

Research Paper

Comparison of the performance of machine learning models and conceptual hydrological models in rainfall-runoff simulation (Case study: Khorramabad River Basin)

Roghayeh Amiri¹, Seyed Yahya Mirzaee^{2*}, Manuchehr Chitsazan³

¹ Ph.D. in hydrogeology, Faculty of Geosciences, Shahid Chamran University of Ahvaz, Iran, Email: r.amiri12@gmail.com

² Associate professor of hydrology, Faculty of Geosciences, Shahid Chamran University of Ahvaz, Iran, ORCID: 0000-0001-7470-6784, Email: Yahyamirzaee@scu.ac.ir

³ Professor of hydrogeology, Faculty of Geosciences, Shahid Chamran University of Ahvaz, Iran, ORCID: 0000-0002-8225-7955, Email: M-chitsazan@yahoo.com



10.22125/iwe.2025.555667.1905

Received:
October 26, 2025
Accepted:
February 21, 2026
Available online:
June 25, 2026

Keywords:
WEAP model,
IHACRES model,
ANFIS model, SVM
model, Rainfall-runoff

Abstract

The development of the rainfall–runoff relationship constitutes a fundamental aspect of hydrological modeling. Given the inherent complexity of this relationship, accurate runoff prediction plays a pivotal role in water resources planning and management. This study investigates the rainfall–runoff relationship within the Khorramabad River Basin, employing simultaneous data from the Khorramabad Synoptic Station and the Cham-Anjir Hydrometric Station. Rainfall–runoff modeling was conducted using two conceptual hydrological models WEAP and IHACRES as well as three artificial intelligence (AI) approaches, namely Artificial ANN, ANFIS and SVM, to estimate runoff. The modeling period for all models extended from October 1956 to September 2024, except for the WEAP model, for which the period October 2010 to September 2023 was selected due to the large number of input parameters required. For the AI-based models, 80% of the data were used for training and 20% for testing. The performance of the models was evaluated using standard statistical indicators, including the R^2 , NSE and RMSE. The results indicated that, among the hydrological models, WEAP outperformed IHACRES, and among the AI models, ANFIS exhibited superior performance compared to ANN and SVM. Overall, the ANFIS model demonstrated the best performance among all models employed, with $R^2 = 0.96$, NSE = 0.98, and RMSE = 2.08 during the training phase, and $R^2 = 0.94$, NSE = 0.87, and RMSE = 1.93 during the testing phase. Consequently, the findings suggest that artificial intelligence models generally outperform conceptual hydrological models in simulating the rainfall–runoff process.

1. Introduction

Modeling rainfall–runoff processes play a crucial role in hydrology, particularly in semi-arid regions where water scarcity and hydrological variability pose major challenges for sustainable water management. Accurate runoff prediction supports flood control, water allocation, and watershed planning. Traditionally, conceptual hydrological models such as WEAP and IHACRES have been widely used to simulate rainfall–runoff dynamics (Lotfirad et al. 2019). However, these models are

* **Corresponding Author:** Seyed Yahya Mirzaee

Address: Faculty of Geosciences, Shahid Chamran University of Ahvaz, Iran

Email: Yahyamirzaee@scu.ac.ir

Tel: 09163096940

constrained by assumptions about catchment homogeneity and simplified process representations that limit their ability to capture nonlinear and dynamic hydrological interactions.

Recent developments in data-driven artificial intelligence (AI) techniques—such as Artificial Neural Networks (ANN), Adaptive Neuro-Fuzzy Inference Systems (ANFIS), and Support Vector Machines (SVM)—offer promising alternatives. These methods can model complex nonlinear relationships between rainfall and runoff without explicit physical assumptions. Several studies have demonstrated the superiority of hybrid or AI-based models compared to conceptual approaches, especially in regions with limited or uncertain data (Asadi et al., 2024; Ramzi et al., 2024). This study aims to evaluate and compare the performance of conceptual (WEAP, IHACRES) and AI-based (ANN, ANFIS, SVM) models in simulating rainfall–runoff processes in the Khorramabad River Basin, Iran.

2. Materials and Methods

The study area, the Khorramabad River Basin in western Iran, is a semiarid catchment. Historical hydro-meteorological data, including precipitation, temperature, wind speed, and relative humidity, were collected for the 1989–2023 period. Two conceptual models (WEAP and IHACRES) and three AI-based models (ANN, ANFIS, and SVM) were developed and calibrated.

The WEAP model simulates catchment processes through a soil moisture balance approach, considering land use, evapotranspiration, infiltration, and runoff routing. The IHACRES model transforms effective rainfall into streamflow using linear and nonlinear modules (Croke and Jakeman, 2004). For the AI approaches, monthly rainfall–runoff data were divided into 80% training and 20% testing subsets. The ANN used a MLP structure with Feed-forward backprop learning; the ANFIS model combined fuzzy logic with neural learning; and the SVM applied a RBF-kernel for regression optimization.

Model performance was evaluated using the NSE, R^2 and the RMSE (1, 2 & 3 Eq). Calibration and validation were performed independently for each model to ensure robust assessment of predictive accuracy (Nassery et al. 2021).

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

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

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{n} \quad (3)$$

3. Discussion and Results

The WEAP and IHACRES models provided acceptable hydrological simulations but showed limited ability to reproduce peak discharges and seasonal fluctuations. During calibration, WEAP achieved $NSE = 0.83$ and $R^2 = 0.71$, while IHACRES achieved $NSE = 0.74$ and $R^2 = 0.64$, indicating moderate predictive power. However, validation results revealed performance degradation in both conceptual models, emphasizing their sensitivity to parameter uncertainty and changing hydrological conditions.

In contrast, the AI-based models demonstrated substantially higher accuracy. The ANFIS model yielded the best overall performance with $NSE = 0.96$, $R^2 = 0.98$, and $RMSE = 2.08$ during calibration, followed by the ANN and SVM models with slightly lower but still robust metrics. The superior results of ANFIS highlight the capability of neuro-fuzzy integration to capture nonlinearities and dynamic feedbacks within rainfall–runoff processes, as confirmed by similar findings in other basins. The ANN also performed well in reproducing both high and low flows, while SVM provided stable generalization with minimal overfitting. Compared to WEAP and IHACRES, AI models better captured rainfall–runoff

variability, especially during extreme events. These results align with previous studies reporting that hybrid data-driven models outperform conceptual frameworks in regions with heterogeneous land use and incomplete climatic data. Table 1 shows the values of the performance evaluation criteria of different models and Figure 1 shows the fit of observed and simulated runoff in the training and testing periods of the ANFIS model.

Table1. Performance evaluation criteria values of different models

Modeling period		Hydrological models		AI models		
		WEAP	IHACRES	ANN	ANFIS	SVM
Calibration/Train period	R ²	0.83	0.74	0.79	0.96	0.72
	NSE	0.71	0.64	0.80	0.98	0.73
	RMSE	5.46	7.35	3.08	2.08	2.61
Validation/Test period	R ²	0.65	0.52	0.76	0.94	0.71
	NSE	0.53	0.48	0.83	0.87	0.72
	RMSE	3.82	4.93	4.87	1.93	3.66

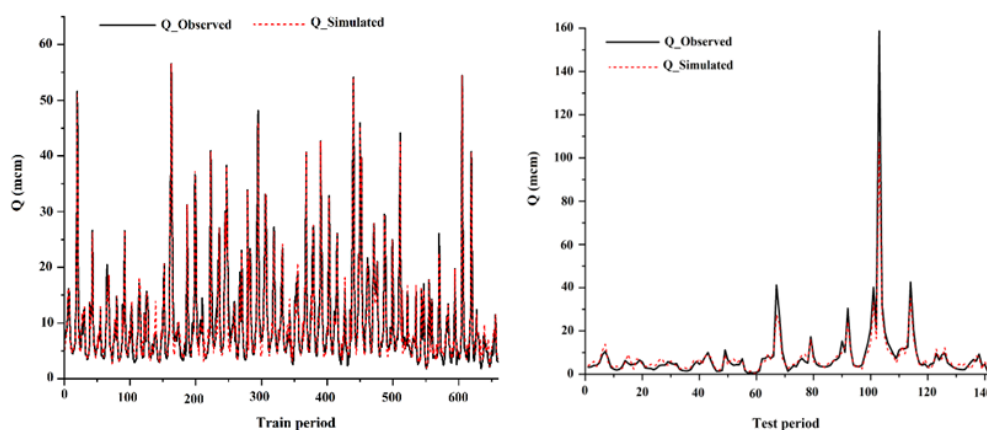


Fig1. Fit of observed and simulated runoff in the training and testing periods for ANFIS model

4. Conclusion

This study confirms that AI-based models, particularly ANFIS, significantly outperform traditional conceptual hydrological models in simulating rainfall–runoff processes for the Khorramabad Basin. The integration of data-driven techniques enables accurate representation of complex nonlinear relationships and temporal variability, which are difficult to capture using physically based methods. While conceptual models like WEAP and IHACRES remain valuable for scenario analysis and water management planning, their predictive capability under nonstationary climatic conditions is limited.

Future research should focus on hybrid frameworks combining the physical interpretability of conceptual models with the adaptive learning capability of AI algorithms. Incorporating remote sensing, multi-source rainfall data fusion, and Bayesian optimization can further enhance model generalization and uncertainty quantification. Overall, the findings emphasize the growing potential of intelligent modeling approaches to improve hydrological prediction and decision-making in data-scarce environments.

5. Six important references

1. Abdi, D.A. and T. Ayenew. 2021. Evaluation of the WEAP model in simulating subbasin hydrology in the Central Rift Valley basin, Ethiopia. *Ecological Processes*. <https://doi.org/10.1186/s13717-021-00305-5>

2. Asadi, S., P. Jimeno-Sáez, A. López-Ballesteros and J. Senent-Aparicio. 2024. Comparison and integration of physical and interpretable AI-driven models for rainfall-runoff simulation. *Results in Engineering*. <https://doi.org/10.1016/j.rineng.2024.103048>
3. Gauch, M., F. Kratzert, O. Gilon, H. Gupta, J. Mai, G. Nearing, B. Tolson, S. Hochreiter and D. Klotz. 2023. In Defense of Metrics: Metrics Sufficiently Encode Typical Human Preferences Regarding Hydrological Model Performance. *Water Resour. Res.* 2023, 59, e2022WR033918. <https://doi.org/10.1029/2022WR033918>
4. Nassery, H. R., N. Zeydalinejad, F. Alijani and A. Shakiba. 2021. A proposed modelling towards the potential impacts of climate change on a semi-arid, small-scaled aquifer: a case study of Iran. *Environ Monit Assess* (2021) 193:182. <https://doi.org/10.1007/s10661-021-08955-w>.
5. Ramzi, Kh., M. Nadir, B.M. Tewfik and D.Kh. Hakim. 2024. Hydrological Forecasts Modeling Using Artificial Intelligence and Conceptual Models of KébirRhumel Watershed, Algeria. *Ecological Engineering & Environmental Technology* 2024, 25(9), 68–80. <https://doi.org/10.12912/27197050/190235>
6. Yu, H. and Q. Yang. 2024. Applying Machine Learning Methods to Improve Rainfall–Runoff Modeling in Subtropical River Basins. *Water* 2024, 16, 2199. <https://doi.org/10.3390/w16152199>

Conflict of Interest

Authors declared no conflict of interest.

Acknowledgments

We are grateful to the Lorestan Regional Water Company for their cooperation in providing the data required for this study.

مقایسه‌ی عملکرد مدل‌های یادگیری ماشین و مدل‌های مفهومی هیدرولوژیکی در شبیه‌سازی بارش-رواناب (مطالعه‌ی موردی: حوضه‌ی آبریز رودخانه‌ی خرم‌آباد)

رقیه امیری^۱، سید یحیی میرزایی^۲، منوچهر چیت‌سازان^۳

تاریخ ارسال: ۱۴۰۴/۰۸/۰۴

تاریخ پذیرش: ۱۴۰۴/۱۲/۰۲

مقاله پژوهشی

چکیده

توسعه‌ی رابطه‌ی بارش-رواناب یک موضوع اساسی در مدل‌سازی هیدرولوژیکی است. با توجه به پیچیدگی رابطه‌ی بارش-رواناب، پیش‌بینی رواناب نقش اساسی در برنامه‌ریزی و مدیریت منابع آب ایفا می‌کند. این مطالعه رابطه‌ی بارش-رواناب در حوضه‌ی آبریز رودخانه‌ی خرم‌آباد را با استفاده از داده‌های ایستگاه‌های سینوپتیک خرم‌آباد و هیدرومتری چمن‌انجیر هم‌زمان مدل‌سازی می‌کند. در این مطالعه مدل‌سازی بارش-رواناب با استفاده از مدل‌های مفهومی هیدرولوژیکی WEAP و IHACRES و مدل‌های یادگیری ماشین ANN، ANFIS و SVM برای تخمین رواناب انجام شد. دوره‌ی مدل‌سازی برای همه‌ی مدل‌ها از مهر ۱۳۳۵ تا شهریور ۱۴۰۳ در نظر گرفته شد و تنها در مدل WEAP به دلیل تعداد زیاد پارامترهای ورودی دوره‌ی آماری مهر ۱۳۸۹ تا شهریور ۱۴۰۲ انتخاب شد. در مورد مدل‌های هوش مصنوعی ۸۰ درصد داده‌ها برای دوره‌ی آموزش و ۲۰ درصد آن‌ها برای دوره‌ی آزمایش انتخاب شدند. برای ارزیابی دقت پیش‌بینی مدل‌ها نیز از معیارهای ارزیابی عملکرد مدل شامل R^2 ، NSE و RMSE استفاده شد. بر این اساس از بین مدل‌های هیدرولوژیکی، مدل WEAP نسبت به مدل IHACRES و از بین مدل‌های یادگیری ماشین، مدل ANFIS نسبت به مدل‌های ANN و SVM عملکرد بهتری از خود نشان دادند. بر اساس نتایج به‌دست آمده در مجموع از بین همه‌ی مدل‌های مورد استفاده مدل ANFIS با $R^2=0/96$ ، $NSE=0/98$ و $RMSE=2/08$ در دوره‌ی آموزش و $R^2=0/94$ ، $NSE=0/87$ و $RMSE=1/93$ در دوره‌ی آزمایش عملکرد بهتری نسبت به سایر مدل‌ها از خود نشان داد. بر این اساس به‌طور کلی می‌توان گفت مدل‌های یادگیری ماشین در مقایسه با مدل‌های هیدرولوژیکی عملکرد بهتری در شبیه‌سازی بارش-رواناب از خود نشان دادند.

