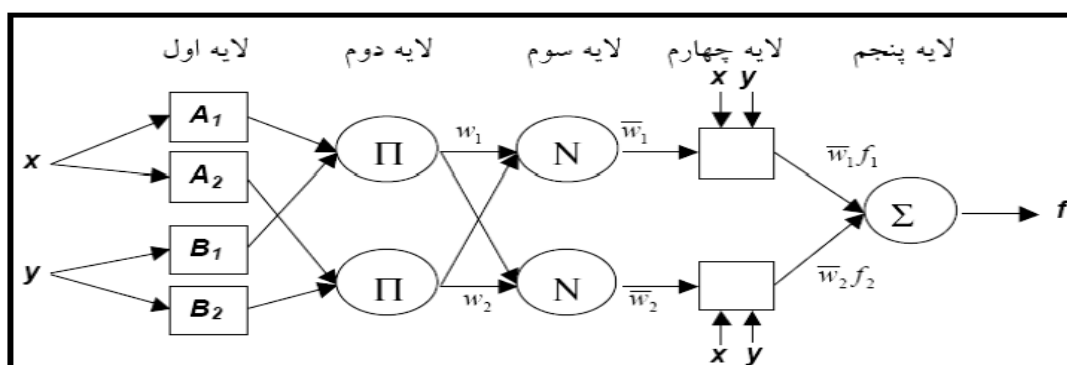
$$y_k = f_o \left[\sum_{j=1}^M w_{jk} \cdot f_h \left(\sum_{i=1}^N w_{ij} x_i + b_j \right) + b_k \right]$$

که وزن نرون M لایه ورودی در اتصال با نرون N لایه مخفی و w_{jk} وزن نرون N لایه مخفی در اتصال با نرون k لایه خروجی است. b_j و b_k مقادیر بایاس به ترتیب N لایه مخفی و k لایه خروجی و f_o و f_h توابع محرک به ترتیب لایه مخفی و خروجی هستند. x_i متغیر ورودی و y_k متغیر خروجی، N تعداد نرون‌های لایه ورودی و M تعداد نرون‌های لایه مخفی هستند. در مجموع مشخصات مدل شبکه عصبی مصنوعی به کار رفته در پژوهش حاضر به شرح زیر است:

در این مطالعه از شبکه عصبی مصنوعی پیشرو با الگوریتم پس انتشارخطا و تابع آموزش لونبرگ-مارکواریت و تعداد دوره‌های آموزش ۵۰۰ تا ۱۰۰۰ استفاده شد. علاوه بر این، توابع فعال‌سازی مورد استفاده برای لایه مخفی و خروجی ترکیبی از توابع سیگموئید و خطی بوده و به منظور تعیین تعداد مناسب نرون در لایه پنهان، از روش آزمون و خطا استفاده شد.

- سیستم استنتاج عصبی - فازی تطبیقی^۱

سیستم استنتاج عصبی - فازی تطبیقی از ترکیب الگوریتم‌های یادگیری منطق فازی و شبکه عصبی برای طراحی نگاشت غیرخطی بین بردارهای ورودی و خروجی استفاده می‌کند (نورانی و صالحی، ۱۳۸۷: ۱). الگوریتم یادگیری منطق فازی یک سیستم مبتنی بر قواعد منطقی «شرط- نتیجه» است که با استفاده از مفهوم متغیرهای زبانی و روند تصمیم‌گیری فازی، فضای متغیرهای ورودی را به فضای متغیرهای خروجی تصویر می‌کند (Kartalopoulos & Kartakopoulos, 1997: 10). یکی از مشکلات اصلی در طراحی این نوع سیستم تعیین قواعد «اگر- آنگاه» فازی و همچنین بهینه‌سازی پارامترهای توابع عضویت متغیرهای فازی است که با استفاده از قابلیت یادگیری شبکه عصبی، این مشکلات برطرف می‌شود (Nayak et al, 2004: 52). معمول‌ترین نوع سیستم استنتاج فازی که قابلیت قرارگیری در یک شبکه تطبیقی را دارد، سیستم فازی تاکاگی- سوگنو است که خروجی آن یک رابطه خطی است (سوگنو درجه یک) و پارامترهای آن را می‌توان با ترکیب روش‌های حداقل مربعات خطا و روش‌های پس‌انتشار خطا برآورد کرد. در شکل ۳ معماری معمول سیستم استنتاج عصبی - فازی تطبیقی ارائه شده است.



شکل ۳: معماری کلی سیستم استنتاج عصبی - فازی تطبیقی

تهیه و ترسیم: نبی‌زاده و همکاران، ۱۳۹۱

آموزش می‌بیند. در پایان، میزان خطای مدل‌های حاصل با هم مقایسه می‌شود و تابعی که کمترین میزان خطا را در کمترین زمان آموزش حاصل کند، به عنوان تابع عضویت انتخاب خواهد شد (Jang, 1993: 665). در مجموع مشخصات سیستم استنتاجی عصبی - فازی تطبیقی به کار رفته در پژوهش حاضر به شرح زیر است: در این مطالعه از سیستم استنتاج فازی تاکاگی - سوگونو درجه یک استفاده شد. به منظور فازی‌سازی الگوهای داده و همچنین استخراج قوانین سیستم روش جداسازی شبکه‌های^۱ به کار گرفته شد. در رابطه با تابع عضویت نیز هر کدام از ترکیبات ورودی با توابع عضویت ورودی مثلثی، گوسی، گوسی نوع دو و زنگوله‌ای و توابع عضویت خروجی خطی و ثابت مورد ارزیابی قرار گرفتند. الگوریتم آموزشی سیستم، از نوع الگوریتم هیبریدی و تعداد تکرارهای بهینه نیز به روش سعی و خطا به دست آمد.

