Iranian Journal of Rainwater Catchment Systems
Online ISSN: 1531-2783 Print ISSN: 5970-2423

Evaluation of intelligent models in predicting the discharge of Aladyzga and Arbabkandy stations

Fariborz Ahmadzadeh Kaleybar [1], Ahad Molavi[*2], Bahman Mehrvarz Qoje Begloo[3]

1. Assistant Professor, Department of Water Science and Engineering, Ta.C., Islamic Azad University, Tabriz, Iran, Email: f.ahmadzadeh@iau.ac.ir
2. Assistant Professor, Department of Water Science and Engineering, Ta.C., Islamic Azad University, Tabriz, Iran, Email: ahad.molavi@iau.ac.ir
3. Former M.Sc. Student, Department of Water Science and Engineering, Ta.C., Islamic Azad University, Tabriz, Iran, Email: mehrvarz13581365@Gmail.com

ARTICLE INFO

Article type:
Research Paper

Article history
Received: 25 May 2025
Revised: 29 July 2025
Accepted: 31 July 2025
Published online: 05 August 2025

Keywords:
Artificial neural network, Support vector machine, Wavelet transform, Time delay

ABSTRACT

The present study was conducted to evaluate the performance of artificial neural networks, support vector machine models, and their hybrid mode with the wavelet model in predicting the discharge of the Aladyzga and Arbabkandy hydrometric stations located in the Qara Su watershed. Considering the correlation index, the discharge of two months ago and the discharge of one month ago were considered as the input of the runoff model at the Arbabkandy and Aladyzga hydrometric stations, respectively. The optimal state in the artificial neural network and hybrid wavelet-artificial neural network models was achieved in two and five neurons at the Aladyzga station, respectively, and in 12 and one neuron at the Arbabkandy station, respectively. The results indicated that the agreement between the observed runoff and predicted runoff values was high when using the wavelet-artificial neural network combination and the wavelet-support vector machine combination compared to the cases of using the conventional artificial neural network and support vector machine. Thus, at Arbabkandy station, hybridizing the single model of the artificial neural network with the wavelet model increased the R parameter from 0.44 to 0.91 and also reduced the RE and RMSE parameters from 41% and 2.03 $m^3 s^{-1}$ to 23 % and 1.33 $m^3 s^{-1}$, respectively. The NSE and GMER indices in the wavelet-artificial neural network and wavelet-support vector machine models had better acceptance in both stations than in the other models, so that in Arbabkandy station, the values of these indices in the wavelet-artificial neural network model were 0.78 and 0.94, respectively. After the hybrid wavelet-artificial neural network model, which had the best fit and consistency with the observational data, the hybrid wavelet-support vector machine model had good accuracy and efficiency compared to other models used in both stations

Citation: Ahmadzadeh Kaleybar, F., Molavi, A., & Mehrvarz Qoje Begloo, B. (2025). Evaluation of intelligent models in predicting the discharge of Aladyzga and arbabkandy stations. *Iranian Journal of Rainwater Catchment Systems*, 13(2), 39-60.

DOR: 20.1001.1.24235970.1404.13.2.6.8

Publisher: Iranian Rainwater Catchment Systems Association

© Author(s)

***Corresponding author**: Ahad Molavi
Address: Department of Water Science and Engineering, Tabriz.Branch, Islamic Azad University, Tabriz, Iran
Tel: +989144036935
Email: ahad.molavi@iau.ac.ir

[Downloaded from jircsa.ir on 2026-10-31]
[DOR: 20.1001.1.24235970.1404.13.2.6.8]

Iranian Journal of Rainwater Catchment Systems
Online ISSN: 1531-2783 Print ISSN: 5970-2423

Evaluation of intelligent models in predicting the discharge of Aladyzga and Arbabkandy stations

Fariborz Ahmadzadeh Kaleybar [1], Ahad Molavi [*2], Bahman Mehrvarz Qoje Begloo [3]

1. Assistant Professor, Department of Water Science and Engineering, Ta.C., Islamic Azad University, Tabriz, Iran, Email: f.ahmadzadeh@iau.ac.ir
2. Assistant Professor, Department of Water Science and Engineering, Ta.C., Islamic Azad University, Tabriz, Iran, Email: ahad.molavi@iau.ac.ir
4. Former M.Sc. Student, Department of Water Science and Engineering, Ta.C., Islamic Azad University, Tabriz, Iran, Email: mehrvarz13581365@Gmail.com

EXTENDED ABSTRACT

Introduction: Accurate prediction of river discharge in watersheds with limited hydrological data represents a significant challenge in contemporary water resources management. This comprehensive study systematically evaluated and compared the predictive capabilities of four advanced computational models: Artificial Neural Networks (ANN), Support Vector Machines (SVM), and their enhanced hybrid versions incorporating Wavelet Transform (W-ANN and W-SVM). The research focused on monthly discharge forecasting at two strategically important hydrometric stations - Aladyzga and Arbabkandy - located in the Qara Su watershed of northwestern Iran. The primary objectives included: (1) developing autocorrelated prediction models using lagged discharge inputs, (2) quantifying the performance improvement achieved through wavelet-based hybrid modeling approaches, (3) conducting rigorous uncertainty analysis to assess model reliability, and (4) establishing practical guidelines for model selection based on specific watershed characteristics and data availability scenarios.

Methodology: This study employed a comprehensive methodology combining advanced computational techniques with rigorous statistical validation. Monthly discharge data (1999-2023) from both stations underwent quality control, including outlier removal and gap-filling. Optimal time lags were determined through autocorrelation analysis (1-month for Aladyzga, 2-month for Arbabkandy). Four modeling approaches were implemented: ANN, SVM, and their wavelet-enhanced versions (W-ANN, W-SVM) using Daubechies-4 wavelet decomposition. The modeling process followed a 70-15-15 data split (training-validation-testing) with early stopping to prevent overfitting. Performance was evaluated using six metrics (R, RMSE, NSE, RE, GMER, MAE) and a statistical test (t-test). Wavelet processing included signal decomposition, noise reduction, and coefficient reconstruction. Uncertainty was quantified through Monte Carlo simulations (1000 iterations), 95% prediction uncertainty bands (95PPU), and d-factor analysis. All analyses were conducted in MATLAB with standardized hardware for consistent comparisons.

Results and Discussion: The comprehensive analysis yielded several significant findings with important theoretical and practical implications. The W-ANN hybrid model demonstrated exceptional performance at Arbabkandy station, achieving remarkable accuracy metrics (R=0.91, NSE=0.78, RMSE=1.33 $m^3 s^{-1}$) that represented a 107% improvement in correlation coefficient and a 34% reduction in root mean square error compared to the standalone ANN model. At Aladyzga station, while absolute performance metrics were slightly lower due to data limitations, the W-ANN still showed superior results (R=0.50, RMSE=0.15 $m^3 s^{-1}$) with particularly strong performance in predicting peak flows during flood seasons. The wavelet-based models consistently outperformed their conventional counterparts across all evaluation criteria, with average improvements of 62% in R values, 48% in RMSE reduction, and 53% enhancement in NSE scores. Uncertainty quantification revealed that the hybrid models exhibited substantially narrower 95% prediction uncertainty bands (95PPU) and significantly lower d-factor values (0.15-0.20 versus 0.25-0.35 for standalone models), indicating more reliable and stable predictions. The enhanced performance of wavelet hybrids was attributed to their superior ability to: (1) decompose complex discharge signals into interpretable subcomponents, (2)

***Corresponding author**: Ahad Molavi
Address: Department of Water Science and Engineering, Tabriz.Branch, Islamic Azad University, Tabriz, Iran
Tel: +989144036935
Email: ahad.molavi@iau.ac.ir

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]

ISSN (Online): 2783-1531 - ISSN (Print): 2423-5970

effectively separate stochastic noise from deterministic patterns, and (3) capture multi-scale temporal dependencies in hydrological processes. Comparative analysis of computational efficiency showed that while hybrid models required 15-20% more training time, their prediction phase was equally fast, making them practical for operational forecasting.

Conclusion: This study demonstrates that wavelet-based hybrid models, particularly W-ANN, significantly improve discharge prediction accuracy in data-scarce watersheds. The models effectively address key hydrological modeling challenges, including non-stationarity and noise in time series data. The W-ANN showed superior performance at Arbabkandy station, while maintaining computational efficiency for operational use. The finding that optimal model structures differ between stations (W-ANN performing best at Arbabkandy while W-SVM showed competitive results at Aladyzga) underscores the importance of site-specific model selection. These findings provide water managers with reliable tools for flood forecasting and drought monitoring in poorly gauged watersheds. The results highlight the importance of site-specific model selection and suggest wavelet hybrids as a robust alternative to complex physical models in data-limited environments.

Ethical Considerations

Data availability statement: The datasets are available upon a reasonable request to the corresponding author.

Funding: This research has not received any financial support from any organization.

Authors' contribution: Fariborz Ahmadzadeh Kaleybar, Ahad Molavi, and Bahman Mehrvarz Qoje Begloo, as the authors of the paper, conducted all parts of the research and wrote the entire manuscript.