واژه‌های کلیدی: مدل WEAP، مدل IHACRES، مدل ANFIS، مدل SVM، بارش-رواناب

۱- دکتری هیدروژئولوژی، دانشکده علوم زمین، دانشگاه شهید چمران اهواز، ایران. r.amiri172@gmail.com

۲- دانشیار هیدرولوژی، عضو هیات علمی دانشکده علوم زمین دانشگاه شهید چمران اهواز، ایران، Yahyamirzee@scu.ac.ir (نویسنده مسئول)، ۰۹۱۶۳۰۹۶۹۴۰

۳- استاد هیدروژئولوژی، عضو هیات علمی دانشکده علوم زمین دانشگاه شهید چمران اهواز، ایران، M-chitsazan@yahoo.com

مقدمه

مدل‌سازی بارش-رواناب نقشی حیاتی در زمینه‌ی هیدرولوژی برای مدیریت بلاهای سیل و برای کمی‌سازی آب موجود برای مصارف آشامیدنی، کشاورزی و برنامه‌ریزی نیروگاه‌های آبی ایفا می‌کند. در دهه‌های اخیر، به دلیل کمبود آب در دسترس پیش‌بینی دقیق رواناب برای هیدرولوژیست‌ها به منظور حفظ منابع آب موجود به موضوعی حیاتی تبدیل شده است (Wen et al. 2019). علاوه بر عوامل اقلیمی، تأثیر پارامترهای خاص حوضه (توپوگرافی، شکل، شیب، ارتفاع، نوع خاک، پوشش زمین، ظرفیت نگهداری رطوبت) بر رواناب، آن را در طبیعت پیچیده‌تر و به فرآیندی غیرخطی تبدیل می‌کند (Niu et al. 2014; Feng et al. 2020; Abera Abdi and Ayenew, 2021). مدل‌سازی بارش-رواناب به دلیل تأثیر عوامل آب و هوایی متعدد مانند دمای هوا، بارش، سرعت باد، بسته‌ی برف، تابش خورشیدی و رطوبت، یک کار چالش برانگیز است.

در این زمینه، دو رویکرد اصلی برای مدل‌سازی فرآیندهای هیدرولوژیکی وجود دارد: مدل‌های مبتنی بر فیزیک و مدل‌های هوش مصنوعی (AI) (Mohammadi et al. 2020a, b, c; Nourani et al. 2021a, 2021b; Gichamo et al. 2024). سال‌های اخیر، مدل‌های یادگیری ماشین به‌طور گسترده و مؤثر برای پیش‌بینی پارامترهای هیدرولوژیکی و هواشناسی به کار گرفته شده‌اند. این مدل‌ها قادرند بدون نیاز به درک مستقیم فرآیندهای فیزیکی، پارامترهای مورد نظر را بر اساس مجموعه‌ای از داده‌های ورودی تخمین بزنند (Mohammadi et al. 2020a, b, c). با این حال، برخی محققان نگرانی‌هایی را در مورد کاربرد روش‌های یادگیری ماشین در زمینه هیدرولوژی مطرح کردند، زیرا این روش‌ها قابلیت تفسیر و سازگاری فیزیکی محدودی دارند، که به‌طور بالقوه منجر به شبیه‌سازی‌های فیزیکی نادرست یا غیرمنطقی می‌شوند، به‌ویژه زمانی که داده‌های آموزشی کیفیت پایینی دارند (Reichstein

et al. 2019)، برون‌یابی به‌ویژه برای رویدادهای شدید خارج از محدوده‌ی آموزش چالش برانگیز است، سازگاری با کاربری زمین یا شرایط هیدرولوژیکی جدید زمانی که تغییرات از داده‌های آموزشی مشاهده شده فراتر رود دشوار است همچنین قابلیت انتقال محدود است زیرا ممکن است در مناطق ناآشنا عملکرد خوبی نداشته باشند در حالی که مدل‌های مبتنی بر فیزیک می‌توانند از طریق تنظیمات پارامتر سازگار شوند (Huang and Tun Lee, 2025). این مدل‌ها با شبیه‌سازی روابط و برهم‌کنش‌های میان متغیرهای مؤثر، رفتار چرخه‌ی هیدرولوژیکی را در سری‌های زمانی بازسازی می‌کنند (Fang et al. 2019; Wang et al. 2016).

مدل‌های فیزیکی بسته به میزان جزئیات مکانی و نیاز به داده‌های ورودی، به دو گروه توزیعی و نیمه‌توزیعی تقسیم می‌شوند. مدل‌های توزیعی با در نظر گرفتن تغییرات مکانی داده‌ها، دقت بالاتری در شبیه‌سازی فرآیند بارش-رواناب دارند، اما به حجم زیادی از داده‌های ورودی نیازمندند (Gebre, 2015). از جمله مدل‌های توزیعی می‌توان به مدل‌های VIC، SHETRAN و LISFLOOD اشاره کرد. در مقابل، مدل‌های نیمه‌توزیعی با تقسیم حوضه به زیرحوضه‌های کوچک‌تر، از پیچیدگی و نیاز داده‌ای کمتری برخوردارند (Orellana et al. 2008). از جمله مدل‌های نیمه‌توزیعی پرکاربرد می‌توان به مدل رطوبت خاک ساکرامنتو (SAC-SMA)، ابزار ارزیابی خاک و آب (SWAT)، مدل مدیریت آب طوفانی (SWMM) و مدل ارزیابی و برنامه‌ریزی آب (WEAP) اشاره کرد. نرم‌افزار WEAP که توسط مؤسسه محیط زیست استکهلم (SEI) توسعه یافته، به‌عنوان ابزاری کارآمد برای شبیه‌سازی فرآیندهای طبیعی بارش-رواناب و مدیریت جامع منابع آب شناخته می‌شود (Yates et al. 2005).

در سال‌های اخیر، مدل‌های هوش مصنوعی به‌عنوان زیرمجموعه‌ای از مدل‌های داده‌محور، محبوبیت قابل توجهی در مطالعات هیدرولوژیکی یافته‌اند. این

نشان داد که هر هشت مدل به طور کلی عملکرد قابل قبولی در مدل‌سازی فرآیند بارش-رواناب در حوضه رودخانه‌ی پداواگو نشان می‌دهند. با این وجود مدل LSTM عملکرد بسیار بهتری را در شبیه‌سازی بارش-رواناب در طول دوره‌های کالیبراسیون و اعتبارسنجی نسبت به سایر مدل‌ها نشان داد. فرودی صفات و همکاران (۱۴۰۰)، دو مدل تلفیقی هیدرولوژیکی (WEAP)-جعبه سیاه (ANN و GMDH) را برای پیش‌بینی سیلاب در حوضه‌ی آبریز هلیل‌رود مورد مطالعه قرار دادند. نتایج نشان داد مدل تلفیقی WEAP-ANN عملکرد بهتری در تخمین رواناب نسبت به مدل‌های WEAP و WEAP-GMDH دارد. مؤمنه (۱۴۰۱)، در مطالعه‌ای به مقایسه‌ی عملکرد مدل‌های هوش مصنوعی (ANN، RBF و LSTM) با مدل IHACRES در مدل‌سازی جریان حوضه‌ی آبریز رودخانه‌ی گاماسیاب پرداختند. نتایج نشان دهنده‌ی عملکرد بهتر مدل‌های ANN، RBF و LSTM به ویژه در نقاط اوج جریان نسبت به مدل IHACRES در مدل‌سازی جریان در منطقه‌ی مورد مطالعه است. در کل نتایج نشان داد که مدل‌های AI ابزار مفیدی برای مدل‌سازی نوسانات جریان هستند.

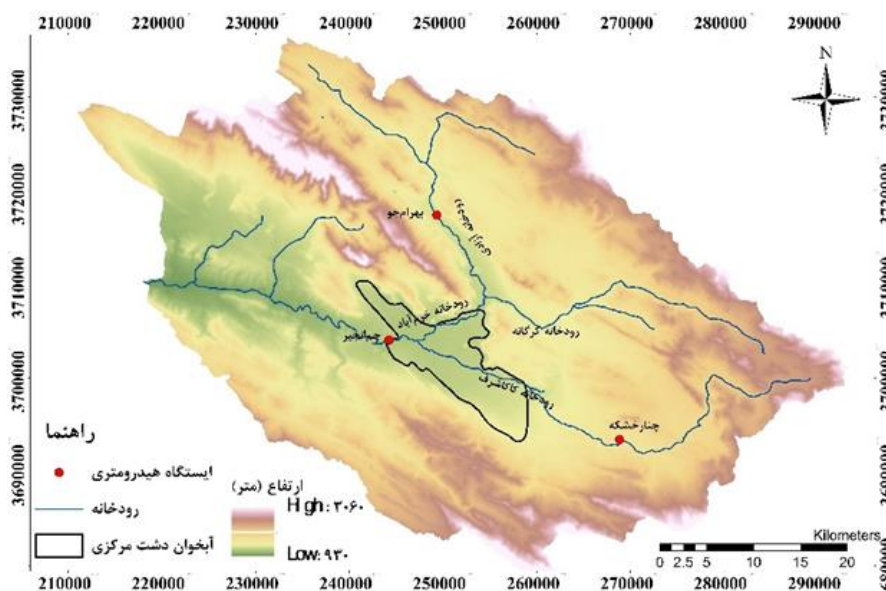
هدف اصلی این مطالعه مدل‌سازی فرآیند بارش-رواناب با بهره‌گیری از مدل‌های هیدرولوژیکی و الگوریتم‌های هوش مصنوعی مختلف و مقایسه‌ی عملکرد آن‌ها است. در این راستا تلاش شده است بهینه‌ترین مدل در شبیه‌سازی و پیش‌بینی رفتار بارش-رواناب انتخاب شود تا مبنایی علمی برای پیش‌بینی‌های آینده فراهم آید. اهمیت این مطالعه در آن است که برای نخستین بار، کارایی مدل‌های مذکور در حوضه‌ی آبریز خرم‌آباد به صورت هم‌زمان و مقایسه‌ای مورد ارزیابی قرار می‌گیرد، که می‌تواند گام مهمی در جهت ارتقای دقت مدل‌سازی‌های هیدرولوژیکی در منطقه‌ی مورد مطالعه و سایر مناطق مشابه باشد.