- پیش پردازش داده‌ها

اصولاً به کارگیری داده‌ها به صورت خام باعث کاهش دقت و سرعت محاسبات می‌شود. برای رفع چنین شرایطی و یکسان‌سازی ارزش داده‌ها، عمل استاندارد کردن داده‌ها با محدود کردن مقادیر آن‌ها در یک بازه خاص صورت می‌گیرد. در پژوهش حاضر همه داده‌ها قبل از ورود به شبکه با استفاده از رابطه (۳) در محدوده صفر تا یک نرمال شدند (اسدی و همکاران، ۱۳۹۸: ۱۱۰).

معادله ۳:

$$X_{\text{norm}} = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}$$

که در آن X_{norm} داده نرمال شده، X_i داده مورد نظر، X_{\min} داده کمینه و X_{\max} داده بیشینه است.

به طور کلی ساختار سیستم استنتاج عصبی - فازی تطبیقی، شامل ۵ لایه است؛ لایه اول: گره‌های ورودی است که درجه عضویت هر ورودی را با توجه به تابع عضویت آن مشخص می‌کند. توابع عضویت استفاده شده در این سیستم می‌توانند تابع عضویت زنگوله‌ای، مثلثی، ذوزنقه‌ای، گوسی، گوسی نوع دو، سیگموئیدی و... باشند. لایه دوم: گره‌های قاعده است که هر گره در این لایه، درجه فعالیت یک قانون را محاسبه می‌کند. لایه سوم: گره‌های متوسط است که در این لایه، وزن نرمال شده با برآورد نسبت وزن اُمین قانون به مجموع وزن‌های تمامی قوانین به دست می‌آید. لایه چهارم: گره‌های نتیجه و لایه پنجم: گره‌های خروجی است. گره موجود در لایه خروجی نهایی سیستم استنتاجی عصبی - فازی تطبیقی را با استفاده از رابطه (۲)، محاسبه می‌کند:

$$O_i^5 = \sum_{i=1}^n \bar{w}_i f \quad \text{معادله ۲:}$$

در سیستم استنتاجی عصبی - فازی تطبیقی، عمل شبیه‌سازی زمانی به درستی انجام می‌شود که مجموعه پارامترهای تطبیقی (بخش فرض) و مجموعه پارامترهای متعاقب (بخش نتیجه)، به نحوی تخمین زده شوند که مقدار تابع خطای مدل در بخش آموزش را به حداقل برساند. همچنین در این سیستم، به منظور بهینه‌سازی پارامترهای دو بخش فرض و نتیجه، از یک الگوریتم دو وجهی هیبرید، شامل روش انتشار برگشتی شیب نزولی و الگوریتم حداقل مربعات خطا استفاده می‌شود. انتخاب تابع عضویت براساس آزمایش انواع مختلف توابع عضویت صورت می‌گیرد؛ به این معنی که توابع عضویت، هر کدام جداگانه مورد بررسی قرار می‌گیرند و سیستم استنتاجی عصبی - فازی تطبیقی برای هر کدام از این توابع عضویت به صورت جداگانه

داده‌های دبی جریان با توالی برگشتی تا ۷ روز (کارآموز و عراقی‌نژاد، ۱۳۹۷: ۳۱۸)، به صورت الگوهای مختلف مطابق با روابط (۴) تا (۱۰) استفاده شده است. در واقع برای تعیین بهترین الگو، ورودی‌های مختلفی در مدل‌های سیستم استنتاج عصبی- فازی تطبیقی و شبکه عصبی مصنوعی در نظر گرفته شد که در نهایت ترکیبی که بهترین نتایج را در ارزیابی مقایسه‌ای داشته باشد، به عنوان الگوی بهینه انتخاب شد.

$$Q_t = f(Q_{t-1}) \quad \text{معادله ۴:}$$

$$Q_t = f(Q_{t-1}, Q_{t-2}) \quad \text{معادله ۵:}$$

$$Q_t = f(Q_{t-1}, Q_{t-2}, Q_{t-3}) \quad \text{معادله ۶:}$$

$$Q_t = f(Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}) \quad \text{معادله ۷:}$$

$$Q_t = f(Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}) \quad \text{معادله ۸:}$$

$$Q_t = f(Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}) \quad \text{معادله ۹:}$$

$$Q_t = f(Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}, Q_{t-6}, Q_{t-7}) \quad \text{معادله ۱۰:}$$

معادله ۱۱:

$$R^2 = \left[\frac{\sum_{i=1}^n (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (S_i - \bar{S})^2}} \right]^2$$

معادله ۱۲:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - S_i)^2}$$

که در این روابط Q_t و S_t ، به ترتیب دبی روزانه مشاهده‌ای و محاسبه‌ای، \bar{O} و \bar{S} به ترتیب میانگین دبی روزانه مشاهده‌ای و محاسبه‌ای و n تعداد نمونه‌هاست.

- الگوسازی جریان

به‌طور کلی پیش‌بینی دبی می‌تواند به صورت بلندمدت یا کوتاه‌مدت باشد که در پیش‌بینی‌های کوتاه‌مدت معمولاً افق زمانی پیش‌بینی کمتر از هفت روز در نظر گرفته می‌شود و در پیش‌بینی‌های بلندمدت این افق زمانی معمولاً طولانی است و تا چندین ماه می‌تواند در نظر گرفته شود (Kisi, 2008: 4142).

با توجه به اینکه در تحقیق حاضر پیش‌بینی کوتاه‌مدت جریان و تأثیر توالی دبی روزهای قبل در پیش‌بینی دبی روز جاری مدنظر بوده؛ از این رو صرفاً از

که در آن Q_t دبی جریان روز جاری، Q_{t-1} ، Q_{t-2} و Q_{t-7} به ترتیب دبی جریان در یک روز قبل، دو روز قبل و تا هفت روز قبل مدنظر قرار گرفته است. با توجه به توضیحات بالا، پیش‌بینی دبی جریان روزانه با استفاده از ورودی‌های مذکور تحت هفت الگو انجام گرفت.