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

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]

Iranian Journal of Rainwater Catchment Systems
مجله علمی سامانه‌های سطوح آبگیر باران ایران
شاپا الکترونیکی: ۲۷۸۳-۱۵۳۱ شاپا چاپی: ۲۴۲۳-۵۹۷۰

ارزیابی مدل‌های هوشمند در پیش‌بینی دبی ایستگاه‌های آلادیزگه و ارباب‌کندی

فریبرز احمدزاده کلیبر[۱]، احد مولوی[۲*]، بهمن مهرورز قوجه بگلو[۳]

۱. استادیار، گروه علوم و مهندسی آب، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران، f.ahmadzadeh@iau.ac.ir

۲. استادیار، گروه علوم و مهندسی آب، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران، ahad.molavi@iau.ac.ir

۳. دانش‌آموخته کارشناسی ارشد، گروه علوم و مهندسی آب، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران، mehrvarz13581365@Gmail.com

مشخصات مقاله

نوع مقاله:
پژوهشی

تاریخچه مقاله
دریافت: ۰۴ خرداد ۱۴۰۴
بازنگری: ۰۷ مرداد ۱۴۰۴
پذیرش: ۰۹ مرداد ۱۴۰۴
انتشار برخط: ۱۴ مرداد ۱۴۰۴

واژه‌های کلیدی:
شبکه عصبی مصنوعی، ماشین بردار پشتیبان، تبدیل موجک، تأخیر زمانی

چکیده

تحقیق حاضر باهدف ارزیابی عملکرد مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و حالت هیبرید آن‌ها با مدل موجک در پیش‌بینی دبی ایستگاه‌های هیدرومتری آلادیزگه و ارباب‌کندی واقع درحوضه قره سو انجام شد. با در نظر گرفتن شاخص همبستگی، در ایستگاه های هیدرومتری ارباب‌کندی و آلادیزگه به‌ترتیب دبی دو ماه قبل و دبی یک ماه قبل به‌عنوان ورودی مدل رواناب در نظر گرفته شدند. حالت بهینه در مدل‌های شبکه عصبی مصنوعی و هیبرید موجک- شبکه عصبی مصنوعی در ایستگاه آلادیزگه به‌ترتیب در دو و پنج نرون و در ایستگاه ارباب‌کندی به‌ترتیب در ۱۲ و یک نرون حاصل شدند. نتایج حاکی از آن بود که تطابق بین مقادیر مشاهداتی رواناب و رواناب پیش‌بینی‌شده در استفاده از ترکیب موجک- شبکه عصبی مصنوعی و نیز ترکیب موجک- ماشین بردار پشتیبان نسبت به حالت‌های استفاده از شبکه عصبی مصنوعی و ماشین بردار پشتیبان مرسوم بالابود. به‌طوری‌که در ایستگاه ارباب‌کندی هیبرید کردن مدل منفرد شبکه عصبی مصنوعی با مدل موجک موجب افزایش پارامتر R از ۰/۴۴ به ۰/۹۱ و نیز کاهش پارامترهای RE و RMSE به‌ترتیب از ۴۱ درصد و ۲/۰۳ مترمکعب بر ثانیه به ۲۳ درصد و ۱/۳۳مترمکعب بر ثانیه شد. علاوه براین، شاخص‌های ضریب نش-ساتکلیف (NSE) و نسبت میانگین هندسی خطا (GMER) در مدل‌های ترکیبی موجک-شبکه عصبی مصنوعی و موجک-ماشین بردار پشتیبان در هر دو ایستگاه، نسبت به سایر مدل‌ها از عملکرد مطلوب‌تری برخوردار بودند. به‌ویژه در ایستگاه ارباب‌کندی، مقادیر این شاخص‌ها برای مدل موجک-شبکه عصبی مصنوعی به‌ترتیب ۰/۷۸ و ۰/۹۴ به‌دست آمد که نشان‌دهنده دقت و قابلیت اطمینان بالای این مدل است. بعد از مدل هیبرید موجک- شبکه عصبی مصنوعی که بهترین تطابق و همخوانی را با داده‌های مشاهداتی داشت، مدل هیبرید موجک- ماشین بردار پشتیبان در هر دو ایستگاه از دقت و کارایی خوبی برخوردار بود.

استناد: احمدزاده کلیبر، فریبرز، مولوی، احد و مهرورز قوجه بگلو، بهمن (۱۴۰۴). ارزیابی مدل‌های هوشمند در پیش‌بینی دبی ایستگاه های آلادیزگه و ارباب‌کندی. *سامانه‌های سطوح آبگیر باران*، ۱۳(۲)، ۳۹-۶۰.

DOR: 20.1001.1.24235970.1404.13.2.6.8

ناشر: انجمن علمی سیستم‌های سطوح آبگیر باران ایران

© نویسندگان

* **نویسنده مسئول:** احد مولوی

نشانی: گروه علوم و مهندسی آب، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

تلفن: ۰۹۱۴۴۰۳۶۹۳۵

پست الکترونیکی: ahad.molavi@iau.ac.ir

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]

مقدمه

ازآن‌جایی‌که سری رواناب ویژگی‌های غیرخطی را نشان می‌دهد، ثبت تناوب و نظم در سری رواناب با استفاده از یک مدل منفرد چالش‌برانگیز است (Kalteh, 2013). مدل‌ها و روش‌های متعددی در شبیه‌سازی جریان رودخانه‌ها مورد استفاده قرار می‌گیرند که عملکرد و موارد به‌کارگیری آن‌ها بسته به ساختار حوضه، داده‌های لازم و در دسترس و نیز هدف شبیه‌سازی از همدیگر متفاوت می‌باشد. جهت شبیه‌سازی رواناب در حوضه‌هایی که دارای آمار و اطلاعات کافی نیستند، به‌کارگیری مدل‌های فیزیکی که به متغیرهای هواشناسی و هیدرولوژیکی بیشتری نیاز دارند مقدور نخواهد بود. روش شبیه‌سازی خود همبسته جریان آبراهه که در آن تنها داده‌های ورودی، دبی‌های تأخیر یافته جریان آبراهه به مدل را تشکیل می‌دهند از رویکردهای راه‌گشا در این‌گونه حوضه‌ها می‌باشد (Chongxun et al., 2023).

در سال‌های اخیر انواع مدل‌های فراکاوشی همچون ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی، مدل ترکیبی موجک–ماشین بردار پشتیبان، نروفازی و مدل هیبریدی موجک–شبکه عصبی مصنوعی کاربرد وسیعی در تحقیقات هیدرولوژی و پدیده‌هایی که الگوریتم مشخصی برای آن‌ها وجود ندارد پیداکرده است (Mugume et al., 2024). علاوه بر این، پیش‌بینی دقیق رواناب رودخانه‌ها به دلیل تغییرات اقلیمی و فعالیت‌های انسانی از اهمیت بالایی برخوردار شده است (Zhang et al., 2025). در همین زمینه، Jain and Kumar (2007) عملکرد روش‌های شبکه عصبی مصنوعی و سری زمانی را در شبیه‌سازی مقادیر جریان ماهانه رودخانه کلرادو تحت سه حالت مورد بررسی قرار دادند. نتایج نشان داد که در هر سه حالت کارایی روش شبکه عصبی از مدل خودهمبسته (AR) بهتر بود. Misra et al. (2009) در تحقیقی نسبت به‌پیش‌بینی رواناب و بار رسوب روزانه، هفتگی و ماهانه حوضه آبریز هند با مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی مبادرت نمودند. نتایج تحقیق نشان داد مدل ماشین بردار پشتیبان در پیش‌بینی رواناب و نیز بار رسوب نسبت به مدل شبکه عصبی مصنوعی دارای کارایی بهتری است. میرزایی و همکاران (۲۰۱۶) هفت معیار توزیع زمانی بارش را با هدف شبیه‌سازی دبی پیک با مدل‌های SCS، CLARK و SNYDER در حوضه آتشگاه مورد ارزیابی قرار دادند. بررسی‌ها نشان داد الگوی بارش WMO در مدل SCS، و الگوی Huff2nd در مدل‌های SNYDER و CLARK دارای نتایج قابل قبول تری هستند. با هدف بررسی تغییرات کاربری اراضی، هیدروگراف سیلاب و دبی جریان حداکثر حوضه آتشگاه از زیرحوضه‌های یدی‌بولیک چای تحقیقی به‌وسیله توکلی قاضی جهانی و همکاران (۲۰۱۸) صورت گرفت. در پژوهش فوق هشت تابع توزیع احتمالاتی با استفاده از سه معیار آماری ارزیابی شدند. نتایج حاکی از کاهش سطح مراتع و افزایش اراضی مسکونی و کشاورزی در طی ۴۳ سال (۱۳۴۷ تا ۱۳۹۰) بود. در ادامه، Kisi et al. (2012) کارایی و عملکرد مدل‌های نروفازی ANN و SVM را در شبیه‌سازی دبی روزانه در دو ایستگاه هیدرومتری واقع در شمال غرب ترکیه مورد بررسی قراردادند. مطابق اظهارات ایشان مدل‌های ANN و نروفازی به‌ترتیب بالاترین دقت را در شبیه‌سازی دبی روزانه در ایستگاه‌ها داشتند.

کاکائی لفدانی و همکاران (۲۰۱۳) برای پیش‌بینی دبی جریان روزانه حوضه اسکندری سه مدل ماشین بردار پشتیبان، سیستم استنتاج فازی– عصبی (ANFIS) و مدل هیدرولوژیکی مفهومی Mike11/NA را مورد مطالعه قراردادند. نتایج تحقیق حاکی از آن بود که مدل ماشین بردار پشتیبان با بیشترین ضریب همبستگی و کمترین میانگین مربعات خطا عملکرد بهتری نسبت به دو مدل دیگر داشت. Kalteh et al. (2013) در پژوهشی ترکیب مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی با تبدیل موجک جهت شبیه‌سازی دبی ماهانه مورد مطالعه قرار داده و به این نتیجه دست یافتند که کارایی هر دو مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی در ترکیب با تبدیل موجک نسبت به مدل‌های SVR و ANN مجزا، دارای کارایی بهتری می باشند. نجیب‌زاده و همکاران (۲۰۲۰) برای شبیه‌سازی رواناب در زیر حوضه سد صفارود واقع در حوضه آبریز هلیل‌رود با

[Downloaded from jircsa.ir on 2026-10-31]
[DOR: 20.1001.1.24235970.1404.13.2.6.8]

استفاده از مدل شبکه عصبی پرسپترون چندلایه (MLP)، شبکه عصبی تابع شعاع مدار (RBF) و همبستگی ماشین بردار پشتیبان با توابع کرنل خطی (Linear SVR) تحقیقی به انجام رساندند. ایشان داده‌های روزانه ایستگاه آب‌سنجی هنجان را طی دوره آماری ۱۳۹۴-۱۳۸۵ در تحقیقاتشان مورد استفاده قراردادند. نتایج پژوهش آنان نشان از مقبولیت مدل Linear SVR5 برای پیش‌بینی رواناب ایستگاه هنجان با مقادیر شاخص‌های خطای MAE، RMSE و R (ضریب همبستگی) به‌ترتیب معادل با ۰/۰۳۲، ۰/۰۲۲۹ و ۰/۹۶۷ بود. دهقانی و همکاران (۲۰۲۲) در پژوهشی عملکرد مدل هیبریدی ماشین بردار پشتیبان – موجک را جهت تخمین دبی رودخانه حوضه آبریز دز بر اساس آمار هیدرومتری روزانه ایستگاه‌های واقع در بالادست سد در طی سال‌های آماری ۱۳۹۷-۱۳۸۷ مورد بررسی قرار داده و نتایج آن را با مدل ماشین بردار پشتیبان مقایسه نمودند. نتایج تحقیق آنان حاکی از مقبولیت ساختارهای ترکیبی در مدل‌سازی رواناب بوده و بر اساس معیارهای ارزیابی مدل هیبریدی ماشین بردار پشتیبان–موجک عملکرد بهتری در پیش‌بینی جریان داشت.