مدل‌ها به دلیل انعطاف‌پذیری و توانایی شبیه‌سازی رواناب بدون نیاز به درک گسترده‌ی فرآیندهای فیزیکی، برای شبیه‌سازی تعاملات غیرخطی و پیچیده میان متغیرهای هواشناسی و فرآیندهای هیدرولوژیکی مناسب هستند (Yu and Yang, 2024; Gauch et al. 2021; Nearing et al. 2023). با این حال، محدودیت‌هایی در تفسیرپذیری و سازگاری فیزیکی این مدل‌ها وجود دارد که ممکن است در صورت داده‌های آموزشی ناکافی به نتایج غیرمنطقی منجر شود (Reichstein et al 2019). مطالعات موردی نشان داده‌اند که مدل‌های شبکه عصبی معمولاً عملکرد بهتری نسبت به مدل‌های مفهومی سنتی دارند. Ramzi et al. 2024 در مطالعه‌ای رابطه بارش-رواناب در حوضه‌ی آبخیز رودخانه‌ی کبیر-رومل در ارتفاعات کنستانتین، الجزایر را با استفاده از چهار مدل مفهومی (GR4J، IHAC6، MORDOR، TOPMO8) و مدل‌های شبکه عصبی (RNN، NARX، LSTM) در دوره‌های سه و ده ساله مدل‌سازی کردند. نتایج این مطالعه نشان داد که مدل‌های شبکه عصبی، به ویژه RNN-LSTM و NARX-RNN دقت پیش‌بینی بالاتری را در مقایسه با مدل‌های مفهومی سنتی و شبکه‌های عصبی مستقل ارائه می‌دهند. Asadi et al. 2024 به مقایسه و ادغام مدل‌های فیزیکی و قابل تفسیر مبتنی بر هوش مصنوعی برای شبیه‌سازی بارش-رواناب حوضه‌ی رودخانه‌ی تاگوس در اسپانیا پرداختند. ایشان در مطالعه‌ی خود از مدل‌های SWAT، SVR، FFNN و LSTM در شبیه‌سازی فرآیند بارش-رواناب استفاده کردند. نتایج این مطالعه نشان داد که مدل‌های شبکه عصبی، به ویژه RNN-LSTM و NARX-RNN، دقت پیش‌بینی بالاتری را در مقایسه با مدل‌های مفهومی سنتی و شبکه‌های عصبی مستقل ارائه می‌دهند. Shekar et al 2023 عملکرد مدل‌های SWAT و هوش مصنوعی (ANN، KNN، SVM، RF، MLR، XGBoost و LSTM) را برای تحلیل ماهانه‌ی بارش-رواناب در حوضه‌ی رودخانه پداواگو در هند با هم مقایسه کردند. یافته‌های مطالعه‌ی آن‌ها

منطقه‌ی مورد مطالعه

حوضه‌ی آبریز خرم‌آباد بخشی از حوضه‌ی رودخانه‌ی دائمی خرم‌آباد است که یکی از زیرحوضه‌های رودخانه‌ی کرخه می‌باشد. این حوضه شامل یک دشت اصلی (دشت مرکزی) و تعدادی دشت کوچک از جمله دشت ده‌پیر، کمالوند و خرم‌آباد است. طول آبراهه‌ی اصلی رودخانه‌ی خرم‌آباد ۷۳/۳ کیلومتر است که پس از عبور از داخل شهر و دشت جنوبی، سرشاخه‌های

فرعی کاکاشرف و سراب چنگایی در بخش جنوبی به آن ملحق شده و تا محل ایستگاه دوآب ویسیان زیرحوضه‌ی خرم‌آباد را به‌وجود می‌آورند. متوسط بارش سالانه‌ی محدوده‌ی مطالعاتی خرم‌آباد با توجه به آمار به‌دست آمده از ایستگاه سینوپتیک خرم‌آباد ۵۰۸ میلی‌متر و متوسط دمای آن ۱۷/۲ درجه‌ی سانتی‌گراد است (آمار ۵۰ ساله، ۱۴۰۲-۱۳۵۳). متوسط ارتفاع منطقه ۱۹۰۳ متر و مساحت محدوده‌ی حوضه‌ی آبریز ۲۵۰۳ کیلومترمربع می‌باشد (Mirzaee et al. 2023).



شکل (۱): موقعیت منطقه مورد مطالعه

مواد و روش‌ها

به منظور انجام این مطالعه ابتدا مقادیر پارامترهای مورد نیاز اقلیمی (بارش و دماهای حداقل، میانگین و حداکثر) برای ایستگاه سینوپتیک خرم‌آباد از سازمان هواشناسی کشور و مقادیر دبی ماهانه‌ی جریان رودخانه‌ی خرم‌آباد نیز برای ایستگاه هیدرومتری چمانجیر از شرکت آب منطقه‌ای لرستان به‌دست آمد. پس از جمع‌آوری داده‌ها، فرآیند آماده‌سازی و اصلاح آن‌ها به‌منظور انجام تحلیل‌های اقلیمی انجام شد. بدین ترتیب، ابتدا همگنی و تصادفی بودن داده‌ها با استفاده از آزمون آماری Run Test مورد ارزیابی قرار گرفت. سپس داده‌های ناقص با بهره‌گیری از روش‌های

تفاضل‌ها و نسبت‌ها بازسازی شد و نواقص موجود رفع شد. کلیه‌ی پردازش‌های مربوط به این مرحله در محیط نرم‌افزارهای EXCEL و SPSS در مقیاس زمانی ماهانه صورت پذیرفت.

مدل WEAP

مدل WEAP توسط مؤسسه‌ی محیط زیست استکهلم (SEI) توسعه یافته و به‌عنوان ابزاری حیاتی برای شبیه‌سازی منابع آب و مدیریت تقاضا مورد استفاده قرار می‌گیرد. این مدل با اولویت‌بندی عرضه و تقاضا، رویکرد بهینه‌ی توزیع آب را ارائه می‌کند و بر اساس بیلان آب طراحی شده است. داده‌های مورد نیاز شامل کاربری اراضی، نوع خاک، منابع تأمین آب

تبخیر و تعرق واقعی (ET) نیز با استفاده از ET مرجع، ضریب محصول (Kc) و سطح آب خاک در منطقه‌ی ریشه‌ی واحد مدل‌سازی که توسط رابطه‌ی (۲) داده شده است، تخمین زده می‌شود.

$$ET = ET_0 \times K_c (5Z_1 - 2Z_1^2) / 3 \quad (2)$$

معمولاً در تخمین ET₀ از داده‌های تاریخی اقلیمی مانند تابش خورشیدی، دمای هوا، رطوبت و سرعت باد در بالای سطح وسیعی از چمن سبز، سایه‌اندازی روی زمین و کمبود آب استفاده می‌کنند (Allen et al., 1998). از جمله روش‌های محاسبه ET₀ روش پنمن-مانتیت است که به صورت زیر بیان می‌شود:

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (3)$$

که در آن، ET₀ تبخیر و تعرق مرجع (mm/day)، R_n تشعشع خالص در سطح محصول (MJ/m²day)، G چگالی شار حرارتی خاک (MJ/m²day)، T میانگین دمای هوای روزانه در ارتفاع ۲ متری (°C)، u₂ سرعت باد در ارتفاع ۲ متری (m/s)، e_s فشار بخار اشباع است (kPa)، e_s - e_a کسری فشار بخار اشباع (kPa)، Δ شیب منحنی فشار بخار (kPa/°C) و γ ثابت سایکرومتریک (kPa/°C) است.

واسنجی و اعتبارسنجی مدل WEAP

هدف از واسنجی مدل (تخمین پارامتر)، به‌دست آوردن مجموعه‌ای از پارامترهای قابل قبول برای زیرحوضه است تا شرایط هیدرولوژیکی سازگار با محیط واقعی رودخانه در ایستگاه اندازه‌گیری شبیه‌سازی شود. واسنجی می‌تواند به‌صورت خودکار یا دستی انجام شود و در طی آن پارامترهای مدل برای حداقل کردن اختلاف بین مقادیر مشاهده‌شده و شبیه‌سازی‌شده تنظیم می‌شوند. در این مطالعه، از رویکرد دستی (آزمون و خطا) برای تطبیق داده‌های جریان شبیه‌سازی‌شده و اندازه‌گیری‌شده استفاده شد.

روش رطوبت خاک WEAP شامل هفت پارامتر مرتبط با خاک و کاربری اراضی است که برای واسنجی مدل هیدرولوژیکی استفاده می‌شوند (Sieber and Purkey 2015). این پارامترها شامل ضریب محصول (Kc)، ظرفیت آب خاک (Sw)، ظرفیت آب عمیق

(رودخانه‌ها، نهرها، آب‌های زیرزمینی و مخازن)، کیفیت آب، نیازهای آبی (کشاورزی، خانگی، دامی و صنعتی) و ارزیابی‌های اقتصادی هستند. فرآیند توسعه‌ی مدل WEAP شامل تعیین مرزهای منطقه و مقیاس زمانی، شناسایی عناصر سیستم (سایت‌های عرضه و تقاضا، مخازن و غیره) و اتصال آن‌ها از طریق لینک‌های انتقال یا انحراف است. مدل می‌تواند فرآیندهای حوضه را به صورت روزانه یا ماهانه شبیه‌سازی کند. در این مطالعه، به دلیل خصوصیات منطقه و داده‌های موجود، از روش رطوبت خاک برای شبیه‌سازی هیدرولوژیکی حوضه‌ی آبریز رودخانه‌ی خرم‌آباد استفاده شد (Abdi and Ayenew, 2021).

در روش رطوبت خاک، WEAP سیستم دینامیکی یک‌بعدی دو لایه‌ی رطوبت خاک را در نظر می‌گیرد و با استفاده از توابع تجربی، آب را به تبخیر تعرق، رواناب سطحی، رواناب زیرسطحی (جریان میانی) و نفوذ عمیق تقسیم می‌کند. داده‌های اقلیمی شامل بارش، دما، رطوبت نسبی و سرعت باد برای هر زیرحوضه اختصاص داده شده‌اند. با ایجاد پیوند بین زیرحوضه و گره آب زیرزمینی، نفوذ می‌تواند به جریان پایه یا ذخیره‌ی آب زیرزمینی منتقل شود و در نهایت بیلان آب محاسبه می‌شود (SEI, 2007):

$$Rd_j \frac{dz_{1,j}}{dt} = P_e(t) - ET_0(t)K_{c,j}(t) \left(\frac{5Z_{1,j} - 2Z_{1,j}^2}{3} \right) - P_e(t)Z_{1,j}^{RRFj} - f_j k_{s,j} Z_{1,j}^2 - (1 - f_j) K_{s,j} Z_{1,j}^2 \quad (1)$$

در رابطه‌ی بالا $Z_{1,j} \in [0,1]$ ذخیره‌ی نسبی آب خاک و بدون بعد است، j کاربری اراضی، Rd_j ظرفیت نگهداشت آب خاک مؤثر (mm). P_e بارش مؤثر (mm)، $ET_0(t)$ تبخیر و تعرق مرجع (mm/day)، $K_{c,j}$ ضریب زراعی کاربری اراضی j ، RRF_j ضریب مقاومت رواناب کاربری و پوشش اراضی j ، $P_e(t)Z_{1,j}^{RRFj}$ رواناب سطحی، $f_j k_{s,j} Z_{1,j}^2$ جریان بین لایه‌ی اول کاربری اراضی j ، f_j ضریب تقسیم مربوط به نوع پوشش زمین، خاک و توپوگرافی برای منطقه‌ی j که جریان را به جریان‌های افقی f_j و عمودی $(1 - f_j)$ تقسیم می‌کند و K_s هدایت هیدرولیکی اشباع لایه‌ی ناحیه‌ی ریشه‌ی کاربری اراضی j (mm/time) است.

پارامتر زمانی برای کاهش s_k است. t_k دمای مشاهده شده در زمان k بر حسب درجه‌ی سانتی‌گراد و f پارامتری برای مدولاسیون دما است. ماژول خطی IHACRES برای یک حوضه، ترکیبی از دو جزء موازی یکی برای جریان سریع ($xk(q)$) و دیگری برای جریان آهسته ($xk(s)$) است (Kim, 2015). بنابراین، جریان در زمان k را می‌توان به صورت زیر نوشت:

$$q_k = x_k^{(q)} + x_k^{(s)} \quad (۶)$$

$$x_k^{(q)} = \exp\left(\frac{-\Delta}{\tau_q}\right) x_{k-1}^{(q)} + v_q \left[1 - \exp\left(\frac{-\Delta}{\tau_q}\right)\right] u_k \quad (۷)$$

$$x_k^{(s)} = \exp\left(\frac{-\Delta}{\tau_s}\right) x_{k-1}^{(s)} + v_s \left[1 - \exp\left(\frac{-\Delta}{\tau_s}\right)\right] u_k \quad (۸)$$

در روابط بالا Δ گام زمانی است. τ_q و τ_s به ترتیب ثابت‌های زمان فروپاشی برای جریان‌های سریع و آهسته و v_q و v_s به ترتیب، گذردهی حجمی نسبی برای اجزای سریع و آهسته جریان هستند.

مدل شبکه‌ی عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی شامل گره‌های محاسباتی متصل به یکدیگر هستند که در لایه‌های ورودی، پنهان و خروجی سازمان‌دهی شده‌اند و از سیستم عصبی بیولوژیکی الهام گرفته شده‌اند. در طول مدل‌سازی ANN، پارامترهای مهم شامل تعداد نورون‌ها در هر لایه، تعداد لایه‌ها، تعداد دوره‌های آموزشی، قوانین آموزش و توابع انتقال است (Elbeltagi et al., 2020a; Seo et al., 2015).

هیچ قانون دقیقی برای تعیین ساختار بهینه‌ی ANN وجود ندارد و معمولاً این ساختار با استفاده از روش آزمون و خطا انتخاب می‌شود (Lee et al. 2008). مطالعات نشان داده‌اند که شبکه‌های عصبی با یک لایه‌ی پنهان قادر به تقریب دقیق بسیاری از توابع غیرخطی محدود هستند (Kim and Gilley, 2008). انتخاب معماری مناسب شامل طراحی ساختار، آموزش و آزمایش شبکه است (Lohani et al. 2012).