- شاخص‌های ارزیابی الگوها

برای ارزیابی و مقایسه کارایی الگوهای مورد استفاده در این پژوهش، از معیارهای آماری جذر میانگین مربعات خطا^۱ و ضریب تبیین^۲ مطابق با روابط زیر استفاده شد (Asadi et al, 2021: 10):

1. Root mean square error
2. Coefficient of determination

نتایج و بحث

-نتایج مدل سازی با استفاده از شبکه عصبی مصنوعی در این پژوهش به منظور مدل سازی دبی روزانه در ایستگاه ولیکن، پس از بررسی داده های مورد استفاده، ۸۰ درصد کل داده ها برای آموزش و ۲۰ درصد باقی مانده برای آزمون انتخاب شدند؛ بدین ترتیب که سری مشخصی از داده ها که مقادیر حداقل و حداکثر را دربر می گیرد، به عنوان مجموعه آموزش جدا شده و بقیه برای ارزیابی و آزمون کنار گذاشته شدند. در نهایت، با استفاده از هفت الگوی ورودی، فرایند مدل سازی دبی روزانه با استفاده از شبکه های هوشمند مذکور صورت گرفت. در مدل شبکه عصبی مصنوعی، به منظور تعیین تعداد مناسب نرون در لایه میانی از آزمون و خطا استفاده شد و در نهایت یک معماری بهینه برای هر الگوی ورودی که بهترین برازش را بین مقادیر محاسبه ای و مشاهده ای داشته باشند، تعیین شد. نتایج ساختار بهینه و همچنین مقادیر شاخص های آماری برای الگوهای ورودی مذکور در مدل شبکه

عصبی مصنوعی در جدول ۳ ارائه شده اند. مقایسه هفت الگوی ورودی با یکدیگر نشان می دهد که به طور کلی نتایج رفته رفته تا دبی پنج روز قبل رو به بهبود بوده و بعد از آن نتایج رو به نزول می گذارد. در نهایت الگوی ورودی شماره ۵، با ضریب تبیین = ۰/۵۱ و جذر میانگین مربعات خطا = ۱/۷۴ برای مجموعه آزمون و ضریب تبیین = ۰/۷۶ و جذر میانگین مربعات خطا = ۰/۴۷ برای مجموعه آموزش، به عنوان بهترین ساختار مشخص شد که به صورت ۱-۲۰-۵ یعنی پنج نرون در لایه ورودی، بیست نرون در لایه پنهان و یک نرون در لایه خروجی است. همچنین بررسی نتایج جدول ۳ نشان می دهد که الگوی ورودی شماره ۷ با ضریب تبیین = ۰/۲۷ و جذر میانگین مربعات خطا = ۲/۷۸ برای مجموعه آزمون و ضریب تبیین = ۰/۳۵ و جذر میانگین مربعات خطا = ۰/۶۹ برای مجموعه آموزش کمترین کارایی را در پیش بینی دبی روزانه داشت که نشان می دهد پارامترهای ورودی اضافی نه تنها کارایی پیش بینی را بهبود نمی بخشد، بلکه دقت پیش بینی مدل را نیز کاهش می دهد.

جدول ۳: ساختار بهینه و نتایج مدل سازی دبی روزانه توسط شبکه عصبی مصنوعی با هفت الگوی ورودی برای مجموعه های آموزش و آزمون

آزمون		آموزش		بهترین ساختار	الگوی ورودی
RMSE	R ²	RMSE	R ²		
۲/۱۳۶	۰/۴۳۹	۰/۵۸۵	۰/۵۰۲	۱-۱۲-۱	۱
۲/۴۷۸	۰/۴۴۲	۰/۴۹۸	۰/۷۲۰	۲-۱۰-۱	۲
۲/۴۲۰	۰/۴۸۳	۰/۴۸۹	۰/۷۳۴	۳-۱۳-۱	۳
۲/۴۱۱	۰/۴۶۹	۰/۴۸۷	۰/۷۳۲	۴-۱۵-۱	۴
۱/۷۴۰	۰/۵۱۱	۰/۴۷۰	۰/۷۶۳	۵-۲۰-۱	۵
۱/۷۶۰	۰/۵۰۱	۰/۵۳۶	۰/۶۵۷	۶-۲۰-۱	۶
۲/۷۸۱	۰/۲۷۱	۰/۶۹۰	۰/۳۵۵	۷-۱۷-۱	۷

مأخذ: نگارندگان، ۱۴۰۰

ورودی مشخص شد که برای تعیین توابع عضویت بهینه، چهار تابع مثلثی، زنگوله‌ای، گوسی و گوسی نوع دو مورد آزمون قرار گرفت. پس از بررسی همه‌الگوهای ورودی با توابع عضویت مذکور، بهترین نتایج هر الگو تعیین شد که نتایج و پارامترهای آماری مربوط به آن‌ها در جدول ۴ ارائه شده‌اند.