Kwon et al. (2020) یک مدل ترکیبی ماشین بردار پشتیبان حداقل مربعات مخزن (LSSVM) را به‌منظور توصیف جنبه‌های فرآیند بارش- رواناب به‌کار بردند. ایشان نقش داده‌های رطوبت خاک ماهواره‌ای (SM) را در مدل‌سازی بارش–رواناب بررسی کرده و به این نتیجه رسیدند که حالات SM استنباط‌شده از ESA CCISWI ابزار مؤثری برای توصیف پویایی زمانی SM ارائه می‌کند. Samantaray et al. (2022) مدل ترکیبی SVM-SSA (ماشین بردار پشتیبان با الگوریتم ازدحام سالپ) و مدل‌های SVM معمولی و شبکه عصبی مصنوعی (ANN) برای پیش‌بینی رواناب در حوضه رودخانه بایتارانی، اودیشا، هند را مورد بررسی قرار دادند. نتایج آزمون نشان داد که مدل ترکیبی دقت پیش‌بینی بهتری را در مقایسه با روش‌های مرسوم داشته و می‌تواند در مدل‌سازی برای فرآیند بارش–رواناب و پیش‌بینی رواناب قابل توصیه باشد. Chongxun et al. (2023) برای افزایش دقت پیش‌بینی، یک مدل ترکیبی تجربی تبدیل موجک–بهینه‌سازی ازدحام ذرات–ماشین بردار پشتیبان (EWT-PSO-SVM) مبتنی بر «تجزیه–پیش‌بینی–بازسازی» برای پیش‌بینی رواناب پیشنهاد نموده و اثربخشی آن را در حوضه کارست رودخانه چنگبی مورد بررسی قراردادند. نتایج تحقیق مشخص نمود که مدل EWT–PSO–SVM از نظر شاخص رتبه‌بندی ترکیبی از هر دو مدل PSO–SVM و مدل SVM بهتر عمل می‌کند. علاوه بر این، ایشان برای تأیید پایداری عملکرد مدل توسعه‌یافته نیز با مدل‌های PSO-SVM و SVM تحت ساختارهای داده ورودی مختلف را مورد بررسی قراردادند. مقایسه نشان داد که مدل هیبریدی EWT-PSO-SVM دارای برتری عملکرد قوی بوده و یک مدل مؤثر است که می‌تواند برای پیش‌بینی رواناب منطقه کارست اعمال شود.

Agheli et al. (2024) در مطالعه ای مبتنی بر مدل‌های هوشمند شبکه عصبی پرسپترون چند لایه- MLP و داده‌های ۱۵۳ چاه در شمال غربی ایران، در نظر گرفتن ساختار مکانی از طریق افزودن فاصله تا چاه های مشاهده ای به همراه داده‌های رسانایی الکتریکی (EC) به‌عنوان ورودی مدل، پیشنهاد شد. نتایج نشان داد استفاده از این رویکرد مکانی و تعداد بهینه چاه‌های همسایه (۸ تا ۲۰ چاه) منجر به تخمین دقیق تر شوری می شود. عمکرد مدل‌های هوشمند توسعه یافته با مقادیر ضریب تعیین ۰/۵۴ الی ۰/۷۳ و کارایی (NSE) از ۰/۵۳ الی ۰/۷۲ نسبت به مدل‌های فاقد ورودی، بهبود معناداری داشت. Mugume et al. (2024) در تحقیقی با به‌کارگیری زبان برنامه‌نویسی پایتون از یک مدل شبکه عصبی مصنوعی که ترکیبی از HEC-HMS و شبکه عصبی پیش‌خور (FFNN) بود، برای شبیه‌سازی جریان رواناب در حوضه آبریز رودخانه مایانجا در اوگاندا مرکزی استفاده نمودند. نتایج مطالعه نشان داد که مدل هیبریدی HEC-HMS-ANN در طول واسنجی و اعتبارسنجی با R^2=0.99 در مقایسه با مدل‌های منفرد HEC-HMS با R^2=0.5 و MIKE HYDRO با R^2=0.42 و مدل ANN با R^2=0.56 عملکرد بهتری داشت. Zhang et al. (2025) با ترکیب مدل‌های یادگیری ماشین شامل LSTM، SVM، جنگل تصادفی و شبکه عصبی مصنوعی و همچنین استفاده از تکنیک‌های پیش‌پردازش مانند EMD، VMD و موجک، به بهبود دقت پیش‌بینی رواناب

[Downloaded from jircsa.ir on 2026-10-31]
[DOR: 20.1001.1.24235970.1404.13.2.6.8]

پرداختند. نتایج تحقیق نشان داد که مدل LSTM در مقایسه با سایر مدل‌های تک‌عاملی عملکرد بهتری داشته و مدل ترکیبی VMD–LSTM با دقت بالا (RMSE=52.14، NSE=0.9) به‌عنوان بهترین مدل شناخته شدند. با توجه به نتایج و کارایی قابل‌قبول به‌کارگیری روش‌های SVM و ANN و همچنین ترکیب آن‌ها با روش موجک و با نظر گرفتن آنکه مطالعه جامعی در خصوص ارزیابی عملکرد مدل‌های مذکور در پیش‌بینی رواناب رودخانه ها آلادیزگه و ارباب‌کندی که به‌عنوان منابع آب حیاتی، تأمین‌کننده آب آشامیدنی و پشتیبانی‌کننده فعالیت‌های کشاورزی در منطقه و یک قطب کلیدی کشاورزی عمل می کنند، انجام‌نشده است. تحقیق حاضر باهدف ارزیابی عملکرد مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان، ترکیب موجک–شبکه عصبی مصنوعی و ترکیب موجک–ماشین بردار پشتیبان در شبیه‌سازی خود همبسته جریان ماهانه رواناب ایستگاه‌های هیدرومتری آلادیزگه و ارباب‌کندی واقع در حوضه قره سو انجام شد.