گره‌ها (نورون‌ها) از طریق پیوندهای وزن‌دار به هم متصل هستند و تعداد نورون‌ها و لایه‌های پنهان بر اساس آزمون و خطا تعیین می‌شود. در کاربردهای هیدرولوژیکی، شبکه‌های پرسپترون چندلایه (MLP) و شبکه‌های با تابع پایه‌ی شعاعی (RBF) بیشترین

(Dw)، ضریب مقاومت رواناب (RRF)، هدایت هیدرولیکی ناحیه‌ی ریشه (Ks)، هدایت هیدرولیکی منطقه‌ی عمیق (Kd)، جهت جریان ترجیحی (f)، کسر ذخیره‌ی اولیه در ابتدای شبیه‌سازی لایه‌ی بالایی خاک (Z_1) و کسر ذخیره‌ی اولیه در ابتدای شبیه‌سازی لایه‌ی پایینی خاک (Z_2) است. اهمیت اصلی اجرای مدل‌های هیدرولوژیکی، شبیه‌سازی شرایط واقعی زیرحوضه است. همچنین، فرآیند اعتبارسنجی مدل برای ارزیابی قابلیت شبیه‌سازی پاسخ هیدرولوژیکی زیرحوضه در شرایط مشابه دوره‌ی واسنجی ضروری است (Legesse et al. 2003).

مدل IHACRES

IHACRES یک مدل یکپارچه‌ی مفهومی برای شبیه‌سازی بارش-رواناب است که برای اولین بار توسط جیکمن و همکاران توسعه یافت (Lotfirad et al., 2019؛ احمدی و همکاران، ۱۳۹۹). این مدل جهت شبیه‌سازی رفتار هیدرولوژیکی حوضه به داده‌های کمی نیاز دارد. مدل IHACRES شامل دو ماژول خطی و غیر خطی است (زارعی و همکاران، ۱۳۸۸). ماژول غیر خطی بارندگی مشاهده شده را به بارندگی اضافی تبدیل می‌کند سپس ماژول خطی بارندگی اضافی تخمینی را به دبی رودخانه تبدیل می‌کند. ماژول اول یک مدل مفهومی یکپارچه است در حالی که ماژول دوم اساساً یک روش داده محور است (Jakeman and Hornberger, 1993; Croke and Jakeman, 2004; Lotfirad et al. 2019). در IHACRES، بارندگی اضافی، u_k ، با استفاده از رابطه‌ی زیر محاسبه می‌شود (Hansen et al. 1996):

$$u_k = \begin{cases} s_k^p r_k & r_k > l \\ 0 & r_k \leq l \end{cases} \quad (۴)$$

در رابطه‌ی بالا r_k میزان بارندگی مشاهده شده در زمان k ، p پارامتر تلفات نمایی، l مقدار آستانه‌ی جریان برای بارش و s_k یک شاخص رطوبتی است که به صورت زیر تعریف می‌شود:

$$s_k = \frac{r_k}{c} + \left[1 - \frac{1}{\tau_w \exp[(20-t_k)f]}\right] s_{k-1} \quad (۵)$$

که در آن c یک پارامتر پاسخ است که برای اطمینان از حفظ تعادل جرم حوضه انتخاب شده است. τ_w یک

به ترتیب). p_i ، q_i و r_i پارامترهای طراحی (پارامترهای تابع خروجی / پارامترهای متعاقب) هستند که در طول فرآیند آموزش تخمین زده می‌شوند. خروجی به دست آمده در هر قانون ترکیب خطی متغیرهای ورودی به اضافه‌ی یک جمله ثابت است.

در این مطالعه FIS مبتنی بر شبکه‌بندی تفریقی با بهینه‌سازی یادگیری ترکیبی برای توسعه‌ی مدل‌های مختلف پیش‌بینی رواناب ماهانه در نرم‌افزار MATLAB2018 استفاده شد.

مدل ماشین بردار پشتیبان (SVM)

SVM یک الگوریتم مبتنی بر نظریه‌ی یادگیری ماشین است. SVM ساختار از پیش تعیین شده‌ای ندارد، در حالی که نمونه‌های آموزشی براساس مشارکت آن‌ها مورد قضاوت قرار می‌گیرند. فقط نمونه‌های انتخاب شده به مدل نهایی کمک می‌کنند که به اصطلاح «بردارهای پشتیبانی» هستند. تابع هدف SVM را می‌توان به صورت زیر بیان کرد:

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (13)$$

$$\begin{cases} (\omega\phi(x_i) + b) - y_i \leq \varepsilon + \xi_i \\ y_i - (\omega\phi(x_i) + b) \leq \varepsilon + \xi_i^* \end{cases} \quad (14)$$

جایی که ω نشان‌دهنده‌ی بردار جهت، C نشان‌دهنده‌ی ضریب تعدیل، ξ_i و ξ_i^* متغیرهای کمکی هستند، $\phi(x_i)$ نشان‌دهنده‌ی نگاشت بردار ورودی x_i به فضای با ابعاد فوق‌العاده بالا، b مقطع تابع رگرسیون و ε ضریب فاقد حساسیت است. بخش اول تابع هدف نشان‌دهنده‌ی پیچیدگی مدل است در حالی که قسمت دوم نشان‌دهنده‌ی خطای برازش است. در تئوری SVM، مدل زمانی به بهترین عملکرد می‌رسد که مجموع به حداقل برسد. مدل‌های SVM به دنبال بهینه‌ی هم‌زمان عملکرد تعمیم مدل و عملکرد برازش هستند.

مدل SVM یک مسأله‌ی برنامه‌نویسی درجه‌ی دوم با ابعاد بالا است. برای جلوگیری از فاجعه‌ی بعدی، یک تابع هسته برای تبدیل محاسبات با ابعاد بالا به محاسبات با ابعاد کم معرفی شده است. توابع هسته‌ی عمومی شامل تابع پایه‌ی خطی، شعاعی (RBF)،

استفاده را دارند، که MLP رایج‌تر است (Anusree and Varghese, 2016; Kisi, 2015). مجموع خالص (n) تعیین شده در هر گره به صورت زیر داده می‌شود:

$$n = \sum_{j=1}^n (W_{ij}X_i + b_i) \quad (9)$$

W_{ij} وزن اتصال بین دو لایه‌ی مربوط به متغیر ورودی X_i و b_i است. خروجی (y) در هر گره به صورت زیر تعیین می‌شود:

$$n = f_i(\sum_{j=1}^n (W_{ij}X_i + b_i)) \quad (10)$$

که در آن f_i تابع فعال سازی/انتقال است.

در این مطالعه از شبکه‌های عصبی مصنوعی پرسپترون چند لایه (MLP) که از یک لایه‌ی ورودی، یک لایه‌ی خروجی و یک یا چند لایه‌ی پنهان تشکیل شده است، تابع سیگموئیدی شامل توابع فعال‌سازی لجستیک و مماسی در لایه‌ی پنهان و تابع فعال‌سازی خطی در لایه‌ی خروجی و همچنین الگوریتم‌های آموزش پس‌انتشار پیش‌خور (Feed-forward backprop) و آموزش لونیبرگ-مارکوارت (Levenberg-Marquardt) استفاده شده است.

سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)

ساختار ANFIS از گره‌های زیادی تشکیل شده است که از طریق لینک‌های جهت‌دار به هم متصل می‌شوند. هر گره عملکرد خاصی را با پارامترهای ثابت یا قابل تنظیم خود انجام می‌دهد (Kisi, 2015). سیستم فازی Takagi-Sugeno یک سیستم فازی ضروری است. قوانین If-Then را در پلتفرم قانون خود ذخیره می‌کند. Takagi-Sugeno دقیق‌ترین و پرکاربردترین FIS در مدل‌سازی فازی است (Seo et al. 2015). برای سیستم واسط فازی Takagi-Sugeno مرتبه‌ی اول با دو ورودی (x و y) و یک خروجی (f)، با در نظر گرفتن دو قانون فازی If-Then در پایه‌ی قانون، دو قانون معمولی را می‌توان به صورت زیر بیان کرد:

Rule1:

$$\text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1, \text{ then } f_1 = p_1x + q_1y + r_1 \quad (11)$$

Rule2:

$$\text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2, \text{ then } f_2 = p_2x + q_2y + r_2 \quad (12)$$

در روابط بالا A_i و B_i مجموعه‌های فازی هستند (توابع عضویت (MFs) برای ورودی‌های x و y).

$$k(x, x_i) = e^{-g||x-x_i||^2} \quad (15)$$

که در آن پارامتر g برای برازش توزیع‌های نمونه‌های مختلف استفاده می‌شود.

در جدول (۱) پارامترهای مورد استفاده در این مطالعه برای مدل‌های مختلف ارائه شده است.

گاوسی، چند جمله‌ای و سایر توابع هسته است. در میان این توابع، هسته RBF نسبت به هسته‌ی خطی هنگام برخورد با نمونه‌های پیچیده با ابعاد بالا برتر است. در مقایسه با توابع هسته‌ی گاوسی و چند جمله‌ای، پارامتر تابع هسته RBF ساده است. بنابراین هسته‌ی RBF اغلب برای حل مدل SVM انتخاب می‌شود که به صورت زیر بیان می‌شود:

جدول (۱): پارامترهای مورد استفاده در مدل‌های مختلف

مدل	پارامتر	منبع
WEAP	SWC, DWC, RZC, DC, RRF, PFD, Initial Z1, Initial Z2	Abdin et al. 2021
IHACRES	τ_w, C, f	Karami et al. 2022
ANN	Network Type, Training Functions, Adoption Learning Function, Performance Function, Transfer Function, No. of neurons used for hidden layer	Mishra et al. 2018
ANFIS	$a_i, b_i, c_i, p_i, q_i^*, r_i$	Islam et al. 2018
SVM	ϵ, C, γ	Ghorbani et al. 2016

بحث و نتایج

مدل‌سازی بارش-رواناب در WEAP

به منظور شبیه‌سازی بارش-رواناب با استفاده از مدل WEAP از روش رطوبت خاک استفاده شده است. در این مطالعه دوره‌ی مدل‌سازی از مهر ۱۳۸۹ تا شهریور ۱۴۰۲ در نظر گرفته شد. همچنین داده‌های رواناب به عنوان خروجی و حداقل و حداکثر دما، بارندگی، سرعت باد و رطوبت نسبی به عنوان ورودی تعیین شد زیرا عوامل اصلی تأثیرگذار بر رواناب هستند. سپس واسنجی مدل به روش سعی و خطا انجام گرفت. دوره‌ی واسنجی از مهر ۱۳۸۹ تا شهریور ۱۳۹۹ در نظر گرفته شد. نتایج واسنجی مدل بارش-رواناب WEAP نشان‌دهنده‌ی عملکرد قابل قبول این مدل در تبدیل بارش به رواناب است (جدول ۲). مقادیر پارامترهای نهایی واسنجی شده بر اساس توانایی آن‌ها در ارائه‌ی بهترین تطابق بین جریان مشاهده شده و شبیه‌سازی شده، بر اساس معیارهای ارزیابی عملکرد مدل (R^2 ، NSE و RMSE) در جدول (۳) ارائه شده است. شکل

معیارهای ارزیابی و سنجش دقت مدل:

در این تحقیق به منظور ارزیابی کارایی هر کدام از مدل‌ها در شبیه‌سازی بارش-رواناب از معیارهای ارزیابی عملکرد مدل شامل: ضریب تعیین (R^2)، ضریب نشت‌سازتکلیف (NSE) و میانگین مربعات خطا (RMSE) استفاده شده است. در شبیه‌سازی بارش-رواناب هدف به حداکثر رساندن مقادیر R^2 و NSE و به حداقل رساندن مقادیر RMSE است. این پارامترها از طریق روابط زیر به دست می‌آیند:

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

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (17)$$

$$NSE = 1 - \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (18)$$

در روابط بالا O_i ، P_i ، \bar{O} ، \bar{P} و n به ترتیب داده‌های مشاهداتی، داده‌های محاسباتی، میانگین داده‌های مشاهداتی، میانگین داده‌های محاسباتی و تعداد داده‌ها می‌باشند (Nassery et al. 2021).

همان شاخص‌های آماری مورد استفاده برای ارزیابی عملکرد مدل در مرحله‌ی واسنجی، مورد ارزیابی قرار گرفت. شکل (۳) برازش رواناب ماهانه‌ی مشاهده شده و شبیه‌سازی شده را در طول دوره‌ی اعتبارسنجی نشان می‌دهد. همان‌طور که نتایج نشان می‌دهند بر خلاف دوره‌ی واسنجی در طول اعتبارسنجی مدل عملکرد خوبی در شبیه‌سازی جریان به خصوص در دبی‌های اوج از خود نشان نداده است. علت این رفتار را می‌توان در ویژگی‌های ساختاری مدل و شرایط هیدرولوژیکی منطقه جست‌وجو کرد. مدل WEAP بر پایه‌ی یک معادله‌ی بیلان ساده شده کار می‌کند. درحالی‌که حوضه‌ی خرم‌آباد دارای رفتار بسیار نوسانی، غیرخطی و واکنش سریع به بارش است. بنابراین مدل WEAP نتوانست تمامی این پیچیدگی‌ها را به‌خصوص در بازسازی دبی‌های اوج و حداقلی در منطقه‌ی مورد مطالعه به‌خوبی شبیه‌سازی کند. علاوه بر این مدل WEAP به تغییر الگوی آبیاری، توسعه‌ی اراضی کشاورزی و تغییرات برداشت آب بسیار حساس است. در سال‌های اخیر این متغیرها تغییر کرده‌اند، اما مدل مفهومی نتوانست اثر واقعی این تغییرات را بازسازی کند

(۲) برازش رواناب مشاهداتی و شبیه‌سازی شده را طی دوره‌ی واسنجی نشان می‌دهد.