نتایج مدل‌سازی با استفاده از سیستم استنتاج عصبی- فازی تطبیقی به منظور بررسی دقت سیستم استنتاج عصبی- فازی تطبیقی نیز از ترکیب‌های مختلف ورودی داده‌ها شامل دبی یک روز قبل، دو روز قبل تا هفت روز قبل استفاده شد. برای تعیین ساختار بهینه در این مدل با استفاده از آزمون و خطا، تعداد و نوع توابع عضویت برای هر الگوی

جدول ۴: ساختار بهینه و نتایج مدل‌سازی دبی روزانه توسط سیستم استنتاج عصبی- فازی تطبیقی با هفت الگوی ورودی برای مجموعه‌های آموزش و آزمون

الگو	تابع عضویت ورودی	آموزش		آزمون	
		RMSE	R ²	RMSE	R ²
۱	مثلثی	۰/۷۶۹	۰/۵۲۱	۰/۶۶۵	۰/۵۶۱
	زنگوله‌ای	۰/۷۷۰	۰/۵۰۰	۰/۶۳۹	۰/۵۵۳
	گوسی	۰/۷۷۲	۰/۵۰۳	۰/۶۳۹	۰/۵۶۲
	گوسی ۲	۰/۷۶۷	۰/۵۱۹	۰/۶۶۱	۰/۵۴۴
۲	مثلثی	۰/۷۸۳	۰/۵۱۴	۰/۶۶۳	۰/۵۵۹
	زنگوله‌ای	۰/۷۹۳	۰/۵۱۱	۰/۶۴۴	۰/۵۴۴
	گوسی	۰/۷۹۵	۰/۵۱۰	۰/۶۴۴	۰/۵۴۷
	گوسی ۲	۰/۷۹۲	۰/۵۱۳	۰/۶۵۹	۰/۵۴۳
۳	مثلثی	۰/۷۹۷	۰/۴۹۴	۰/۶۵۸	۰/۵۵۶
	زنگوله‌ای	۰/۸۱۳	۰/۵۱۸	۰/۶۴۸	۰/۴۸۳
	گوسی	۰/۸۲۸	۰/۵۰۶	۰/۶۴۹	۰/۴۸۸
	گوسی ۲	۰/۸۰۴	۰/۵۱۵	۰/۶۵۶	۰/۴۹۵
۴	مثلثی	۰/۸۸۳	۰/۴۸۶	۰/۶۶۱	۰/۵۸۰
	زنگوله‌ای	۰/۸۷۲	۰/۴۸۹	۰/۶۴۸	۰/۵۹۴
	گوسی	۰/۸۷۷	۰/۴۷۹	۰/۶۳۸	۰/۵۹۹
	گوسی ۲	۰/۸۶۶	۰/۴۸۱	۰/۶۳۸	۰/۵۹۷
۵	مثلثی	۰/۸۵۹	۰/۵۶۵	۰/۶۴۵	۰/۳۲۹
	زنگوله‌ای	۰/۸۵۰	۰/۵۴۸	۰/۶۵۲	۰/۳۲۳
	گوسی	۰/۸۵۹	۰/۵۴۲	۰/۶۴۶	۰/۳۳۱
	گوسی ۲	۰/۸۴۶	۰/۵۵۵	۰/۶۵۷	۰/۳۰۳
۶	مثلثی	۰/۸۷۴	۰/۵۹۲	۰/۶۴۲	۰/۲۶۸
	زنگوله‌ای	۰/۸۶۳	۰/۵۲۶	۰/۶۶۰	۰/۴۴۴
	گوسی	۰/۸۷۰	۰/۵۸۸	۰/۶۵۱	۰/۳۳۰
	گوسی ۲	۰/۸۵۹	۰/۴۹۵	۰/۶۴۳	۰/۴۶۵
۷	مثلثی	۰/۸۲۶	۰/۵۴۰	۰/۶۵۶	۰/۲۲۴
	زنگوله‌ای	۰/۸۲۰	۰/۵۷۱	۰/۶۵۰	۰/۳۳۵
	گوسی	۰/۸۳۹	۰/۵۱۴	۰/۶۴۹	۰/۳۸۸
	گوسی ۲	۰/۸۱۹	۰/۵۵۸	۰/۶۵۳	۰/۳۴۵

مأخذ: نگارندگان، ۱۴۰۰

فازی تطبیقی با متغیرهای ورودی کمتر معمولاً عملکرد بهتری از خود نشان می‌دهد و اطلاعات ورودی اضافی نه تنها کارایی پیش‌بینی را بهبود نمی‌بخشد، بلکه بر عملکرد مدل تأثیر منفی می‌گذارد.


سلاجقه و همکاران (۱۳۸۸) نیز تأیید کردند که با افزایش شمار ورودی‌ها و توابع عضویت عملکرد مدل بدتر شده است. همچنین بررسی و مقایسه نتایج با توابع عضویت مختلف نشان می‌دهد که نوع تابع عضویت بر عملکرد مدل تأثیرگذار است؛ ولی مقدار این تأثیر خیلی زیاد نیست که با نتایج سلاجقه و همکاران (۱۳۸۸) نیز مطابقت دارد. علاوه بر این، براساس پارامترهای آماری ملاحظه می‌شود که در سیستم استنتاج عصبی- فازی تطبیقی در اکثر موارد مدل با تابع عضویت گوسی و زنگوله‌ای برای ورودی‌ها دقیق‌ترین نتایج پیش‌بینی دبی را ارائه می‌دهد.

- تعیین بهترین مدل


به منظور ارزیابی کارایی مدل‌ها، نمودار پراکنش و همچنین منحنی سری زمانی داده‌های مشاهده‌ای در مقابل داده‌های محاسبه‌ای برای الگوهای بهینه ترسیم شد. شکل‌های ۴ و ۵ به ترتیب، نمودار پراکنش دبی روزانه مشاهده‌ای و محاسبه‌ای داده‌های آزمون برای الگوهای منتخب در مدل‌های شبکه عصبی مصنوعی ($R^2 = 0/51$) و سیستم استنتاج عصبی- فازی تطبیقی ($R^2 = 0/60$) را نشان می‌دهند.