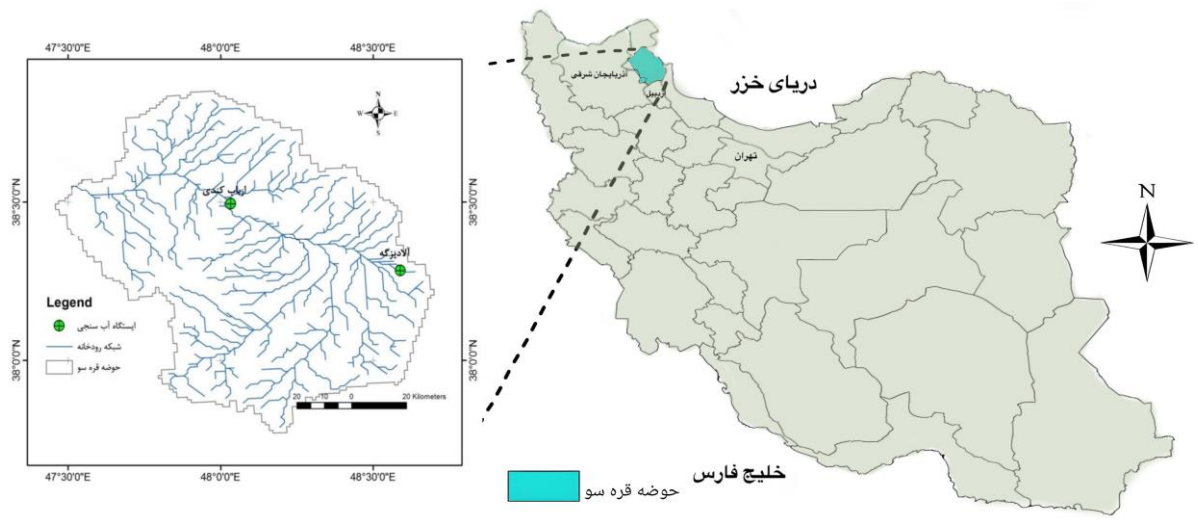
مواد و روش تحقیق

منطقه مورد مطالعه

محل مورد مطالعه ایستگاه‌های آب‌سنجی آلادیزگه و ارباب‌کندی واقع در حوضه آبریز قره‌سو بود. حوضه قره‌سو یکی از زیرحوضه‌های حوضه ارس است که در قسمت مرکزی استان اردبیل قرارگرفته و بخش کوچکی از آن در استان آذربایجان شرقی واقع‌شده است. این حوضه در مختصات جغرافیایی ′۳۲ °۴۷ تا ′۴۱ °۴۸ طول شرقی و ′۴۷ ° ۳۷ تا ′۵۲ °۳۸ عرض شمالی قرارگرفته و مساحت آن بالغبر ۷۷۰۶ کیلومترمربع است. اختلاف ارتفاع پست‌ترین نقطه حوضه (۷۷۴ متر) و بلندترین نقطه آن در قله کوه سبلان (۴۷۸۶ متر) ۴۰۱۲ متر می‌باشد. اقلیم حوضه در محدوده مدیترانه‌ای و نیمه‌خشک قرار دارد. حدود ۴۲ درصد بارندگی حوضه در فصل بهار روی می‌دهد. کمترین میزان بارندگی فصلی با ۱۰ درصد در تابستان اتفاق می‌افتد. رژیم آبدهی به تبعیت از میزان و نوع بارندگی افزایش فراوانی از اواسط سال آبی یعنی اواخر اسفند تا اواسط بهار داشته و سپس تا اواخر تابستان کاهش می‌یابد. دلیل این امر ناشی از ذوب برف زمستانی و بارش‌های سنگین بهاره در مقایسه با بارش‌های کم تابستانه و نیز بهره‌برداری‌های انسانی از آب رودها می‌باشد. شبکه گسترده آب‌های سطحی و زیرزمینی موجود در حوضه قره‌سو موجب شده تا این حوضه از نظر تأمین منابع آب استان اردبیل از جایگاه مهم برخوردار شود (Esfandiari and Qarachoorloo, 2023). در این پژوهش، از داده‌های ماهانه رواناب ایستگاه‌های آب‌سنجی آلادیزگه و ارباب‌کندی طی دوره آماری ۱۳۷۸–۱۴۰۲ استفاده شده است. این داده‌ها از سازمان آب‌منطقه‌ای استان اردبیل استخراج شده و پس از اعمال کنترل‌های کیفی و حذف نقاط پرت، برای شبیه‌سازی رواناب ماهانه به‌صورت خودهمبسته با به‌کارگیری مدل‌های هوشمند و هوشمند–هیبریدی مورد استفاده قرار گرفته‌اند. برای اطمینان از صحت داده‌ها، آزمون‌های استاندارد کنترل کیفیت، شامل آزمون همگنی و آزمون ناپیوستگی، انجام شد. در ایستگاه آلادیزگه، حدود ۵ درصد از داده‌ها به دلیل مشکلات فنی در ثبت،ناقص بودند که با روش‌های درونیابی خطی و همبستگی با ایستگاه‌های مجاور بازسازی شدند. در مقابل، داده‌های ایستگاه ارباب‌کندی کامل بوده و هیچ نقطه گم‌شده‌ای نداشتند. موقعیت ایستگاه‌های مذکور در حوضه قره‌سو در شکل (۱) ارائه‌شده است.

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]



شکل ۱- موقعیت ایستگاه‌های مورد مطالعه در حوضه آبریز قره‌سو

Figure 1- Location of the study stations in the Qara Su watershed

کاربرد ماشین بردار پشتیبان

در این مدل صفحه بهینه جداکننده در حالت غیرخطی به‌صورت رابطه (۱) خواهد بود. تابع لاگرانژ دوگان نیز به صورت رابطه (۲) است.

$$f(x) = \phi(x)^T w + w_0 \quad (۱)$$

$$L_d = \sum_{i=1}^{n} a_i - \frac{1}{2}\sum_{i=1}^{n}\sum_{j=1}^{n} a_i a_j y_i y_j \left(\phi(x_i), \phi(x_j)\right) \quad (۲)$$

در روابط بالا $\phi(x)$ تابع هسته می‌باشد. تابع پایه شعاعی(RBF)، تابع چندجمله‌ای درجه d و تابع سیگموئید(پرسپترون) سه تابع هسته‌ای (کرنل) می‌باشند که به‌طور متداول در SVM استفاده می‌شوند (Kavzoglu and Colkesen 2009). به‌منظور تخمین جریان با استفاده از مدل ماشین بردار پشتیبان می‌توان انواع تابع کرنل را مورد بررسی قرارداد، درواقع انتخاب تابع مناسب در استفاده از این مدل بسیار حائز اهمیت بوده و نتایج مختلفی را به همراه خواهد داشت. در مطالعات شبیه‌سازی جریان و بارش- رواناب عمدتاً از مدل تابع کرنل RBF استفاده می‌شود (Eskandari and Nouri, 2010). فرآیند محاسبات این مدل با کد نویسی در محیط متلب صورت گرفته است. روابط تابع پایه شعاعی(RBF)، تابع چندجمله‌ای درجه d و تابع سیگموئید (پرسپترون) به‌ترتیب در روابط (۳) الی (۵) ارائه‌شده است.

$$K(x, x_i) = \exp\left(-\|x - x_i\|^2 / \sigma^2\right) \quad (۳)$$

$$K(x, x_i) = (t + (x, x_i))^d \quad (۴)$$

$$K(x, x_i) = tanh(k_1(x, x_i) + k_2 \quad (۵)$$

کاربرد شبکه عصبی مصنوعی

از آن‌جایی‌که برای افزایش کارایی و سرعت اجرای شبکه‌های عصبی مصنوعی باید از داده‌های نرمال‌شده استفاده نمود (Zare Abyaneh et al., 2010) ابتدا داده‌های رواناب با استفاده از رابطه (۶) در محدوده [1,1-] قرارگرفته و نرمال شدند.

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (۶)$$

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]

برای شبیه‌سازی جریان با استفاده از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون چندلایه با یک‌لایه پنهان با تعداد نرون‌های متعدد و از تابع تانژانت سیگموئید جهت نگاشت اطلاعات از لایه ورودی به لایه پنهان و از تابع محرک خطی برای نگاشت اطلاعات از لایه پنهان به لایه خروجی استفاده شد. واسنجی شبکه‌های پرسپترون چندلایه با الگوریتم آموزش پس انتشار خطای لونبرگ- مارکوارت (همگرایی سریع و دقیق) انجام و حداکثر تعداد تکرار در فرآیند یادگیری شبکه۱۰۰۰ در نظر گرفته شد. تعداد نرون‌های موجود در لایه پنهان با سعی و خطا تعیین شد. روند کار با تعداد نرون‌های اندک شروع و با افزودن نرون‌ها تا حداکثر ۲۰ نرون ادامه پیدا کرد.

کاربرد تحلیل موجک

یک موج به‌عنوان تابع نوسان‌کننده تعریف می‌شود. تابع سینوسی یک موج است. برای این توابع تحلیل فوریه به کار گرفته می‌شود. در حقیقت تحلیل فوریه یک تحلیل موجی می‌باشد که در آن توابع یا سیگنال‌ها برحسب توابع سینوسی و کسینوسی بسط داده‌شده‌اند(Misiti, et al,1996) . تابع تحلیل $\phi(x)$ در صورت صدق کردن در شرایط دوگانه (الف) و (ب) به‌عنوان یک تابع موجک در نظر گرفته می‌شود.

الف- موجک دارای انرژی محدود است.

$$E=\int_{-\infty}^{+\infty}|\phi(t)|^2dt\langle\infty \qquad (۷)$$

ب- اگر $\phi(f)$ تبدیل فوریه $\phi(t)$ باشد باید رابطه (۸) برقرار باشد.

$$\int_{0}^{+\infty}\frac{|\varphi(f)|^2}{f}df\langle\infty \qquad (۸)$$

کاربرد هیبرید موجک-ماشین بردار پشتیبان

در مدل ترکیبی موجک و ماشین بردار پشتیبان پس از تبدیل سری داده‌ها به چند زیر سری با کاربرد تحلیل موجکی و انتخاب موجک مادر دابچیز نوع چهار به‌عنوان پرکاربردترین موجک مادر (Taie et al., 2024) زیر سری‌های به‌دست‌آمده به‌عنوان ورودی ماشین بردار پشتیبان در نظر گرفته شدند. با توجه به تعداد داده‌ها تجزیه سری در دو سطح انجام و با توابع کرنل پایه شعاعی، چندجمله‌ای و خطی عملیات ادامه یافت.

کاربرد هیبرید موجک- شبکه عصبی

در این روش تجزیه سری زمانی داده‌های ورودی آموزش و آزمون با استفاده از تحلیل موجکی به زیر سری‌ها انجام یافت. اولین مرحله تجزیه سری‌ها، انتخاب موجک مادر می‌باشد که با عنایت به کاربرد گسترده موجک دابچیز نوع چهارم از این موجک استفاده شد. تعداد سطوح تجزیه معمولاً جزء صحیح لگاریتم طول سری منظور می‌شود (Taie et al., 2024). بعد از تعیین زیر سری‌های ایجادشده با تحلیل موجکی به‌عنوان ورودی شبکه عصبی مصنوعی، نرمال نمودن داده‌ها به انجام رسید. برای مشخص نمودن تعداد بهینه نرون‌های لایه پنهان شبکه عصبی مصنوعی، کارایی ۱ تا۲۰ نرون در لایه پنهان ارزیابی شد. در این روش آموزش شبکه‌های پرسپترون چندلایه به‌وسیله الگوریتم آموزش پس انتشار خطای لونبرگ- مارکوارت و با حداکثر تعداد تکرارها در عملیات یادگیری شبکه ۱۰۰۰ انجام شد. کلیه محاسبات این تحقیق از طریق کد نویسی و در محیط نرم‌افزار متلب انجام‌شده است.

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]

تأخیر زمانی دبی‌های ورودی

برای مدل بندی رواناب از متغیر اصلی دبی و تأخیرهای زمانی آن به‌عنوان ورودی مدل استفاده شد. جهت تعیین میزان تأخیر قابل‌قبول از آزمون فرض ضریب همبستگی به شرح زیر استفاده به عمل آمد.