جدول (۲): مقادیر معیارهای ارزیابی عملکرد مدل

معیارهای ارزیابی عملکرد مدل			مراحل مدل‌سازی
NSE	RMSE	R ²	
۰/۷۱	۵/۴۶	۰/۸۳	دوره واسنجی
۰/۵۳	۳/۸۲	۰/۶۵	دوره اعتبارسنجی


جدول (۳): مقادیر پارامترهای مدل واسنجی شده

پارامتر	مقدار واسنجی شده پارامتر
SWC	۳۸۵ mm
DWC	۴۲۰ mm
RZC	۵ mm/day
DC	۲ mm/day
RRF	٪۴۸
PFD	۰/۹
Initial Z1	٪۳۰
Initial Z2	٪۵۰

پس از مرحله‌ی واسنجی، اعتبارسنجی مدل برای دوره‌ی مهر ۱۳۹۹ تا شهریور ۱۴۰۲ انجام شد. خروجی شبیه‌سازی‌ها در طول دوره‌ی اعتبارسنجی با استفاده از



شکل (۲): برازش رواناب مشاهداتی و شبیه‌سازی شده در دوره‌ی واسنجی مدل WEAP



شکل (۳): برازش رواناب مشاهداتی و شبیه‌سازی شده در دوره‌ی اعتبارسنجی مدل WEAP

نشان داده شده است. همچنین در جدول (۳)، $V^{(S)}$ حجمی از جریان آهسته که در ایجاد رودخانه نقش دارد، $\tau^{(S)}$: ثابت زمانی کاهش پاسخ جریان آهسته، $\tau^{(q)}$: ثابت زمانی کاهش پاسخ جریان سریع، $1/c$: ظرفیت ذخیره‌ی رطوبت حوضه، f : فاکتور تعدیل دما و τ_w : ثابت زمانی خشک شدن حوضه است (موجرلو و همکاران، ۱۳۹۸). شکل (۴) نیز برازش رواناب مشاهداتی و شبیه‌سازی شده طی دوره‌ی واسنجی و شکل (۵) این برازش را طی دوره‌ی اعتبارسنجی نشان می‌دهد.

پارامتر τ نشان‌دهنده‌ی واکنش حوضه به بارش است. در این مطالعه τ مقداری متوسط به دست آمد که نشان‌دهنده‌ی واکنش کند مدل به بارش است و این مسئله باعث خطا در شبیه‌سازی دبی‌های اوج شده است. همچنین در حوضه‌ی خرم‌آباد بارش‌های مقطعی، دوره‌های خشکسالی و رفتار غیرایستا وجود دارد که عملکرد IHACRES را محدود کرده است در نتیجه در دوره‌ی اعتبارسنجی مقادیر RMSE بالا و NSE پایین مشاهده شده می‌شود.

شبیه‌سازی بارش-رواناب توسط مدل IHACRES

داده‌های مورد نیاز جهت شبیه‌سازی بارش-رواناب توسط مدل IHACRES شامل داده‌های بارش، میانگین دما و دبی مشاهداتی ماهانه می‌باشد. دوره‌ی آماری استفاده شده در مدل‌سازی از مهر ۱۳۳۵ تا شهریور ۱۴۰۳ می‌باشد. در مدل IHACRES به منظور واسنجی مدل دوره‌های مختلفی در نظر گرفته شد که بهترین نتایج از واسنجی دوره‌ی آماری مهر ۱۳۸۹ تا شهریور ۱۳۹۹ به دست آمد. سپس مدل برای دوره‌ی آماری مهر ۱۳۹۹ تا شهریور ۱۴۰۲ مورد اعتبارسنجی قرار گرفت.

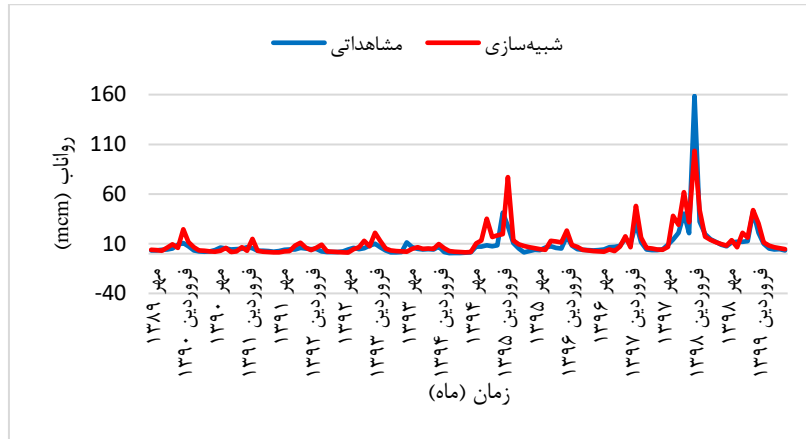
با توجه به نتایج به دست آمده از واسنجی و معیارهای ارزیابی عملکرد مدل، مدل IHACRES توانایی قابل قبولی در مدل‌سازی بارش-رواناب در حوضه‌ی آبریز مورد مطالعه دارد. مقادیر بهینه‌ی حاصل از واسنجی پارامترهای مدل IHACRES و همچنین مقادیر پارامترها و معیارهای ارزیابی عملکرد مدل در دو دوره‌ی واسنجی و اعتبارسنجی به ترتیب در جداول (۴) و (۵)

جدول (۴): مقادیر بهینه‌ی پارامترهای مدل IHACRES


τ_w (day)	f (°C)	$1/c$ (mm)	$\tau^{(q)}$ (day)	$\tau^{(S)}$ (day)	$V^{(S)}$	گام زمانی
۱/۳	۲/۵	۱۱۱۱	۰/۹۹	۵/۷۵۹	۰/۴۱۵	ماهانه

جدول (۵): معیارهای ارزیابی عملکرد مدل IHACRES در دو دوره‌ی واسنجی و اعتبارسنجی

دوره‌ی مدل‌سازی	R ²	RMSE	NSE
واسنجی	۰/۶۴	۷/۳۵	۰/۷۴
اعتبارسنجی	۰/۴۸	۴/۹۳	۰/۵۲



شکل (۴): برازش رواناب مشاهداتی و شبیه‌سازی شده در دوره‌ی واسنجی مدل IHACRES



شکل (۵): برازش رواناب مشاهداتی و شبیه‌سازی شده در دوره‌ی اعتبارسنجی مدل IHACRES

تأخیرهای مورد نیاز برای مدل‌سازی متغیرهای ورودی به شبکه با رسم توابع خودهمبستگی جزئی در نرم‌افزار Minitab به دست آمد (شکل ۶). با توجه به نمودارهای خودهمبستگی جزئی ترسیم شده، خودهمبستگی داده‌های همه‌ی متغیرها در تأخیر یک معنادار است و در سایر تأخیرها خودهمبستگی معنادار ضعیف است و یا در داده‌ها دیده نمی‌شود. در این پژوهش جهت شبیه‌سازی بارش-رواناب از داده‌های ماهانه‌ی ایستگاه

مدل‌سازی بارش-رواناب توسط الگوریتم‌های

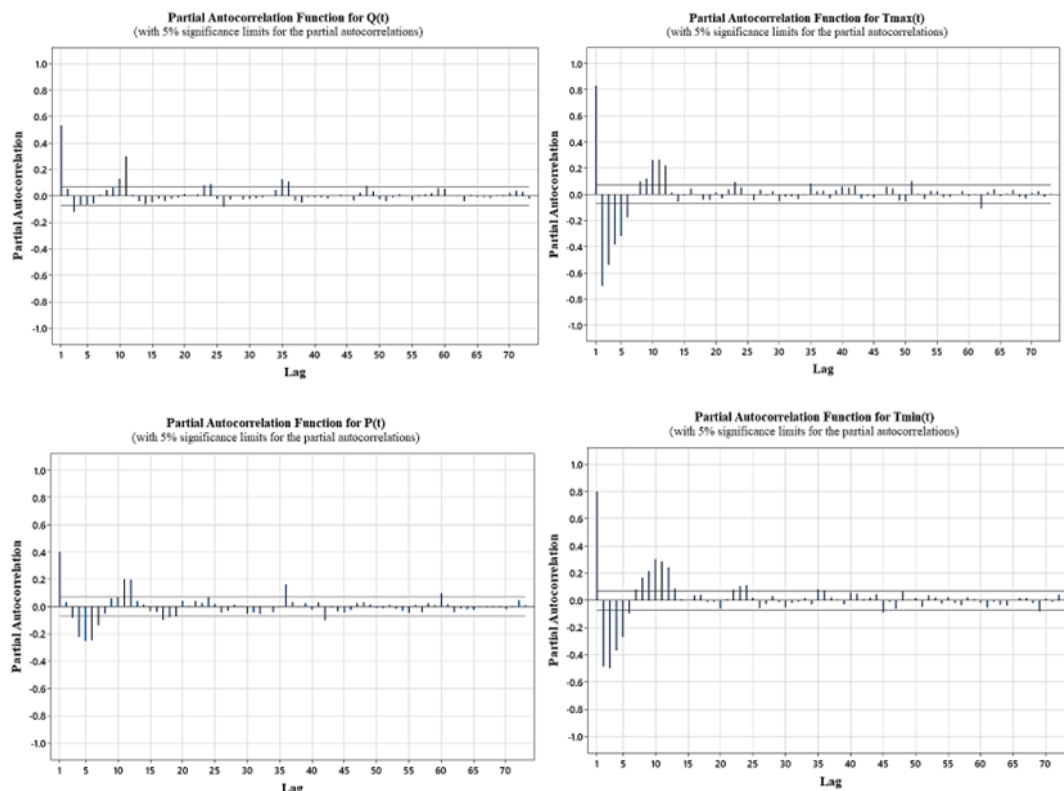
هوش مصنوعی

- آماده‌سازی داده‌های ورودی

تعیین متغیرهای ورودی یکی از مهم‌ترین مراحل در فرآیند توسعه مدل هیدرولوژیکی شبکه‌ی عصبی مصنوعی است. برای انتخاب مقادیر ورودی به شبکه، یک راه‌حل مناسب مشاهدات هیدرولوژیکی در زمان‌های تأخیر مختلف است. برای این منظور، تعداد

آموزش از مهر ۱۳۳۵ تا شهریور ۱۳۸۹ (۸۰ درصد کل داده‌ها) و دوره‌ی آزمایش از مهر ۱۳۸۹ تا شهریور ۱۴۰۳ (۲۰ درصد کل داده‌ها) انتخاب شد.

سینوپتیک خرم‌آباد (مهر ۱۳۳۵ تا شهریور ۱۴۰۳) استفاده شده است. به منظور شبیه‌سازی بارش-رواناب با استفاده از روش‌های هوش مصنوعی نیز دوره‌ی



شکل (۶): نمودار خودهمبستگی جرئی متغیرهای ورودی و خروجی مورد استفاده در مدل‌های هوش مصنوعی

ضرایب همبستگی بین متغیرها نیز نشان داد همبستگی بسیار خوبی بین رواناب فعلی با بارندگی فعلی و همبستگی معنی‌داری با بارندگی با تأخیر ۱ ماهه وجود دارد. ضریب همبستگی بین رواناب فعلی و حداکثر و حداقل دماهای فعلی نیز معنی‌دار بود. همچنین مشاهده شد که همبستگی بین رواناب ماهانه، بارندگی با تأخیر دو ماهه و حداکثر و حداقل دما با تأخیر یک ماهه بسیار پایین بود. بنابراین، این ترکیبات برای این مطالعه در نظر گرفته نشدند. شرح الگوهای مختلف متغیرهای ورودی برای شبیه‌سازی رواناب ماهانه در جدول (۶) ارائه شده است.

جدول (۶): الگوهای مختلف متغیرهای ورودی برای شبیه‌سازی رواناب ماهانه

مدل	ورودی	خروجی
M1	P_t, P_{t-1}	Q_t
M2	$P_t, T_{t \max}$	Q_t
M3	$P_t, T_{t \min}$	Q_t
M4	$P_t, T_{(t-1) \max}, T_{(t-1) \min}$	Q_t
M5	$P_t, T_{t \max}, T_{t \min}$	Q_t
M6	$P_t, P_{t-1}, T_{t \max}$	Q_t
M7	$P_t, P_{t-1}, T_{t \min}$	Q_t
M8	$P_t, P_{t-1}, T_{t \max}, T_{t \min}$	Q_t
M9	$P_t, P_{t-1}, T_{(t-1) \max}$	Q_t
M10	$P_t, P_{t-1}, T_{(t-1) \min}$	Q_t
M11	$P_t, P_{t-1}, T_{(t-1) \max}, T_{(t-1) \min}$	Q_t

(جدول ۷). بر این اساس بهترین الگوی ورودی (M6) شامل دمای حداکثر، بارش و بارش یک ماه قبل (T_{max} , Pt, P(t-1)) به دست آمد. شکل (۷) نمودار پراکندگی مدل ANN برای الگوی M6 در مراحل آموزش و آزمایش نشان می‌دهد. همان‌طور که ملاحظه می‌شود همبستگی خوبی بین متغیرهای الگوی M6 وجود دارد. شکل (۸) نیز برازش رواناب مشاهداتی و شبیه‌سازی شده را در مراحل آموزش و آزمایش نشان می‌دهد.