مقایسه نتایج طی دوره آزمون نشان می‌دهد که به‌طور کلی با افزایش تعداد ورودی‌ها دقت مدل‌سازی افزایش یافته؛ به‌طوری‌که الگوی شماره چهار در هر چهار تابع عضویت مثلثی، زنگوله‌ای، گوسی و گوسی نوع دو نسبت به سایر الگوهای ورودی، کارایی بهتری داشته است. این نتیجه با نتایج زارع ابیانه و بیات ورکشی (۱۳۹۰) و کورتولوس و رازاک (۲۰۱۰) مطابقت دارد که البته با افزایش تعداد ورودی‌ها بیشتر از چهار تأخیر و نیز افزایش توابع عضویت بیشتر از سه، عملکرد مدل بدتر شده است و در واقع، بهترین نتایج مربوط به الگوی شماره چهار با تابع عضویت گوسی است. در واقع، این الگو با ضریب تبیین $= 0/60$ و جذر میانگین مربعات $\text{خطا} = 0/64$ برای مجموعه آزمون و ضریب تبیین $= 0/88$ و جذر میانگین مربعات $\text{خطا} = 0/48$ برای مجموعه آموزش، به‌عنوان مدل بهینه انتخاب شد.

دستورانی و همکاران (۱۳۹۰) نیز نشان دادند که در تخمین دبی روزانه با استفاده از مدل سیستم استنتاج عصبی- فازی تطبیقی، نتایج تا دبی چهار روز قبل رو به بهبود بوده است و بعد از آن رو به نزول می‌گذارد و حالت بهینه مربوط به الگوی ورودی با دبی چهار روز قبل بوده است. ضعیف‌ترین نتایج در دوره آزمون، مربوط به الگوی شماره هفت با تابع عضویت مثلثی است (ضریب تبیین $= 0/22$ و جذر میانگین مربعات $\text{خطا} = 0/66$). عدنان و همکاران (۲۰۲۱) در این زمینه بیان کردند که مدل سیستم استنتاج عصبی-




شکل ۴: نمودار پراکنش بهترین الگوی ورودی در دورهٔ آزمون با استفاده از مدل شبکهٔ عصبی مصنوعی تهیه و ترسیم: نگارندگان، ۱۴۰۰




شکل ۵: نمودار پراکنش بهترین الگوی ورودی در دورهٔ آزمون با استفاده از سیستم استنتاج عصبی- فازی تطبیقی تهیه و ترسیم: نگارندگان، ۱۴۰۰

۶ و ۷ نیز به ترتیب منحنی سری زمانی دبی روزانهٔ مشاهده‌ای در مقابل محاسبه‌ای برای الگوهای بهینه در هر دو مدل شبکهٔ عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی نشان داده شده است.

مقایسهٔ مقادیر پراکنده بین داده‌های مشاهده‌ای و محاسبه‌ای مدل‌های منتخب در طی دورهٔ آزمون نشان می‌دهد که اختلاف مقادیر مشاهده‌ای مدل‌سازی شده در سیستم استنتاج عصبی- فازی تطبیقی نسبت به مدل شبکهٔ عصبی مصنوعی کمتر است. در شکل‌های



شکل ۶: نمودار سری زمانی دبی روزانه مشاهده‌ای و محاسبه‌ای بهترین الگوی ورودی در دوره آزمون با استفاده از مدل شبکه عصبی مصنوعی (تهیه و ترسیم: نگارندگان، ۱۴۰۰)



شکل ۷: نمودار سری زمانی دبی روزانه مشاهده‌ای و محاسبه‌ای بهترین الگوی ورودی در دوره آزمون با استفاده از سیستم استنتاج عصبی- فازی تطبیقی (تهیه و ترسیم: نگارندگان، ۱۴۰۰)

مهر و مجدزاده طباطبایی (۱۳۸۹) نیز مقادیر منفی را در پیش‌بینی دبی روزانه با استفاده از شبکه عصبی مصنوعی نشان داد که البته به لحاظ فیزیکی غیرممکن است.

از طرفی با توجه به نتایج به دست آمده از هر دو مدل و مقایسه آن‌ها با یکدیگر مشخص شد که هر دو مدل با دقت خوبی می‌توانند دبی جریان را پیش‌بینی کنند که با نتایج تحقیقات دستورانی (۱۳۸۶)، معتمدنیا و همکاران (۲۰۱۵)، اسدی و همکاران (۲۰۱۹) و داو و همکاران (۲۰۲۰) که حاکی از دقت بالای شبکه عصبی مصنوعی است، همخوانی دارد.

همان‌طور که در شکل‌های ۶ و ۷ مشخص است، تطابق منحنی دبی مشاهده‌ای و مدل‌سازی شده در سیستم استنتاج عصبی- فازی تطبیقی بیشتر از مدل شبکه عصبی مصنوعی است و در مدل شبکه عصبی مصنوعی برآزش کمتری با داده‌های مشاهده‌ای وجود دارد. علاوه بر این، سیستم استنتاج عصبی- فازی تطبیقی توانسته است مقادیر پایین و بالای (اوج) دبی را با دقت بهتری برآورد کند. همچنین نمودارهای سری زمانی جریان روزانه پیش‌بینی شده نشان می‌دهد که هر دو مدل برای برخی از مقادیر دبی حداقل، مقادیر منفی را پیش‌بینی کرده‌اند که نتایج داننده

عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی در حوزهٔ آبخیز کسلیان صورت گرفت که در مجموع با وجود کارایی هر دو مدل در شبیه‌سازی جریان رودخانه، ولی مدل سیستم استنتاج عصبی - فازی تطبیقی را به‌عنوان یک روش دقیق‌تر برای پیش‌بینی جریان رودخانه بر مبنای توالی جریان پیشنهاد می‌کند. نتایج این پژوهش نشان داد که به‌کارگیری پارامترهای ورودی مناسب و استفاده از ساختار معماری صحیح در بهبود نتایج پیش‌بینی جریان رودخانه با استفاده از مدل‌های هوشمند مؤثر بود. بنابراین طراحی بهینهٔ شبکه‌های هوشمند و انتخاب دادهٔ ورودی مناسب، علاوه بر ابزار مدل‌سازی در افزایش دقت نتایج مؤثر است. از طرفی با توجه به اینکه استفاده از روش‌های مختلف، نتایج متفاوتی را در شرایط مختلف به‌همراه داشته است، پیشنهاد می‌شود این پژوهش در شرایط مختلف منطقه‌ای و جغرافیایی (به‌ویژه حوزه‌هایی که از نظر ویژگی‌های اقلیمی، هیدرولوژیکی و ژئومورفولوژیکی با حوزهٔ مورد بررسی متفاوت هستند) تکرار و نتایج مورد آزمون قرار گیرد. همچنین به‌دلیل غیرصریح بودن مدل‌های هوش مصنوعی مورد استفاده در این پژوهش، استفاده از روش‌های صریح نظیر برنامه‌ریزی ژنتیک یا روش‌های نوین دیگر به‌منظور برآورد دبی جریان و مقایسهٔ نتایج آن‌ها با پژوهش حاضر پیشنهاد می‌شود. علاوه بر این، با توجه به نقش پارامترهای اقلیمی، هیدروژئومورفیک و بیوفیزیکی حوزه در میزان جریان رودخانه، بررسی این پارامترها علاوه بر پارامتر هیدرولوژیکی به‌کارگرفته‌شده در پژوهش حاضر به‌عنوان ورودی مدل‌ها برای برآورد دقیق و مطلوب مقدار دبی جریان پیشنهاد می‌شود.

البته نتایج نشان داد که سیستم استنتاج عصبی - فازی تطبیقی از دقت و کارایی بیشتری برخوردار است که با نتایج نایاک و همکاران (۲۰۰۵)، تیفور و سینگ (۲۰۰۶)، فیرات (۲۰۰۷)، نورانی و همکاران (۱۳۸۸)، کورتولوس و رازاک (۲۰۱۰)، دستورانی و همکاران (۱۳۹۰)، شجاع رستگاری و بارانی (۲۰۱۱)، اینسری و وارکیس (۲۰۱۶) و ری و سینگ (۲۰۲۰) مبنی بر کارایی بیشتر این مدل نسبت به مدل شبکهٔ عصبی مصنوعی مطابقت دارد. کارایی بهتر این مدل به‌علت ترکیب دو مدل فازی و عصبی است (Liu et al., 2021: 2934)؛ بدین‌صورت که آموزش داده‌ها با استفاده از شبکهٔ عصبی صورت گرفته و با بهره‌گیری از یک تابع عضویت خاص و یک سری قوانین فازی، مدل ساخته می‌شود. البته یکی از محدودیت‌های سیستم استنتاج عصبی - فازی تطبیقی، تعداد ورودی‌های آن است؛ زیرا با افزایش قوانین فازی، که آن نیز متناسب با تعداد متغیرهای ورودی مدل است، ساختار پیچیده‌ای از مدل تشکیل می‌شود که روند شبیه‌سازی را طولانی می‌کند. مزیت این مدل این است که با توجه به اینکه زمان کمتری برای آموزش احتیاج دارد، می‌توان چندین تابع عضویت را برای این مدل مورد آزمایش قرار داد که نتایج پهلوانی (۱۳۸۸) نیز این نتایج را تأیید می‌کند. همچنین نتایج این پژوهش نشان داد که در مدل‌های مبتنی بر داده، انتخاب ورودی‌ها با زمان تأخیر مناسب مهم است؛ زیرا بردارهای ورودی ساختار مدل را تعیین می‌کنند و بر نتایج مدل مؤثر هستند (Asadi et al., 2019: 1).

نتیجه

پژوهش حاضر به‌منظور بررسی تأثیر توالی دبی روزانه در پیش‌بینی جریان رودخانه با استفاده از مدل شبکهٔ