همبستگی معنی‌دار نمی‌باشد: $H_0 : \rho = 0$

همبستگی معنی‌دار می‌باشد: $H_1 : \rho \neq 0$

که ρ ضریب همبستگی برای جامعه است. در این راستا از آماره k طبق رابطه (۹) استفاده به عمل آمد.

$$k = r.\left(\frac{1-r^2}{n-2}\right)^{-1/2} \quad (۹)$$

در این رابطه r ضریب همبستگی برای نمونه و n تعداد داده‌ها می‌باشد. هرگاه قدر مطلق k محاسبه‌شده از مقدار k جدول مربوط به سطح اطمینان ۹۵ درصد با درجه آزادی n-2 بزرگ‌تر باشد، در این صورت ضریب همبستگی معنی‌دار خواهد بود. مقدار k مربوط به سطح اطمینان ۹۵ درصد با درجه آزادی ۱۰۰ در جدول احتمالات ۱/۹۸+ و ۱/۹۸- می‌باشد، لذا چنانچه در هر سری رابطه (۱۰) برقرار گردد، همبستگی معنی‌دار خواهد بود.

$$|k_{cal}| \geq 1.98 \quad (۱۰)$$

ازاین‌رو ضریب همبستگی بین رواناب در زمان t و رواناب با تأخیرهای زمانی یک ماه، دو ماه، سه ماه و ... محاسبه و مقدار k متناظر هرکدام جهت تشخیص معنی‌دار بودن آن با رابطه (۱۰) مقایسه می‌شود. درصورتی‌که r رواناب با هر یک از تأخیرهای در نظر گرفته‌شده بزرگ‌تر از ۰/۲ یا کوچک‌تر از ۰/۲- حاصل شود، گویای معنی‌دار بودن همبستگی بوده و می‌توان از آن به‌عنوان متغیر ورودی استفاده نمود.

معیارهای ارزیابی عملکرد مدل‌ها

مقادیر رواناب‌های حاصل از چهار مدل ماشین بردار پشتیبان، شبکه عصبی مصنوعی، ترکیب موجک و شبکه عصبی مصنوعی و ترکیب موجک با ماشین بردار پشتیبان تحت شاخص‌های آماری NSE (ضریب نش-ساتکلیف یا کارایی)، RE (خطای نسبی)، GMER (نسبت خطای متوسط هندسی) RMSE (جذر میانگین مربعات خطا)، MAE (میانگین خطای مطلق)،R (ضریب همبستگی) و نیز آزمون t با مقادیر مشاهداتی مورد ارزیابی عملکرد قرار گرفتند (Erich et al., 2022).

$$R = \frac{\sum_{i=1}^{N}(Q_{xi}-\overline{Q}_x)(Q_{yi}-\overline{Q}_y)}{\sqrt{\sum_{i=1}^{N}(Q_{xi}-\overline{Q}_x)^2}\sqrt{\sum_{i=1}^{N}(Q_{yi}-\overline{Q}_y)^2}} \quad (۱۱)$$

$$RMSE = \left(\sum_{i=1}^{n}\left(Q_{y_i}-Q_{xi}\right)^2/n\right)^{1/2} \quad (۱۲)$$

$$MAE = \left(\sum_{i=1}^{n}\left|Q_{y_i}-Q_{xi}\right|/n\right) \quad (۱۳)$$

$$RE = \left(\sum_{i=1}^{n}\left|Q_{y_i}-Q_{xi}\right|/\sum_{i=1}^{n}Q_{xi}\right) \quad (۱۴)$$

$$GMER = EXP\left(\frac{1}{N}\sum_{i=1}^{n}Ln\left(\frac{Q_{xi}}{Q_{y_i}}\right)\right) \quad (۱۵)$$

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]

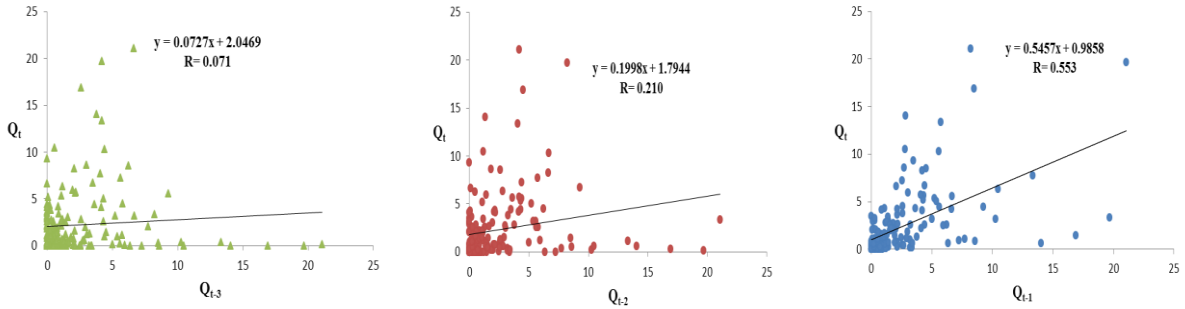
$$NSE = 1 - \left(\frac{\sum_{i=1}^{n} \left(Q_{y_i} - Q_{x_i} \right)^2}{\sum_{i=1}^{N} \left(Q_{xi} - \overline{Q}_x \right)^2} \right) \quad (۱۶)$$

در این روابط Qxi و Qyi، به‌ترتیب مقادیر مشاهداتی و محاسباتی دبی در گام زمانی iام، n تعداد داده‌ها، $\overline{Q_x}$ و $\overline{Q_y}$ نیز میانگین مقادیر مشاهداتی و محاسباتی دبی می‌باشند. کوچک بودن شاخص‌های RE، RMSE و MAE بر دقت بالای مدل دلالت خواهد داشت. GMER بزرگتر از یک نشان از بیش برآوردی و کمتر از یک گویای کم برآوردی مدل خواهد بود. هر چه این شاخص به عدد یک نزدیک باشد دال بر دقت بالای آن است (Raoof et. al, 2022).

نتایج و بحث

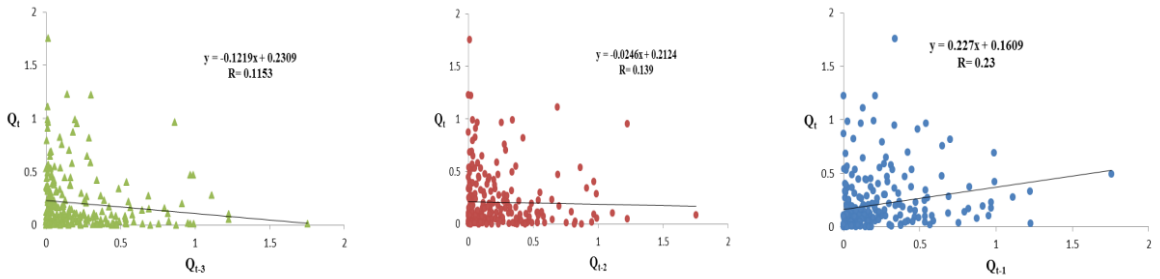
تعیین تأخیرهای قابل‌قبول رواناب

ترکیب مناسب ورودی هر چهار مدل شبکه عصبی، ماشین بردار پشتیبان، مدل هیبرید موجک- عصبی و مدل هیبرید موجک- ماشین بردار پشتیبان با لحاظ تعداد تأخیرهای لازم دبی جریان در دو ایستگاه آب‌سنجی ارباب‌کندی و آلادیزگه انجام شد. نتایج به‌دست‌آمده از ترکیب مزبور در شکل‌های (۲) و (۳) ارائه‌شده است.



شکل ۲- مقایسه رواناب حاضر با زمان‌های تأخیر یک الی سه ماه ایستگاه هیدرومتری ارباب‌کندی

Figure 2- Comparison of current runoff with one to three month delay times at Arbabkandy hydrometric station



شکل ۳- مقایسه رواناب حاضر با زمان‌های تأخیر یک الی سه ماه ایستگاه هیدرومتری آلادیزگه

Figure 3- Comparison of current runoff with one to three month lag times at the Aladyzga hydrometric station

در شکل‌های فوق Q_{t-1}، Q_{t-2} و Q_{t-3} به‌ترتیب مقادیر دبی جریان با یک الی سه ماه تأخیر می‌باشند. به‌طوری‌که از شکل‌های (۲) و (۳) مشهود است رواناب ماه حاضر در ایستگاه هیدرومتری ارباب‌کندی با یک و همچنین دو تأخیر(دو ماه قبل) همبستگی معنی‌دار نشان می‌دهد؛ بنابراین در این ایستگاه جهت مدل‌سازی رواناب دبی دو ماه قبل به‌عنوان ورودی مدل

[Downloaded from jircsa.ir on 2026-10-31]
[DOR: 20.1001.1.24235970.1404.13.2.6.8]

رواناب منظور شد. در ایستگاه آلادیزگه (شکل ۲) رواناب ماه حاضر با یک تأخیر (رواناب یک ماه قبل) همبستگی معنی‌دار دارد. بر این اساس جهت مدل‌سازی رواناب در ایستگاه آب‌سنجی آلادیزگه دبی یک ماه قبل به‌عنوان ورودی مدل رواناب انتخاب شد.

بررسی عملکرد و کارایی مدل‌ها

پس از انجام مدل‌سازی پیش‌بینی رواناب با هر چهار روش شبکه عصبی مصنوعی (ANN) و هیبرید تبدیل موجک – شبکه عصبی، ماشین بردار پشتیبان و ترکیب موجک – ماشین بردار پشتیبان انجام و نتایج با داده‌های مشاهداتی مورد ارزیابی قرار گرفت. در جدول های (۱) و (۲) معیارهای آماری R, RMSE, NSE, RE, GMER مربوط به مدل‌های شبکه عصبی مصنوعی و هیبرید تبدیل موجک –شبکه عصبی مصنوعی به ازای هرکدام از نرون‌ها در مرحله صحت سنجی ارائه‌شده است. تعیین دقیق تعداد بهینه نورون‌های لایه پنهان با بهره‌گیری از روش اعتبارسنجی متقابل و بر مبنای شاخص‌های آماری ذکرشده صورت گرفت. در این فرآیند، داده‌ها به دو بخش مجزای آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم‌بندی شدند و کارایی مدل‌های مختلف با تغییر تعداد نورون‌ها در بازه ۱ تا ۲۰ مورد مقایسه قرار گرفت. حالت بهینه زمانی انتخاب شد که مدل به مقادیر مطلوب در معیارهای ارزیابی شامل حداقل خطای ریشه میانگین مربعات (RMSE)، حداقل خطای مطلق میانگین (MAE)، و همچنین حداکثر ضریب همبستگی (R) و کارایی نش–ساتکلیف (NSE) دست یافت. این روش اگرچه ماهیتی تکرارشونده و مبتنی بر آزمون و خطا دارد، اما با اتکا به مبانی آماری و تقسیم‌بندی اصولی داده‌ها اجرا شده است.