ANN قادر به یادگیری الگوهای پیچیده است اما به‌تنهایی کافی نیست. شبکه‌های عصبی روابط پیچیده را آموزش می‌دهند اما فاقد منطق استنتاجی هستند و تنها بر داده‌های گذشته تکیه می‌کنند به همین دلیل عملکرد آن‌ها در شرایط خشک، سال‌های کم‌بارش و داده‌های پرت دچار افت می‌شود. این مدل معمولاً پیک‌ها را بهتر از مدل‌های مفهومی شبیه‌سازی می‌کنند اما اگر داده متنوع نباشد، دچار بیش‌برازش می‌شوند. در این مطالعه ANN توانست رفتار کلی را ثبت کند، اما نتوانست مانند ANFIS تغییرات پیک را دقیق مدل کند.

در مرحله‌ی بعد به منظور حذف تأثیر مقیاس (اندازه) داده‌ها در یادگیری مدل و همچنین جلوگیری از تخمین کم‌تر از حد وزن‌های شبکه عصبی مصنوعی، تمامی متغیرها بر اساس فرمول زیر نرمال و سپس به شبکه معرفی گردید.

$$x_n = 0.8 \left(\frac{x_i - x_{min}}{x_{max} - x_{min}} \right) + 0.1 \quad (19)$$

در رابطه‌ی فوق x_i مقدار واقعی داده نام، x_{max} حداکثر مقدار داده‌ها، x_{min} حداقل مقدار داده‌ها و x_n مقدار داده نرمال شده است (Rashidi et al. 2016).

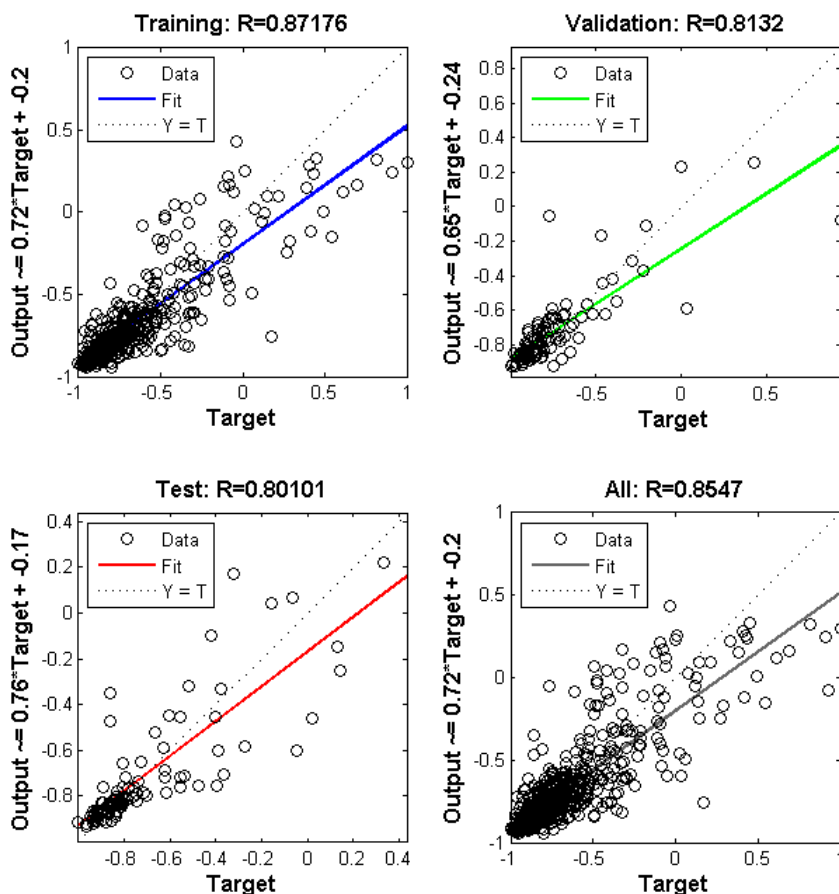
- مدل‌سازی بارش-رواناب توسط الگوریتم ANN

مدل‌سازی شبکه‌ی عصبی با استفاده از نرم‌افزار Matlab2018 انجام شده است. به منظور مدل‌سازی بارش-رواناب با استفاده از مدل ANN از مجموع کل داده‌های موجود ۸۰ درصد برای فرآیند آموزش و ۲۰ درصد برای فرآیند آزمون انتخاب شد.


با توجه به ترکیب ورودی‌های مختلف بهترین الگوی ورودی که کم‌ترین خطا را در مراحل آموزش و آزمایش نشان داد، با استفاده از روش سعی و خطا انتخاب شد

جدول (۷): مقادیر معیارهای ارزیابی عملکرد مدل حاصل از الگوهای مختلف ورودی به الگوریتم ANN

الگوی ورودی	مرحله آموزش			مرحله آزمایش		
	RMSE	NSE	R ²	RMSE	NSE	R ²
M1	۵/۶۳	۰/۷۷	۰/۶۱	۵/۷۵	۰/۸۲	۰/۶۴
M2	۷/۹۲	۰/۷۳	۰/۵۷	۷/۵۲	۰/۷۴	۰/۵۹
M3	۹/۸۶	۰/۵۹	۰/۵۰	۹/۲۷	۰/۶۱	۰/۴۸
M4	۸/۴۹	۰/۶۰	۰/۵۱	۸/۳۸	۰/۶۷	۰/۵۵
M5	۶/۶۵	۰/۷۲	۰/۵۸	۶/۱۹	۰/۷۵	۰/۶۲
M6	۴/۳۶	۰/۸۳	۰/۷۶	۳/۰۸	۰/۸۰	۰/۷۹
M7	۸/۸۷	۰/۶۳	۰/۵۵	۷/۷۶	۰/۶۹	۰/۵۴
M8	۱۰/۴۶	۰/۵۶	۰/۴۱	۱۰/۰۷	۰/۵۳	۰/۴۲
M9	۹/۷۱	۰/۵۷	۰/۴۴	۹/۴۹	۰/۵۸	۰/۴۶
M10	۱۱/۳۸	۰/۴۶	۰/۳۵	۱۰/۷۸	۰/۴۸	۰/۴۰
M11	۱۰/۰۹	۰/۵۱	۰/۴۸	۹/۶۱	۰/۵۵	۰/۴۹



شکل (۷): نمودار پراکندگی الگوریتم ANN برای الگوی M6 در مراحل آموزش و آزمایش



شکل ۸- برآزش رواناب مشاهده‌ای و شبیه‌سازی شده در مراحل آموزش و آزمایش

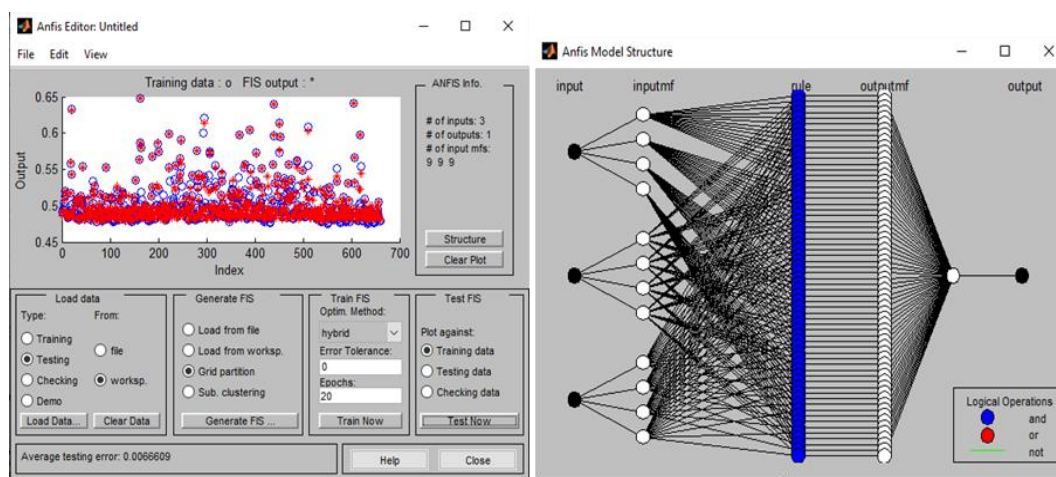
سوگنو در محیط نرم‌افزار MATLAB پیاده‌سازی و کدنویسی گردید. در چارچوب مدل ANFIS، از مجموعه‌ای متنوع از توابع عضویت فازی شامل اشکال مثلثی، زنگوله‌ای، دوزنقه‌ای، گوسی و گوسی نوع دوم

مدل‌سازی بارش-رواناب توسط الگوریتم ANFIS

به‌منظور شبیه‌سازی فرآیند بارش-رواناب، الگوریتم ANFIS با بهره‌گیری از ساختار سیستم فازی نوع

(۱۰) نیز برازش رواناب مشاهداتی و شبیه‌سازی شده در دوره‌های آموزش و آزمایش را نشان می‌دهد. با توجه به اینکه مدل ANFIS ترکیبی از شبکه عصبی و منطق فازی است این ویژگی باعث می‌شود همزمان بتواند الگوهای خطی را مانند رگرسیون خطی شبیه‌سازی کند، و روابط غیرخطی و پیچیده بارش-رواناب را مانند شبکه‌های عصبی استخراج کند. روابط غیرخطی بارش-رواناب در حوضه خرم‌آباد بسیار قوی است در چنین شرایطی، مدل‌های مبتنی بر قواعد فازی مثل ANFIS توانایی بیشتری در ثبت تغییرات ناگهانی دارند. همچنین این مدل قادر است عدم قطعیت و تغییرپذیری داده‌ها را بهتر مدیریت کند. به‌علاوه به دلیل وجود توابع عضویت، ANFIS نوسانات، ناهنجاری‌ها و داده‌های غیرایستا را بهتر از مدل‌های ANN و SVM پردازش می‌کند. بر اساس نتایج مقاله، تابع گوسی نوع دوم بهترین عملکرد را داشته است. این تابع تغییرات آرام و پیوسته را بهتر ثبت می‌کند، نسبت به نویز مقاوم‌تر است، و در داده‌های هیدرولوژیک معمولاً بهترین کارایی را دارد. این ویژگی‌ها باعث شده‌اند که ANFIS بتواند ساختار دینامیک بارش-رواناب را با نزدیک‌ترین برازش نسبت به مقادیر مشاهده‌شده شبیه‌سازی کند.


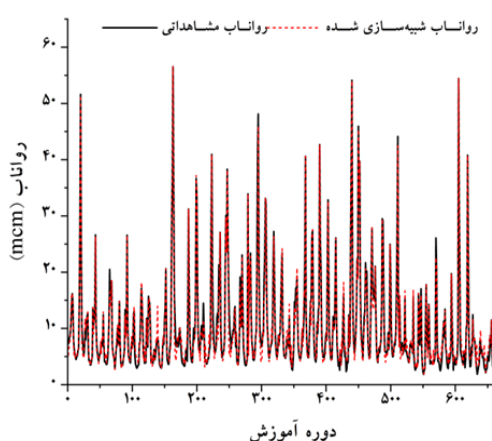
استفاده شد. با توجه به ترکیب‌های مختلف متغیرهای ورودی، به‌منظور شناسایی بهترین الگوی ورودی، از فرآیند آزمون و خطا استفاده گردید. در این مرحله، بهترین ترکیب ورودی بر اساس شاخص‌های ارزیابی عملکرد مدل (R^2 ، RMSE و NSE) در دو فاز آموزش و آزمون انتخاب شد. نتایج نشان داد که در میان توابع عضویت مورد استفاده، تابع گوسی نوع دوم بالاترین دقت را در شبیه‌سازی رابطه‌ی بارش-رواناب ارائه می‌دهد. بر همین اساس، تنها نتایج ارزیابی عملکرد مدل مبتنی بر تابع گوسی نوع دوم برای ترکیب‌های گوناگون متغیرهای ورودی در جدول (۸) گزارش شده است. در ساختار مدل طراحی‌شده، تعداد توابع عضویت در لایه‌ی نخست برابر با پنج در نظر گرفته شد، تابع عضویت خروجی از نوع خطی انتخاب گردید و الگوریتم یادگیری هیبرید به‌عنوان روش بهینه‌سازی مورد استفاده قرار گرفت. همچنین، برای ایجاد سیستم استنتاج فازی اولیه از رویکرد مبتنی بر شبکه‌بندی بهره گرفته شد. شکل (۹) ساختار کلی سیستم مذکور را نمایش می‌دهد. براساس نتایج حاصل از الگوهای ورودی و توابع عضویت مختلف، همانند مدل ANN الگوی M6 به عنوان بهترین الگوی ورودی در نظر گرفته شد. شکل