منابع

- اسدی، هانیه؛ کاکا شاهی؛ ری سایدل؛ سید مصطفی کلامی هریس (۱۳۹۸). پیش‌بینی رسوب معلق با استفاده از داده‌های هیدرولوژیک و هیدروژئومورفیک در مدل‌های هوشمند، مجله تحقیقات منابع آب ایران. سال ۱۵. شماره ۳. شماره پیاپی ۵۰. صفحات ۱۱۹-۱۰۵. <https://www.magiran.com/paper/2068726>
- پوستی‌زاده، ندا؛ جمال محمد ولی سامانی؛ امین کوره‌پزان دزفولی (۱۳۸۷). پیش‌بینی جریان رودخانه با استفاده از سیستم استنتاج فازی، مجله تحقیقات منابع آب ایران. سال ۴. شماره ۲. شماره پیاپی ۱۱. صفحات ۳۴-۲۳. <https://www.magiran.com/paper/897697>
- پهلوانی، حمید (۱۳۸۸). ارزیابی کارایی مدل‌های شبکه عصبی مصنوعی در تخمین هوشمند هیدروگراف سیل ورودی به سد مخزنی شیرین‌دره در مقایسه با مدل‌های تطبیقی عصبی- فازی، پایان‌نامه کارشناسی ارشد، دانشگاه علوم کشاورزی و منابع طبیعی گرگان. ۱۲۳ صفحه. <https://ganj.irandoc.ac.ir/#/articles/ed8982b031f3b29aa2f0b1b7a816d4ab>
- داننده مهر، علی؛ محمد رضا مجدزاده طباطبایی (۱۳۸۹). بررسی تأثیر توالی دبی روزانه در پیش‌بینی جریان رودخانه‌ها با استفاده از برنامه‌ریزی ژنتیک، نشریه آب و خاک. سال ۲۴. شماره ۲. شماره پیاپی ۱۰. صفحات ۳۳۳-۳۲۵. <https://www.magiran.com/paper/750345>
- دستورانی، محمدتقی (۱۳۸۶). بررسی کاربرد مدل‌های هوش محاسباتی در شبیه‌سازی و پیش‌بینی به‌هنگام جریان‌های سیلابی، نشریه علوم آب و خاک (علوم و فنون کشاورزی و منابع طبیعی). سال ۱۱. شماره ۲. شماره پیاپی ۴۰. صفحات ۳۷-۲۷. <https://www.magiran.com/paper/474118>
- دستورانی، محمدتقی؛ حامد شریفی دارانی، علی طالبی، علیرضا مقدس‌نیا، (۱۳۹۰). کارایی شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی در مدل‌سازی بارش- رواناب در حوضه آبخیز سد زاینده‌رود، مجله آب و فاضلاب. دوره ۲۲. شماره ۴. شماره پیاپی ۸۰. صفحات ۱۲۵-۱۱۴. <https://www.magiran.com/paper/949761>
- زارع ابیانه، حمید؛ مریم بیات‌ورکشی (۱۳۹۰). ارزیابی مدل‌های هوشمند عصبی و تجربی در تخمین رواناب سالانه. نشریه آب و خاک (علوم و صنایع کشاورزی)، دوره ۲۵. شماره ۲. صفحات ۳۷۹-۳۶۵. <https://www.sid.ir/fa/journal/ViewPaper.aspx?id=135206>
- سلاجقه، علی؛ ابوالحسن فتح آبادی؛ محمد مهدوی (۱۳۸۸). بررسی کارایی روش‌های عصبی- فازی و مدل‌های آماری در شبیه‌سازی فرایند بارش- رواناب، فصلنامه مرتع و آبخیزداری. سال ۶۲. شماره ۱. صفحات ۷۹-۶۵. <https://www.magiran.com/paper/684437>
- شجاع رستگاری، حمید؛ غلام‌عباس بارانی (۱۳۹۰). استفاده از سیستم فازی- عصبی تطبیقی در مدل‌سازی بارش- رواناب، اولین همایش منطقه‌ای توسعه منابع آب. دانشگاه آزاد اسلامی. واحد ابرکوه. ۱۳ صفحه. <https://civilica.com/doc/114808>
- صادقی، سید حمیدرضا؛ هانیه اسدی (۱۳۸۹). اهمیت زمان پیمایش بین خطوط هم‌زمان تمرکز در دقت تخمین سیلاب از آب‌نمود واحد لحظه‌ای کلارک، نشریه آب و خاک. سال ۲۴. شماره ۴. شماره پیاپی ۱۲. صفحات ۶۳۵-۶۲۵. <https://www.magiran.com/paper/790598>
- فتح‌آبادی، ابوالحسن؛ علی سلاجقه؛ محمد مهدوی (۱۳۸۷). پیش‌بینی دبی رودخانه با استفاده از روش‌های نور و فازی و مدل‌های سری‌های زمانی، مجله علوم و مهندسی آبخیزداری ایران. سال ۲. شماره ۵. صفحات ۲۱-۳۰. <https://www.magiran.com/paper/686503>
- کارآموز، محمد؛ شهاب عراقی‌نژاد (۱۳۹۷). هیدرولوژی پیشرفته، انتشارات دانشگاه صنعتی امیرکبیر. چاپ اول. ۴۶۸ صفحه. <https://www.adinehbook.com/gp/product/9644632745>

نبی‌زاده، مرتضی؛ ابوالفضل مساعدی؛ موسی حسام؛ امیراحمد دهقانی (۱۳۹۱). پیش‌بینی جریان رودخانه با استفاده از سامانه استنتاج فازی (FIS) و سامانه استنتاج فازی-عصبی تطبیقی (ANFIS)، مجله علوم و مهندسی آبخیزداری ایران. سال ۵. شماره ۱۷. صفحات ۱۴-۷. <https://www.magiran.com/paper/1083411>

نورانی، وحید؛ کامران صالحی (۱۳۸۷). مدل‌سازی بارش-رواناب با استفاده از روش شبکه عصبی فازی تطبیقی و مقایسه آن با روش‌های شبکه عصبی و استنتاج فازی (مطالعه موردی: حوضه آبریزلیقوان چای واقع در استان آذربایجان شرقی)، چهارمین کنگره ملی مهندسی عمران. تهران. ۸ صفحه. <https://civilica.com/doc/38309/>

نورانی، وحید؛ محمدعلی کی‌نژاد؛ لیلا ملکانی (۱۳۸۸). استفاده از سیستم فازی-عصبی تطبیقی در مدل‌سازی بارش-رواناب، نشریه مهندسی عمران و محیط زیست دانشگاه تبریز. سال ۳۹. شماره ۴. شماره پیاپی ۶۰. صفحات ۸۱-۷۵. <https://www.magiran.com/paper/880137>