جدول ۱- مقادیر شاخص‌های آماری R, NSE, RE, GMER و RMSE مدل‌های ANN و W-ANN در ایستگاه آلادیزگه

Table 1- R, NSE, RE, GMER and RMSE statistical indices values of ANN and W-ANN models at Aladyzga station
Note: ANN: Artificial Neural Networks, W-ANN: Wavelet-Artificial Neural Networks

نرون	آلادیزگه									
	WAV –ANN					ANN				
	R	RMSE	RE	GMER	NSE	R	RMSE	RE	GMER	NSE
1	0.45	0.169	25.1	1.05	0.38	0.29	0.18	45.20	1.40	0.08
2	0.49	0.163	24.3	1.03	0.42	0.36	0.18	44.00	1.41	0.12
3	0.49	0.172	26.4	1.07	0.40	0.36	0.19	46.10	1.38	0.10
4	0.46	0.175	27.8	1.08	0.37	0.29	0.19	47.30	1.42	0.09
5	0.50	0.153	24.0	1.08	0.45	-0.15	0.27	50.50	1.50	-0.20
6	0.40	0.187	28.5	1.10	0.32	0.29	0.19	46.40	1.39	0.07
7	0.45	0.164	25.7	1.06	0.39	-0.11	0.19	48.70	1.45	-0.15
8	0.47	0.169	26.2	1.09	0.41	0.35	0.18	44.80	1.37	0.11
9	0.39	0.197	29.3	1.12	0.30	0.16	0.20	49.20	1.48	0.02
10	0.44	0.176	27.1	1.07	0.36	0.09	0.24	51.00	1.52	-0.05
11	0.35	0.177	28.9	1.11	0.28	-0.13	0.23	52.30	1.55	-0.18
12	0.43	0.204	30.2	1.15	0.31	0.27	0.19	45.60	1.36	0.06
13	0.47	0.168	25.9	1.04	0.40	0.16	0.21	47.90	1.43	0.01
14	0.37	0.213	31.5	1.18	0.26	0.06	0.20	48.50	1.44	-0.03
15	0.41	0.198	28.7	1.09	0.34	0.16	0.20	46.80	1.40	0.03
16	0.39	0.176	27.5	1.08	0.33	0.13	0.22	49.00	1.47	-0.01
17	0.45	0.178	26.8	1.06	0.38	0.16	0.22	47.50	1.42	0.04
18	0.37	0.177	27.9	1.07	0.30	0.14	0.19	45.90	1.38	0.05
19	0.41	0.192	28.4	1.10	0.35	0.14	0.23	50.20	1.49	-0.08
20	0.43	0.177	26.5	1.05	0.37	0.12	0.27	53.10	1.57	-0.25

برپایه جدول (۱) در به‌کارگیری مدل شبکه عصبی مصنوعی تعداد دو نرون انتخاب شد؛ زیرا در این حالت تقریبا شاخص‌های آماری R، RMSE، RE، GMER و NSE به‌ترتیب با مقادیر ۰/۱۸مترمکعب بر ثانیه، ۰/۳۵۷، ۴۴، ۱/۴۱ و ۰/۱۳ حالت بهینه را ایجاد کرده اند. در به‌کارگیری مدل هیبریدی موجک– شبکه عصبی مصنوعی به دلیل بهینه بودن مقادیر

[Downloaded from jircsa.ir on 2026-10-31]
[DOR: 20.1001.1.24235970.1404.13.2.6.8]

شاخص‌های آماری فوق استفاده از پنج نرون انتخاب شد، به‌طوری‌که شاخص‌های RMSE و R به‌ترتیب برابر با ۰/۱۵۳ مترمکعب بر ثانیه و ۰/۴۹۵ حاصل شده‌اند. بدین‌سبب موارد فوق در محاسبات مدنظر قرار داده شدند. مدل هیبریدی موجک- شبکه عصبی مصنوعی نسبت به مدل شبکه عصبی مصنوعی منفرد از دقت بالاتری در شبیه‌سازی رواناب ایستگاه آلادیزگه برخوردار بود.

جدول ۲- مقادیر شاخص‌های آماری R, NSE, RE, GMER و RMSE مدل‌های ANN و W-ANN در ایستگاه ارباب‌کندی

Table 2- R, NSE, RE, GMER and RMSE statistical indices values of ANN and W-ANN models at Arbabkandy station

Note: ANN: Artificial Neural Networks, W-ANN: Wavelet-Artificial Neural Networks

ارباب‌کندی

نرون	WAV-ANN					ANN				
	R	RMSE	RE	GMER	NSE	R	RMSE	RE	GMER	NSE
1	0.91	1.334	23.0	0.94	0.78	0.36	2.24	42.10	1.35	0.12
2	0.78	1.457	25.2	0.95	0.65	0.28	2.26	43.50	1.37	0.08
3	0.82	1.561	26.8	0.97	0.70	0.39	2.13	41.00	1.33	0.15
4	0.81	1.518	25.9	0.96	0.68	0.39	2.30	44.20	1.39	0.14
5	0.81	1.342	24.1	0.93	0.75	0.30	2.55	46.80	1.45	0.09
6	0.36	2.168	35.7	1.22	0.30	0.26	2.57	47.50	1.47	0.07
7	0.80	1.485	25.5	0.94	0.72	0.35	2.51	45.30	1.42	0.13
8	0.79	1.441	24.8	0.93	0.74	0.39	2.11	40.70	1.32	0.16
9	0.65	1.931	31.2	1.15	0.50	0.39	2.24	43.10	1.36	0.14
10	0.74	1.504	26.3	0.98	0.62	0.31	2.44	45.90	1.43	0.10
11	0.73	1.548	27.5	1.02	0.60	0.32	2.67	48.20	1.49	0.06
12	0.75	1.506	24.0	0.94	0.70	0.44	2.04	41.00	1.31	0.18
13	0.74	1.492	23.8	0.93	0.71	-0.04	4.71	62.50	1.78	-0.30
14	0.44	2.242	38.5	1.28	0.35	0.23	2.96	51.30	1.55	0.03
15	0.73	1.512	26.0	0.97	0.63	0.13	3.66	55.70	1.65	-0.12
16	0.69	1.587	28.3	1.05	0.55	0.41	2.34	44.50	1.40	0.15
17	0.79	1.545	25.7	0.96	0.73	0.29	2.58	46.20	1.44	0.11
18	0.70	1.618	29.1	1.08	0.57	0.13	3.50	54.80	1.63	-0.15
19	0.36	2.362	42.7	1.35	0.25	0.17	6.50	68.30	1.92	-0.50
20	0.73	1.494	24.5	0.94	0.64	0.23	3.04	50.50	1.53	0.02

بر اساس جدول (۲) با توجه به آنکه در مدل شبکه عصبی مصنوعی در ایستگاه هیدرومتری ارباب‌کندی، شاخص‌های آماری RMSE، R، RE، GMER و NSE به‌ترتیب با مقادیر ۰/۴۴۳مترمکعب بر ثانیه، ۲/۰۳۵، ۴۱، ۱/۳۱ و ۰/۱۸ در استفاده از ۱۲ نرون حالت بهینه داشتند، مقادیر متناظر در محاسبات به‌کار برده شدند. در مدل هیبریدی موجک- شبکه عصبی مصنوعی نیز به دلیل بهینه بودن شاخص‌های آماری فوق در استفاده از یک نرون این حالت انتخاب شد. به‌طوری‌که در این شرایط شاخص‌های NSE و R به‌ترتیب ۰/۷۸ و ۰/۹۰۹ حاصل شدند.