شکل (۹): ساختار الگوریتم ANFIS مورد استفاده در این مطالعه

جدول (۸): مقادیر معیارهای ارزیابی عملکرد مدل حاصل از الگوهای مختلف ورودی به الگوریتم ANFIS

دوره آزمایش			دوره آموزش			الگوی ورودی
RMSE	NSE	R ²	RMSE	NSE	R ²	
۳/۴۶	۰/۷۴	۰/۸۳	۱/۶۹	۰/۸۹	۰/۹۱	M1
۳/۹۲	۰/۷۲	۰/۸۱	۳/۷۴	۰/۷۷	۰/۸۶	M2
۳/۴۸	۰/۷۹	۰/۸۰	۳/۸۷	۰/۷۶	۰/۷۹	M3
۳/۸۳	۰/۷۸	۰/۷۵	۳/۳۶	۰/۸۱	۰/۷۸	M4
۲/۹۷	۰/۸۶	۰/۸۸	۲/۵۲	۰/۹۰	۰/۹۲	M5
۱/۹۳	۰/۸۷	۰/۹۴	۲/۰۸	۰/۹۸	۰/۹۶	M6
۳/۸۷	۰/۷۱	۰/۸۲	۳/۷۶	۰/۷۳	۰/۸۵	M7
۴/۴۶	۰/۷۰	۰/۷۱	۴/۰۷	۰/۷۸	۰/۷۴	M8
۳/۷۱	۰/۸۰	۰/۷۴	۳/۷۴	۰/۸۲	۰/۷۷	M9
۵/۶۹	۰/۵۹	۰/۶۳	۴/۷۸	۰/۶۸	۰/۶۶	M10
۴/۵۸	۰/۷۳	۰/۷۶	۴/۸۱	۰/۷۱	۰/۷۲	M11



شکل (۱۰): برازش رواناب مشاهده‌ای و شبیه‌سازی شده در مراحل آموزش و آزمایش الگوریتم ANFIS

Kernel)، تابع چندجمله‌ای (Polynomial Kernel) و تابع خطی (Linear Kernel) مورد استفاده و ارزیابی قرار گرفته‌اند. در گام نخست، هدف اصلی تحقیق، تشخیص بهینه‌ترین تابع کرنل از منظر کارایی مدل‌سازی و توان تعمیم‌دهی در مقایسه با سایر توابع بوده است. بدین منظور، فرآیند مدل‌سازی SVM با به‌کارگیری هر یک از کرنل‌های مذکور و بر اساس ترکیب‌های متنوعی از متغیرهای ورودی انجام پذیرفت. جهت سنجش عملکرد الگوریتم در مراحل آموزش و آزمون، از شاخص‌های ارزیابی عملکرد مدل شامل R²

- مدل‌سازی بارش-رواناب توسط الگوریتم SVM

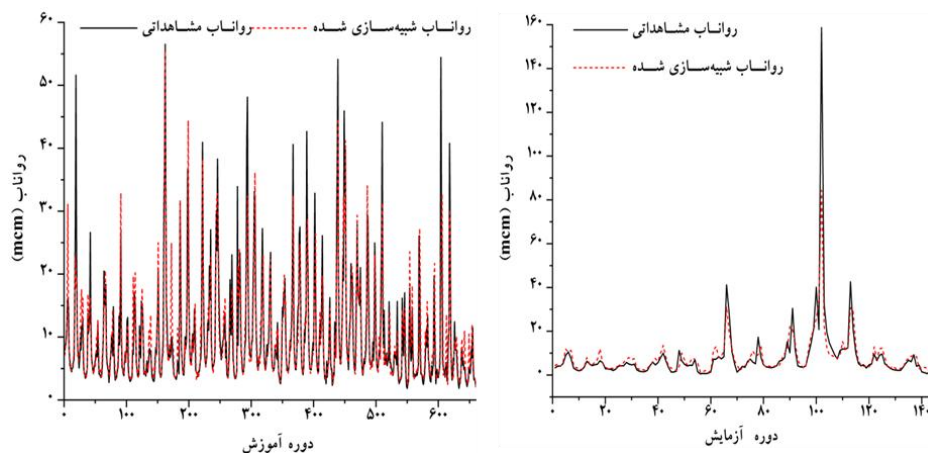
به منظور مدل‌سازی دبی ماهانه با استفاده از روش SVM نیز همانند روش ANFIS و ANN داده‌های ۵۴ سال برای آموزش و ۱۴ سال برای آزمایش انتخاب شدند. از میان اجزای سازنده الگوریتم ماشین بردار پشتیبان (SVM)، انتخاب تابع کرنل به‌عنوان مؤلفه‌ای تعیین‌کننده در ساختار و کارایی مدل از اهمیت ویژه‌ای برخوردار است. در این مطالعه، سه نوع تابع کرنل شامل تابع پایه‌ی شعاعی (Radial Basis Function)

مشخص شود. این روند برای مقادیر متفاوت پارامتر γ نیز تکرار گردید و در نتیجه، مجموعه‌ای از مدل‌های مختلف SVM با ترکیب‌های گوناگون از پارامترها توسعه یافت. سپس از بین مدل‌های توسعه داده شده، مدل با کم‌ترین خطا تعیین و پارامترهای آن به عنوان مقادیر بهینه‌ی ϵ ، C و γ انتخاب شد. برای هر الگوی ورودی با تغییر ϵ ، C و γ شبکه‌های مختلفی ساخته و آموزش داده شد و در نهایت ساختاری که کم‌ترین خطا و بیش‌ترین دقت را داشت، به عنوان مناسب‌ترین الگو انتخاب شد (جدول ۹). با توجه به این نتایج می‌توان نتیجه گرفت که در کل SVM عملکرد مناسبی در پیش‌بینی دبی ماهانه دارد. شکل (۱۱) نیز برآزش رواناب مشاهداتی و شبیه‌سازی شده در دوره‌های آموزش و آزمایش را نشان می‌دهد.

مدل SVM معمولاً برای داده‌های مرزی و تفکیک‌پذیر مناسب‌تر است، این مدل در شرایطی که داده‌ها مرزبندی مشخص داشته باشند عملکرد عالی دارد اما در داده‌های هیدرولوژیک که پیوسته و پرنوسان هستند، کارایی آن کاهش می‌یابد و پیک‌های بارش-رواناب را به خوبی نمی‌بیند. طبق نتایج این مطالعه، مدل SVM در جریان‌های متوسط ضریب خطای مشابهی با مدل‌های ANFIS و ANN دارد اما در جریان‌های پیک دقت آن نسبت به ANFIS و ANN کمتر است.

NSE و RMSE استفاده شده است. بر این اساس تابع RBF-kernel کارایی بالاتری در مقایسه با سایر توابع هسته از خود نشان داد. در گام بعدی، تعیین مقادیر بهینه‌ی پارامترهای کنترلی الگوریتم SVM شامل ϵ و C صورت گرفت. علاوه بر این، در تابع RBF-kernel پارامتر دیگری با نماد γ نیز باید مقداردهی و بهینه شود. از این رو، به منظور پیش‌بینی دبی ماهانه جریان با استفاده از مدل SVM، لازم است مقادیر بهینه‌ی هر سه پارامتر ϵ ، C و γ تعیین گردد. به منظور برآورد این پارامترها، دو پارامتر ϵ و C از طریق الگوریتم بهینه‌سازی جست‌وجوی شبکه و پارامتر γ نیز بر اساس فرآیند آزمون و خطا استخراج شدند. با این حال، از آنجا که روش جست‌وجوی شبکه در حالت عادی دارای سرعت پایین و هزینه‌ی محاسباتی بالاست، در این مطالعه از نسخه‌ی اصلاح‌شده‌ی الگوریتم جست‌وجوی شبکه‌ی دو مرحله‌ای همراه با اعتبارسنجی متقاطع به منظور بهبود کارایی محاسبات استفاده گردید (Chen et al. 2006).

در گام نخست، با در نظر گرفتن شبکه‌هایی با ابعاد نسبتاً بزرگ، محدوده‌ی تغییرات پارامترهای ϵ و C به ازای مقادیر ثابت پارامتر γ تعیین گردید. سپس، پس از شناسایی بازه‌های مناسب، همان محدوده‌ها به شبکه‌هایی با دقت بالاتر (ابعاد ریزتر) تقسیم شدند تا مقادیر بهینه‌ی دو پارامتر یادشده با دقت بیشتری



شکل (۱۱): برآزش رواناب مشاهداتی و شبیه‌سازی شده مراحل آموزش و آزمایش الگوریتم SVM

جدول (۹): نتایج حاصل از الگوهای ورودی مختلف به مدل SVM در دوره‌های آموزش و آزمایش

الگوی ورودی	مرحله آموزش			مرحله آزمایش			پارامترهای بهینه		
	RMSE	NSE	R ²	RMSE	NSE	R ²	ε	C×۱۰ ^۰	γ
M1	۰/۵۷	۰/۶۰	۵/۶۹	۰/۵۵	۰/۵۷	۵/۹۱	۰/۱۹	۱۰۸/۱	۱۵۹
M2	۰/۵۵	۰/۵۴	۵/۹۴	۰/۵۴	۰/۵۳	۵/۹۷	۰/۰۰۰۱	۶	۱۴
M3	۰/۵۴	۰/۵۵	۶/۲۶	۰/۵۲	۰/۵۱	۶/۳۶	۰/۰۰۰۸	۱۳	۲۷/۴۸
M4	۰/۶۳	۰/۶۶	۴/۴۲	۰/۶۱	۰/۶۲	۴/۵۴	۰/۱۰	۰/۰۰۰۵	۰/۳۰
M5	۰/۶۸	۰/۷۰	۳/۶۸	۰/۶۶	۰/۶۹	۳/۷۵	۰/۳	۴۲/۳	۲۱۴
M6	۰/۷۹	۰/۷۸	۲/۶۱	۰/۷۷	۰/۷۶	۳/۶۶	۰/۲۵	۵۹۰/۲	۲۴۰
M7	۰/۷۲	۰/۷۳	۲/۷۲	۰/۷۱	۰/۷۵	۴/۰۹	۰/۱۶	۶۲/۳	۱۵۵
M8	۰/۷۵	۰/۷۳	۲/۲۷	۰/۷۱	۰/۸۵	۴/۱۹	۰/۰۸	۰/۰۰۰۶	۱۶
M9	۰/۷۶	۰/۷۵	۲/۷۴	۰/۷۴	۰/۷۳	۳/۸۳	۰/۴	۲۷۸	۲۰۸
M10	۰/۷۸	۰/۷۷	۳/۵۶	۰/۷۷	۰/۷۹	۳/۶۸	۰/۲	۰/۳	۵۳۵
M11	۰/۷۳	۰/۷۱	۳/۳۱	۰/۷۰	۰/۶۸	۳/۷۲	۰/۰۳	۴۳/۷	۹

نتیجه‌گیری

این مطالعه بینش قابل توجهی در مورد مدل‌سازی‌های رابطه بارش-رواناب در حوضه آبریز رودخانه‌ی خرم‌آباد با استفاده از مدل‌های مفهومی و یادگیری ماشین ارائه می‌دهد. به‌طور کلی با توجه به نتایج به‌دست آمده، مدل‌های هیدرولوژیکی و یادگیری ماشین مورد استفاده در این تحقیق عملکرد قابل قبولی در شبیه‌سازی بارش-رواناب بر اساس معیارهای R²، RMSE و NSE از خود نشان دادند. بر این اساس به ترتیب مدل‌های ANFIS، ANN، SVM، WEAP و IHACRES عملکرد بهتری در شبیه‌سازی بارش-رواناب ارائه دادند. در میان مدل‌های مفهومی آزمایش‌شده نیز مدل WEAP برآزش بهتری را نسبت به مدل IHACRES برای حوضه آبریز رودخانه‌ی خرم‌آباد ارائه داد. همان‌طور که نتایج نشان می‌دهد در مجموع می‌توان گفت که مدل‌های یادگیری ماشین کارایی بهتری در شبیه‌سازی بارش رواناب نسبت به مدل‌های هیدرولوژیکی دارند. نتایج این مطالعه با نتایج حقی‌زاده و همکاران (۱۳۹۴)، ناظری تهرودی و همکاران (۱۳۹۵)، فرودی‌صفات و همکاران (۱۴۰۰)، اسدی و همکاران (۲۰۲۴) و مؤمنه (۱۴۰۱) مطابقت دارد. مدل‌های یادگیری ماشین در ثبت فرآیندهای

هیدرولوژیکی پیچیده و غیر ایستا که برای مدل‌سازی دقیق بارش-رواناب در مناطق نیمه‌خشک بسیار مهم است، برتری دارند. در مجموع، این مطالعه با اعتبارسنجی استفاده از مدل‌های شبکه عصبی در محیط‌های غیر ایستا، به پیشرفت مدل‌سازی هیدرولوژیکی کمک می‌کند. با توجه به اینکه مدل‌های یادگیری ماشین دارای مزیت‌هایی از جمله داده‌های ورودی کمتر، سرعت اجرای بالاتر و دقت بیشتر نسبت به مدل‌های هیدرولوژیکی در شبیه‌سازی هستند، بنابراین توصیه می‌شود در تحقیقات از این مدل‌ها در کنار مدل‌های هیدرولوژیکی به منظور افزایش دقت نتایج و پیش‌بینی‌ها استفاده شود. علاوه بر این، ترکیب این مدل‌های مفهومی هیدرولوژیکی و یادگیری ماشین به موضوعی محبوب برای مطالعات اخیر تبدیل شده است. بنابراین توصیه می‌شود در مطالعات آتی شبیه‌سازی بارش-رواناب در حوضه آبریز رودخانه‌ی خرم‌آباد با استفاده از ترکیب مدل‌های مختلف مفهومی و یادگیری ماشین صورت گیرد و سپس نتایج آن با مدل‌های منفرد مقایسه و سازگارترین مدل‌ها جهت انجام شبیه‌سازی و پیش‌بینی رواناب در منطقه مورد مطالعه انتخاب شود.