References

- Adnan, R. M., Petroselli, A., Heddami, S., Santos, C. A. G., & Kisi, O. (2021). Short term rainfall-runoff modelling using several machine learning methods and a conceptual event-based model. *Stochastic Environmental Research and Risk Assessment*, 35(3), 597-616. <https://doi.org/10.1007/s00477-020-01910-0>
- Anusree, K., & Varghese, K. O. (2016). Streamflow prediction of Karuvannur River Basin using ANFIS, ANN and MNL models. *Procedia Technology*, 24, 101-108. <https://doi.org/10.1016/j.protcy.2016.05.015>
- Asadi, H., Dastorani, M. T., Sidle, R. C., & Shahedi, K. (2021). Improving Flow Discharge-Suspended Sediment Relations: Intelligent Algorithms versus Data Separation. *Water*, 13(24), 3650. <https://doi.org/10.3390/w13243650>
- Asadi, H., Shahedi, K., Jarihani, B., & Sidle, R. C. (2019). Rainfall-runoff modelling using hydrological connectivity index and artificial neural network approach. *Water*, 11(2), 212. <https://doi.org/10.3390/w11020212>
- Chen, J. C., Chang, N. B., & Shieh, W. K. (2003). Assessing wastewater reclamation potential by neural network model. *Engineering applications of artificial intelligence*, 16(2), 149-157. [https://doi.org/10.1016/S0952-1976\(03\)00056-3](https://doi.org/10.1016/S0952-1976(03)00056-3)
- Dou, M., Qin, C., Li, G., & Wang, C. (2020). Research on calculation method of free flow discharge based on artificial neural network and regression analysis. *Flow Measurement and Instrumentation*, 72, 102-123. <https://doi.org/10.1016/j.flowmeasinst.2020.101707>
- El-Shafie, A., Taha, M. R., & Noureldin, A. (2007). A neuro-fuzzy model for inflow forecasting of the Nile river at Aswan high dam. *Water resources management*, 21(3), 533-556. <https://doi.org/10.1007/s11269-006-9027-1>
- Firat, M. (2007). Artificial intelligence techniques for river flow forecasting in the Seyhan river catchment, Turkey. *Hydrology and Earth System Sciences Discussions*, 4(3), 1369-1406. <https://hal.archives-ouvertes.fr/hal-00298839>
- Hagan, M. T., & Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE transactions on Neural Networks*, 5(6), 989-993. <https://doi.org/10.1109/72.329697>
- Haykin, S. (1999). *Neural Networks, a comprehensive foundation*, Prentice-Hall Inc. Upper Saddle River, New Jersey, 7458, 842. https://onsearch.library.rice.edu/permalink/01RICE_INST/11atd6j/alma991012352029705251
- Hosseini, S. M., & Mahjouri, N. (2016). Integrating support vector regression and a geomorphologic artificial neural network for daily rainfall-runoff modeling. *Applied Soft Computing*, 38, 329-345. <https://doi.org/10.1016/j.asoc.2015.09.049>

- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.
<https://doi.org/10.1109/21.256541>
- Kartalopoulos, S. V., & Kartakopoulos, S. V. (1997). *Understanding neural networks and fuzzy logic: basic concepts and applications*. Wiley-IEEE Press. 205.
<https://dl.acm.org/doi/book/10.5555/550087>
- Kim, T. W., & Valdés, J. B. (2003). Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering*, 8(6), 319-328.
[https://doi.org/10.1061/\(ASCE\)1084-0699\(2003\)8:6\(319\)](https://doi.org/10.1061/(ASCE)1084-0699(2003)8:6(319))
- Kişî, Ö (2008). Stream flow forecasting using neuro- wavelet technique. *Hydrological Processes: An International Journal*, 22(20), 4142-4152.
<https://doi.org/10.1002/hyp.7014>
- Kisi, O., Shiri, J., & Nikoofar, B. (2012). Forecasting daily lake levels using artificial intelligence approaches. *Computers & Geosciences*, 41, 169-180.
<https://doi.org/10.1016/j.cageo.2011.08.027>
- Kumar, D., Pandey, A., Sharma, N., & Flügel, W. A. (2016). Daily Suspended Sediment simulation using machine learning approach. *Catena*, 138, 77-90.
<https://doi.org/10.1016/j.catena.2015.11.013>
- Kurtulus, B., & Razack, M. (2010). Modeling daily discharge responses of a large karstic aquifer using soft computing methods: Artificial neural network and neuro-fuzzy. *Journal of Hydrology*, 381(1-2), 101-111.
<https://doi.org/10.1016/j.jhydrol.2009.11.029>
- Liu, Z., Li, Q., Zhou, J., Jiao, W., & Wang, X. (2021). Runoff Prediction Using a Novel Hybrid ANFIS Model Based on Variable Screening. *Water Resources Management*, 35(9), 2921-2940.
<https://doi.org/10.1007/s11269-021-02878-4>
- Moatamednia, M., Nohegar, A., Malekian, A., Asadi, H., Tavasoli, A., Safari, M., & Karimi, K. (2015). Daily river flow forecasting in a semi-arid region using twodatadriven. *Desert*, 20(1), 11-21.
<https://dx.doi.org/10.22059/jdesert.2015.54078>
- Nayak, P. C., Sudheer, K. P., Rangan, D. M., & Ramasastri, K. S. (2004). A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*, 291(1-2), 52-66.
<https://doi.org/10.1016/j.jhydrol.2003.12.010>
- Nayak, P. C., Sudheer, K. P., Rangan, D. M., & Ramasastri, K. S. (2005). Short- term flood forecasting with a neurofuzzy model. *Water Resources Research*, 41(4). 2517-2530
<https://doi.org/10.1029/2004WR003562>
- Roy, B., & Singh, M. P. (2020). An empirical-based rainfall-runoff modelling using optimization technique. *International journal of river basin management*, 18(1), 49-67.
<https://doi.org/10.1080/15715124.2019.1680557>
- Sachan, A., & Kumar, D. (2017). Neural Fuzzy Inference System Modelling with Different Input Vectors for Rainfall-Runoff Prediction. *International Journal of Advance Research, Ideas and Innovations in Technology*, 4, 449-458.
<https://www.ijariit.com/manuscripts/v4i1/V4I1-1305.pdf>
- Tayfur, G., & Singh, V. P. (2006). ANN and fuzzy logic models for simulating event-based rainfall-runoff. *Journal of hydraulic engineering*, 132(12), 1321-1330.
[https://doi.org/10.1061/\(ASCE\)0733-9429\(2006\)132:12\(1321\)](https://doi.org/10.1061/(ASCE)0733-9429(2006)132:12(1321))