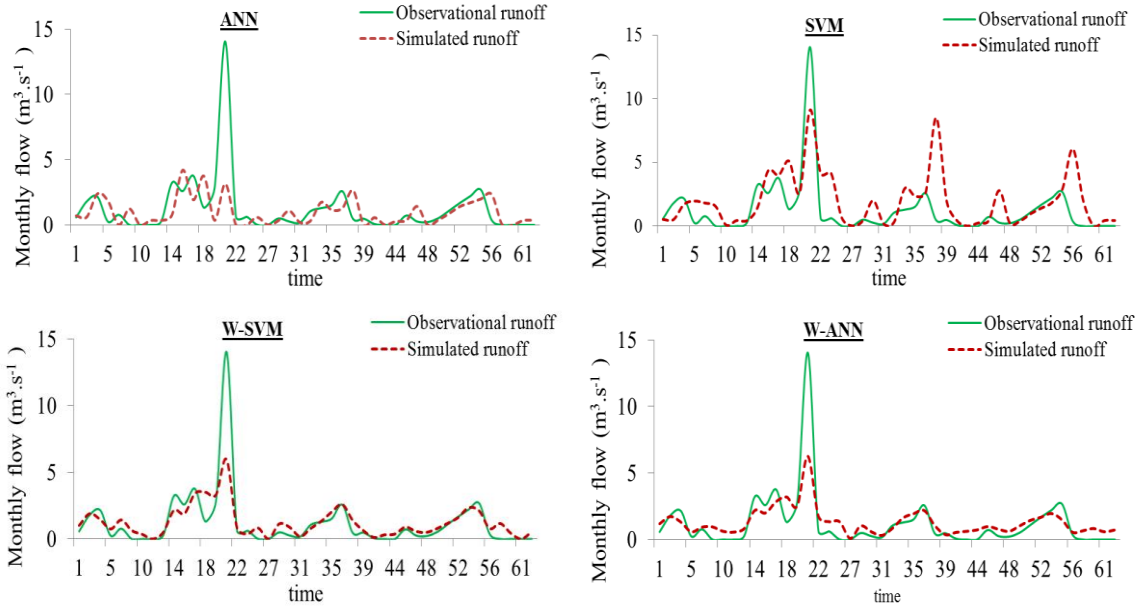
علت تفاوت نتایج در دو ایستگاه ممکن است به دلیل دارا بودن رواناب پایدارتر ایستگاه ارباب‌کندی نسبت به آلادیزگه باشد. همچنین ایستگاه ارباب‌کندی نسبت به آلادیزگه دارای آمار کاملی بود، به‌طوری‌که ایستگاه آلادیزگه حدود ۵ درصد نقاط گم‌شده داشت که بازسازی شدند. مقادیر منفی در برخی پیکربندی‌ها نشان‌دهنده اهمیت انتخاب دقیق و حساسیت مدل‌ها به پارامترهاست و دقیقاً همان پیکربندی‌هایی را که عملکرد مناسبی در داده‌های تست داشته‌اند مثلاً ۲ نرون برای ANN به‌عنوان مدل‌های نهایی انتخاب شده اند. این مقادیر منفی درجدول ممکن است به دلیل پیروی داده‌های تست از الگوی متفاوت نسبت به داده‌های آموزش باشند و یا حذف نویز ممکن است در داده‌های تست بهتر انجام نشده باشد. البته به‌طوری‌که در جداول مشخص است مدل ترکیبی W-ANN به‌طور سیستماتیک این مشکلات را حل کرده و در تمامی موارد در داده‌های تست عملکرد مثبت و بهبودیافته‌ای نشان داده است. با این حال، مدل‌های ترکیبی در کاربردهای عملی با چالش‌هایی مواجه

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]

هستند که برخی از مهم‌ترین آن‌ها عبارتند از: روش‌های بهینه‌سازی ابتکاری (مانند الگوریتم والگر) به تعداد تکرارهای بالایی نیاز دارند که این امر در مورد داده‌های حجیم، غیرقابل اجرا می‌شود. همچنین، مدل‌های هیبریدی برای آموزش به مجموعه‌ای جامع از داده‌های تاریخی بلندمدت شامل متغیرهای هیدرولوژیکی مانند دبی رودخانه، بارندگی، دمای هوا، رطوبت خاک و سایر پارامترهای مرتبط وابسته هستند، در حالی که در بسیاری از حوزه‌های آبخیز، این داده‌ها یا به صورت ناقص موجود بوده یا از کیفیت مطلوب برخوردار نیستند.

در استفاده از مدل‌های ماشین بردار پشتیبان و هیبرید موجک- ماشین بردار پشتیبان با در نظر گرفتن آنکه در ایستگاه هیدرومتری ارباب‌کندی رواناب با دو ماه تأخیر و در ایستگاه هیدرومتری آلادیزگه با یک ماه تأخیر همبستگی معنی‌دار داشتند، بر این اساس مدل‌سازی رواناب با روش‌های فوق با دو ماه تأخیر و یک ماه تأخیر قابل‌قبول به‌ترتیب در ایستگاه‌های مزبور به‌عنوان ورودی مدل‌ها در نظر گرفته‌شده و فرآیند مدل‌سازی بهینه انجام یافت. بعد از حصول نتایج مقایسه بین مقادیر مشاهداتی و شبیه‌سازی شده رواناب در شکل‌های (۴) و (۵) به‌ترتیب برای ایستگاه‌های ارباب‌کندی و آلادیزگه ارائه‌شده است.



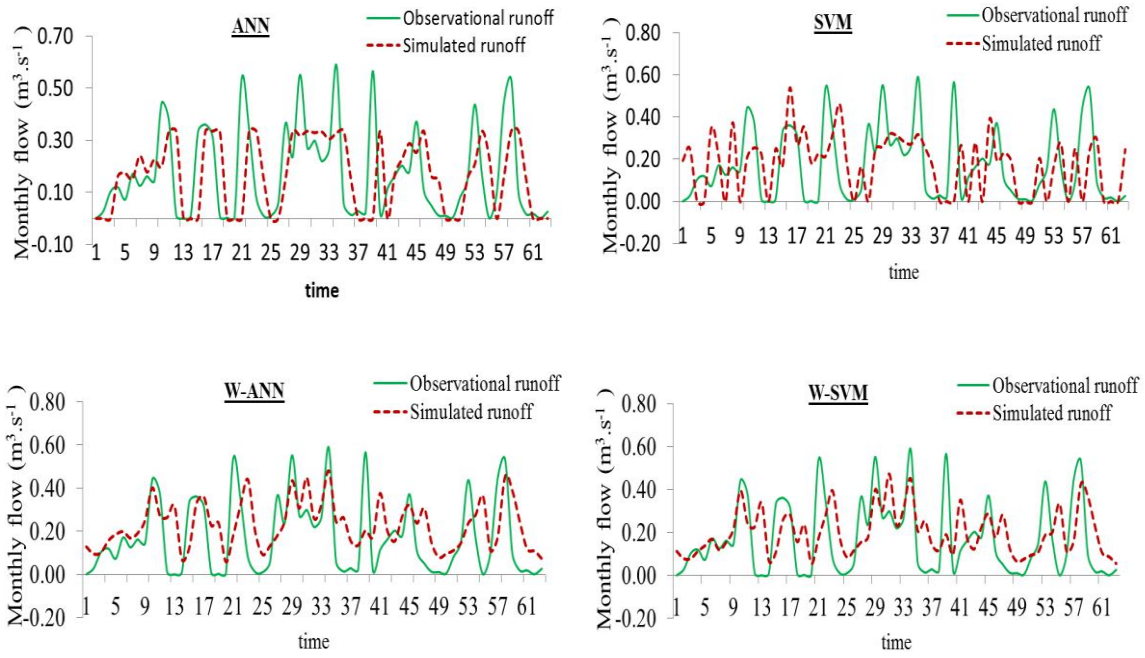
شکل۴- مقایسه رواناب مشاهداتی و شبیه‌سازی‌شده ایستگاه هیدرومتری ارباب‌کندی با دو ماه تأخیر

Figure 4 - Comparison of observed and simulated runoff of Arbabkandy hydrometric station with a two-month delay

به‌طوری‌که از شکل (۴) که مربوط به ایستگاه هیدرومتری ارباب‌کندی می‌باشد مشهود است، تطابق بین مقادیر مشاهداتی رواناب و مقادیر رواناب شبیه‌سازی‌شده در به‌کارگیری هیبرید موجک- شبکه عصبی مصنوعی و نیز موجک- ماشین بردار پشتیبان نسبت به حالت‌های استفاده از شبکه عصبی و ماشین بردار مجزا بسیار بالاست. این امر گویای اثربخشی در نظر گرفتن تبدیل موجک در پیش‌بینی رواناب می‌باشد. همچنین در این ایستگاه تطابق و همخوانی بین رواناب مشاهداتی و رواناب شبیه‌سازی‌شده حاصل از مدل شبکه عصبی مصنوعی بهتر از مدل ماشین بردار پشتیبان بود.

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]



شکل ۵- مقایسه رواناب مشاهداتی و شبیه‌سازی‌شده ایستگاه هیدرومتری آلادیزگه

Figure 5- Comparison of observed and simulated runoff at the Aladyzga hydrometric station

شاخص‌ها و آزمون آماری مدل‌ها

پس از انجام مدل‌سازی نتایج با کاربرد شاخص‌های آماری و آزمون t مورد ارزیابی قرار گرفت که نتایج ارزیابی برای همه مدل‌ها برای دو ایستگاه هیدرومتری ارباب‌کندی و آلادیزگه در جدول (۳) ارائه‌شده است.

جدول ۳- مقادیر شاخص‌ها و آزمون آماری مدل‌های به‌کار رفته در ایستگاه‌های ارباب‌کندی و آلادیزگه

Table 3- Index values and statistical tests of the models used in Arbabkandy and Aladyzga stations

Method	RMSE ($m^3 s^{-1}$)	GMER	MAE ($m^3 s^{-1}$)	RE	R	NSE	Mean Difference	t Stat
				ANN				
ارباب‌کندی	2.03	1.31	0.97	41	0.44	0.18	0.25	1.95*
آلادیزگه	0.18	1.41	0.17	44	0.36	0.12	-o.57	-2.26
mean	**1.105**	**1.36**	**0.57**	**42.5**	**0.4**	**0.15**	**0.25**	
				SVM				
ارباب‌کندی	2.11	1.47	1.24	48	0.42	0.19	0.77	-2.57
آلادیزگه	0.20	1.51	0.16	51	0.22	0.05	-0.32	-2.22
mean	**1.15**	**1.49**	**0.7**	**49.5**	**0.32**	**0.12**	**0.22**	
				W-ANN				
ارباب‌کندی	1.33	0.94	0.72	23	0.91	0.78	-0.08	0.23*
آلادیزگه	0.15	1.08	0.15	24	0.50	0.45	0.01	0.023*
mean	**0.74**	**1.01**	**0.435**	**23.5**	**0.705**	**0.62**	**-0.035**	
				W- SVM				
ارباب‌کندی	1.37	1.11	0.59	21	0.86	0.65	-0.04	0.08*
آلادیزگه	0.17	1.25	0.14	26	0.48	0.41	0.2	-0.25*
mean	**0.77**	**1.18**	**0.365**	**23.5**	**0.67**	**0.53**	**0.08**	

*: تائید فرض صفر ($H_0: \mu_1=\mu_2$) در سطح معنی‌داری ۵ درصد.