قدردانی: نویسندگان این مقاله از شرکت آب منطقه‌ای لرستان جهت همکاری در ارائه داده‌های مورد نیاز این تحقیق تشکر و قدردانی می‌کنند.

منابع

- حقی‌زاده، ع.، م. محمدلو و ف. نوری. ۱۳۹۴. شبیه‌سازی فرآیند بارش-رواناب با استفاده از شبکه‌ی عصبی-مصنوعی و سیستم فازی عصبی تطبیقی و رگرسیون چند متغیره (مطالعه‌ی موردی: حوضه‌ی آبریز رودخانه‌ی خرم‌آباد). نشریه اکوهیدرولوژی، دوره ۲، شماره ۲، ص ۲۴۳-۲۳۳.
- زارعی، م.، م. ر. قنبرپور، م. حبیب نژاد روشن و ک. شاهدهی. ۱۳۸۸. شبیه‌سازی جریان رودخانه با استفاده از مدل بارش-رواناب IHACRES (مطالعه موردی: حوضه‌ی آبخیز کسلیان). مجله علمی-پژوهشی علوم و مهندسی آبخیزداری ایران. جلد سوم، شماره ۸.
- فرودی صفات، ا.، م.م. احمدی، ک. قادری و س. گلستانی کرمانی. ۱۴۰۰. ارزیابی دو مدل تلفیقی هیدرولوژیکی-جعبه سیاه برای پیش‌بینی سیلاب در حوضه آبریز هلیل‌رود. نشریه اکوهیدرولوژی، دوره ۸، شماره ۲، ص ۴۰۹-۳۹۷.
- موجرلو، ف.، ر. فضل‌اولی و ع. عمادی. ۱۳۹۷. کاربرد مدل IHACRES برای ارزیابی اثرات تغییر اقلیم بر دبی حوضه آبریز تجن. نشریه‌ی آبیاری و زهکشی ایران. شماره‌ی ۱، جلد ۱۳، اردیبهشت ۱۳۹۸، ص ۱۴۱-۱۲۹.
- مؤمنه، ص. ۱۴۰۱. مقایسه عملکرد مدل‌های هوش مصنوعی با مدل IHACRES در مدل‌سازی جریان حوضه آبریز رودخانه گاماسیاب. مدل‌سازی و مدیریت آب و خاک ۲(۳)، ۱-۱۶.
- <https://doi.org/10.22098/MMWS.2022.9972.1076>
- ناظری تهرودی، م.، س. ر. هاشمی، ف. احمدی و ز. ناظری تهرودی. ۱۳۹۵. بررسی دقت مدل‌های ANFIS, SVM و GP در مدل‌سازی مقادیر دبی جریان رودخانه. مجله‌ی علمی پژوهشی اکوهیدرولوژی، دوره‌ی ۳، شماره‌ی ۳، پاییز ۱۳۹۵.

Abdi, D.A. and T. Ayenew. 2021. Evaluation of the WEAP model in simulating subbasin hydrology in the Central Rift Valley basin, Ethiopia. Ecological Processes. <https://doi.org/10.1186/s13717-021-00305-5>

Adnan, R.M., A. Petroselli, S. Heddham, C.A.G. Santos and O. Kisi. 2021. Comparison of different methodologies for rainfall-runoff modeling: Machine learning vs. conceptual approach. Nat. Hazards 2021, 105, 2987-3011. <https://doi.org/10.1007/s11069-020-04438-2>

Asadi, S., P. Jimeno-Sáez, A. López-Ballesteros and J. Senent-Aparicio. 2024. Comparison and integration of physical and interpretable AI-driven models for rainfall-runoff simulation. Results in Engineering 24(2024)103048. <https://doi.org/10.1016/j.rineng.2024.103048>

Bai, Y., N. Bezak, K. Sapac, M. Klun and J. Zhang. 2019. Short-Term Streamflow Forecasting Using the Feature-Enhanced Regression Model. Water Resour. Manag. 33, 4783-4797. <https://doi.org/10.1007/s11269-019-02399-1>

Fang, W., S. Huang, K. Ren, Q. Huang, G. Huang, G. Cheng and K. Li. 2019. Examining the applicability of different sampling techniques in the development of decomposition-based streamflow forecasting models. Journal of Hydrology 568:534-550. <https://doi.org/10.1016/j.jhydrol.2018.11.020>

Feng, Z.K., W.J. Niu, Z.Y. Tang, Z.Q. Jiang, Y. Xu, Y. Liu and H.R. Zhang. 2020. Monthly runoff time series prediction by variational mode decomposition and support vector machine based on quantum-behaved particle swarm optimization. J Hydrol 583:124627

Gauch, M., F. Kratzert, O. Gilon, H. Gupta, J. Mai, G. Nearing, B. Tolson, S. Hochreiter and D. Klotz. 2023. In Defense of Metrics: Metrics Sufficiently Encode Typical Human Preferences

Regarding Hydrological Model Performance. *Water Resour. Res.* 2023, 59, e2022WR033918. <https://doi.org/10.1029/2022WR033918>

Gebre, S. L. 2015. Application of the HEC-HMS model for runoff simulation of Upper Blue Nile River Basin. *Hydrology: Current Research* 6 (2), 1000199. <https://doi.org/10.4172/2157-7587.1000199>

Gichamo, T., V. Nourani, H. Gökçekuş and G. Gelete. 2024. Ensemble rainfall-runoff modeling of physically based semi-distributed models using multi-source rainfall data fusion. *Journal of Water and Climate Change* Vol 15 No 2, 325 <https://doi.org/10.2166/wcc.2023.084>

Ghorbani, M.A., R. Khatibi, A. Goel, M. FazeliFard and A. Azani. 2016. Modeling river discharge time series using support vector machine and artificial neural networks. *Environ Earth Sci* (2016) 75:685. <https://doi.org/10.1007/s12665-016-5435>

Herath, H.M.V.V., J. Chadalawada and V. Babovic. 2021. Hydrologically informed machine learning for rainfall-runoff modelling: Towards distributed modelling. *Hydrology. Earth System. Sci.* 2021, 25, 4373–4401. <https://doi.org/10.5194/hess-25-4373-2021>

Huang, P.C and K, Tun Lee. 2025. Developing an alternative data-driven model to resemble geomorphologic rainfall-runoff models, *Geomatics, Natural Hazards and Risk*, 16:1, 2516725, <https://doi.org/10.1080/19475705.2025.2516725>

Islam, M.R., W.Z.W. Jaafar, L.S. Hin, N. Osman, A. Hossain and N.S. Mohd. 2018. Development of an intelligent system based on ANFIS model for predicting soil erosion. *Environmental Earth Sciences* (2018) 77:186 <https://doi.org/10.1007/s12665-018-7348-z>

Kao, I.F., Y. Zhou, L.-C. Chang and F.-J. Chang. 2020. Exploring a Long Short-Term Memory based Encoder-Decoder framework for multi-step-ahead flood forecasting. *J. Hydrol.* 2020, 583, 124631. <https://doi.org/10.1016/j.jhydrol.2020.124631>

Karami, R., M. Amirabadizadeh, M. Pourreza bilondi, and M. Yaghoobzadeh. 2022. Evaluation of IHACRES models and neural-fuzzy inference system in forecasting the runoff of the Kurit dam catchment in the future period. *Integrated Watershed Management*, Autumn 2022, 2(3), 82-94 <https://doi.org/10.22034/iwm.2022.563130.1046>

Mahesh, B. 2020. Machine learning algorithms-a review. *Int. J. Sci. Res.* 2020, 9, 381–386. <https://doi.org/10.21275/ART20203995>

Mishra, N., H.K. Soni, S. Sharma and A.K. Upadhyay. 2018. Development and Analysis of Artificial Neural Network Models for Rainfall Prediction by Using Time-Series Data. *I.J. Intelligent Systems and Applications*, 2018, 1, 16-23.

Mohammadi, B., F. Ahmadi, S. Mehdizadeh and Y. Guan. 2020a. Developing novel robust models to improve the accuracy of daily streamflow modeling. *Water Resource Management*, 34(10):3387–3409.

Mohammadi, B., Y. Guan, R. Moazenzadeh, M. Jafar and S. Safari. 2020b. Catena implementation of hybrid particle swarm optimization-differential evolution algorithms coupled with multi-layer perceptron for suspended sediment load estimation. *Catena* 198:105024. <https://doi.org/10.1016/j.catena.2020.105024>

Mohammadi, B., S. Mehdizadeh, F. Ahmadi, N. Thi and T. Lien. 2020c. Developing hybrid time series and artificial intelligence models for estimating air temperatures. *Stoch Environ Res Risk Assess* 7. <https://doi.org/10.1007/s00477-020-01898-7>

Nassery, H. R., N. Zeydalinejad, F. Alijani and A. Shakiba. 2021. A proposed modelling towards the potential impacts of climate change on a semi-arid, small-scaled aquifer: a case study of Iran. *Environ Monit Assess* (2021) 193:182. <https://doi.org/10.1007/s10661-021-08955-w>

Nearing, G.S., F. Kratzert, A.K. Sampson, C.S. Pelissier, D. Klotz, J.M. Frame, C. Prieto and H.V. Gupta. 2010. What Role Does Hydrological Science Play in the Age of Machine Learning? *Water Resour. Res.* 2021, 57, e2020WR028091. <https://doi.org/10.1029/2020WR028091>

Niu, G.Y., C. Paniconi, P.A. Troch, R.L. Scott, M. Durcik, X. Zeng, T. Huxman and D.C. Goodrich. 2014. An integrated modeling framework of catchment-scale ecohydrological processes: 1. Model description and tests over an energy-limited watershed. *Ecohydrology*



7(2):427–439. <https://doi.org/10.1002/eco.1362>

Nourani, V., H. Gökçekuş and T. Gichamo. 2021b. Ensemble data-driven rainfall-runoff modeling using multi-source satellite and gauge rainfall data input fusion. *Earth Science Informatics* 14 (4), 1787–1808. <https://doi.org/10.1007/s12145-021-00615-4>

Orellana, B., I. G. Pechlivanidis, N. McIntyre, H. S. Wheeler and T. Wagener. 2008. A toolbox for the identification of parsimonious semi distributed rainfall-runoff models: application to the Upper Lee catchment. In: *Proceedings of the iEMSs Fourth Biennial Meeting: International Congress on Environmental Modelling and Software (iEMSs 2008)*.

Ramzi, Kh., M. Nadir, B.M. Tewfik and D.Kh. Hakim. 2024. Hydrological Forecasts Modeling Using Artificial Intelligence and Conceptual Models of KébirRhumel Watershed, Algeria. *Ecological Engineering & Environmental Technology* 2024, 25(9), 68–80. <https://doi.org/10.12912/27197050/190235>

Reichstein, M., G. Camps-Valls, B. Stevens, M. Jung, J. Denzler and N. Carvalhais. 2019. Deep learning and process understanding for data-driven Earth system science. *Nature* 566(7743):195-204. <https://doi.org/10.1038/s41586-019-0912-1>

Shekar, P. R., A. Mathew, A. Pandey and A. Bhosale. 2023. A comparison of the performance of SWAT and artificial intelligence models for monthly rainfall–runoff analysis in the Peddavagu River Basin, India. *Aqua Water Infrastruct. Ecosyst. Soc.* 72 (9), 1707–1730. <https://doi.org/10.2166/aqua.2023.048>

Wang, S., G. Huang, B. Baetz and W. Huang. 2016. Probabilistic inference coupled with possibilistic reasoning for robust estimation of hydrologic parameters and piecewise characterization of interactive uncertainties. *J Hydrometeorol* 17(4): 1243–1260. <https://doi.org/10.1175/JHM-D-15-0131.1>

Wen, X., Q. Feng, R.C. Deo, M. Wu, Z. Yin, L. Yang and V.P. Singh. 2019. Two-phase extreme learning machines integrated with the complete ensemble empirical mode decomposition with adaptive noise algorithm for multi-scale runoff prediction problems. *J Hydrology* 570:167–184

Yates, D., J. Sieber, D. Purkey and A. Huber-Lee. 2005. WEAP21- A Demand, Priority, and Preference-Driven Water Planning Model. *Water International*, 30(4), pp.487-500.

Yu, H. and Q. Yang. 2024. Applying Machine Learning Methods to Improve Rainfall–Runoff Modeling in Subtropical River Basins. *Water* 2024, 16, 2199. <https://doi.org/10.3390/w16152199>