[Downloaded from jircsa.ir on 2026-10-31]
[DOR: 20.1001.1.24235970.1404.13.2.6.8]

در جدول (۳) از نتایج مقایسه داده‌های مشاهداتی و شبیه‌سازی‌شده دو ایستگاه آلادیزگه و ارباب‌کندی با چهار مدل شبکه عصبی مصنوعی، ماشین بردار پشتیبان، ترکیب موجک- شبکه عصبی مصنوعی و ترکیب موجک- ماشین بردار پشتیبان تحت شاخص‌های آماری RMSE، MAE و R و همچنین آزمون آماری t موارد زیر قابل استنباط است.

در حالت کلی مدل شبکه عصبی مصنوعی نتایج قابل‌قبول‌تری نسبت به ماشین بردار پشتیبان ارائه داده است. نتایج حاصل از تحلیل آزمون t در خصوص ایستگاه ارباب‌کندی حاکی از آن است که فرض یک ($H_1: \mu_1 \neq \mu_2$) در مدل‌های شبکه عصبی مصنوعی، هیبرید موجک- شبکه عصبی مصنوعی و موجک- ماشین بردار پشتیبان رد و فرض صفر ($H_0: \mu_1 = \mu_2$) تائید می شود. نتایج حاصل از تحلیل آزمون t در رابطه با ایستگاه آلادیزگه نشان داد که فرض یک ($H_1: \mu_1 \neq \mu_2$) در مدل‌های هیبرید موجک- شبکه عصبی مصنوعی و موجک- ماشین بردار پشتیبان رد و فرض صفر ($H_0: \mu_1 = \mu_2$) برقرار بود. در ایستگاه ارباب‌کندی مدل ترکیبی موجک- شبکه عصبی مصنوعی بالاترین مقدار ضریب همبستگی R، با مقدار برابر با ۰/۹۱ را در بین تمامی مدل‌های به‌کار رفته دارا بود. در ایستگاه آلادیزگه نیز مدل ترکیبی موجک- شبکه عصبی مصنوعی بالاترین مقدار ضریب همبستگی R، با مقدار برابر با حدود ۰/۵ را در بین تمامی مدل‌های به‌کار رفته داشت. کمترین مقدار شاخص آماری جذر میانگین مربعات خطا (RMSE) مربوط به مدل هیبرید موجک- شبکه عصبی مصنوعی در هر دو ایستگاه ارباب‌کندی و آلادیزگه به‌ترتیب برابر با ۱/۳۳ و ۰/۱۶ مترمکعب بر ثانیه است. بیشتر بودن مقدار شاخص آماری جذر میانگین خطا ایستگاه ارباب‌کندی نسبت به ایستگاه آلادیزگه به دلیل زیاد بودن مقادیر دبی جریان در ایستگاه ارباب‌کندی نسبت ایستگاه آلادیزگه می‌باشد. شاخص GMER در مدل‌های موجک- شبکه عصبی مصنوعی و موجک- ماشین بردار پشتیبان در هر دو ایستگاه نسبت به سایر مدل‌ها به عدد یک نزدیکتر بوده به‌طوری‌که در مدل موجک- شبکه عصبی مصنوعی مقدار این شاخص ۰/۹۴ حاصل شده که گویای خطای کمتر این مدل در مقایسه با سایر مدل‌ها است. بیشترین مقدار پارامتر GMER مربوط به ایستگاه هیدرومتری آلادیزگه با مقدار ۱/۵۱ در استفاده از روش ماشین بردار پشتیبان بود که حاکی از بیش برآوردی این مدل می باشد. هیبرید کردن مدل منفرد شبکه عصبی مصنوعی با مدل موجک در:

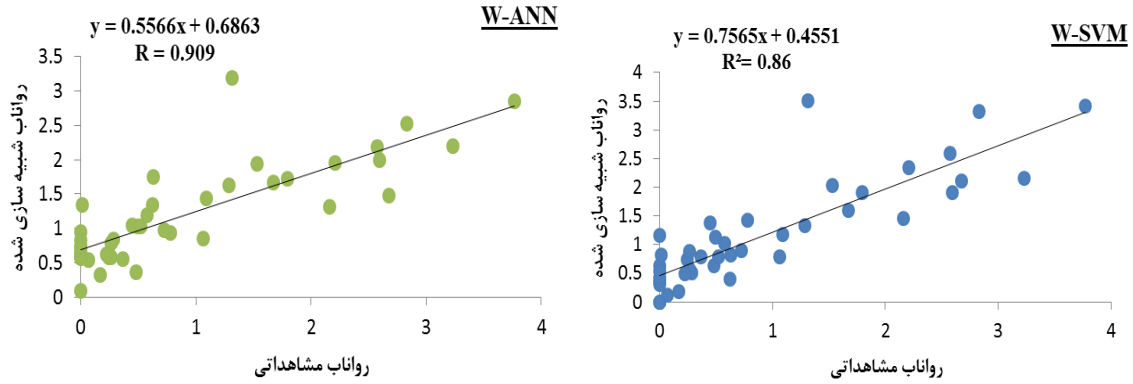
الف- ایستگاه ارباب‌کندی موجب افزایش پارامتر R از ۰/۴۴ به ۰/۹۱ و نیز کاهش پارامترهای RE و RMSE به‌ترتیب از ۴۱ درصد و ۲/۰۳ مترمکعب بر ثانیه به ۲۳ درصد و ۱/۳۳ مترمکعب بر ثانیه شده است.

ب- ایستگاه آلادیزگه موجب افزایش پارامتر R از ۰/۳۶ به ۰/۵ و نیز کاهش پارامترهای RE و RMSE به‌ترتیب از ۴۴ درصد و ۰/۱۸ مترمکعب بر ثانیه به ۲۴ درصد و ۰/۱۵ مترمکعب بر ثانیه شده است.

در مدل‌های ترکیبی با تجزیه سیگنال اصلی به زیرسیگنال‌های فرکانسی مختلف، قابلیت شناسایی الگوهای غیرخطی و نوسانات کوتاه‌مدت و بلندمدت افزایش یافته که این امر باعث می‌شود این مدل‌ها حساسیت به نویز را کاهش داده و از طرفی اطلاعات زمانی-فرکانسی را بهتر استخراج کرده و درنهایت منجر به بهبود عملکرد مدل‌های ترکیبی W-ANN و W-SVM نسبت به مدل‌های منفرد در پیش‌بینی مقادیر رواناب شده است. با توجه به مقبولیت مدل‌های ترکیبی موجک- شبکه عصبی مصنوعی و موجک- ماشین بردار پشتیبان در شبیه‌سازی رواناب نسبت به سایر مدل‌ها ضرایب واسنجی مدل‌های مزبور در قالب گراف‌هایی در شکل‌های (۶) و (۷) ارائه‌شده است. بعد از لحاظ ضرایب واسنجی در مقادیر رواناب حاصل از مدل‌های ترکیبی موجک- شبکه عصبی مصنوعی و موجک- ماشین بردار پشتیبان، مجددا مقادیر بدست آمده با مقادیر مشاهداتی مورد مقایسه قرار گرفتند. شاخص‌های خطای RMSE و MAE قبل و بعد از اعمال ضرایب واسنجی در شکل‌های (۸) و (۹) ارائه شده است.

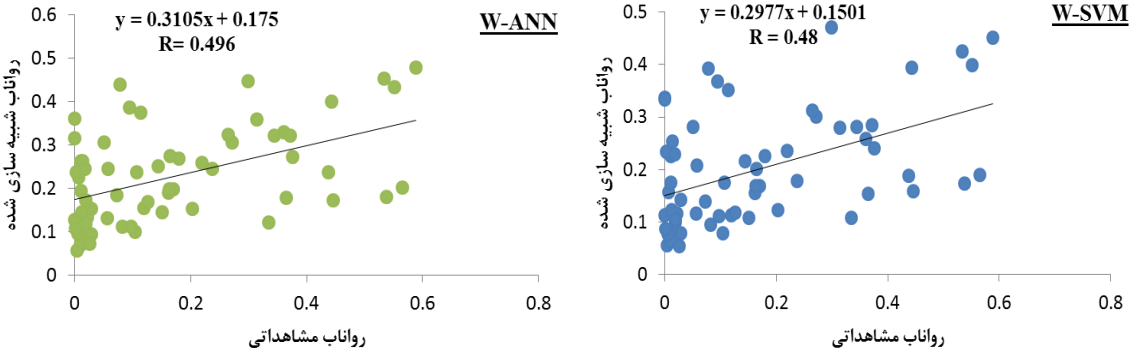
[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]



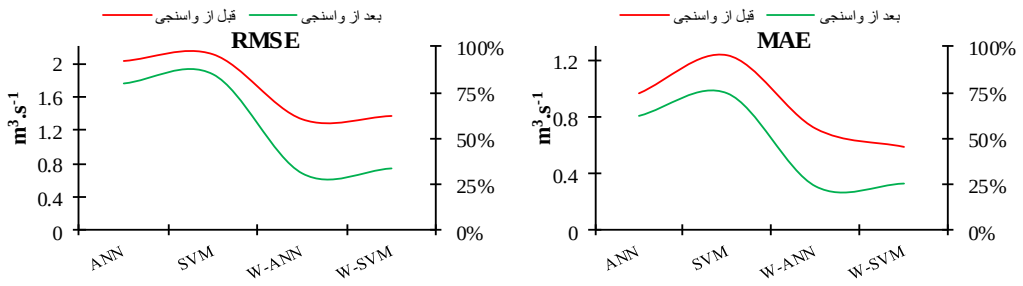
شکل ۶- ضرایب واسنجی مدل‌های W-ANN و W-SVM ایستگاه هیدرومتری ارباب‌کندی

Figure 6- Calibration coefficients of W-ANN and W-SVM models of Arbabkandy hydrometric station



شکل ۷- ضرایب واسنجی مدل‌های W-ANN و W-SVM ایستگاه هیدرومتری آلادیزگه

Figure 7- Calibration coefficients of W-ANN and W-SVM models of Aladyzga hydrometric station

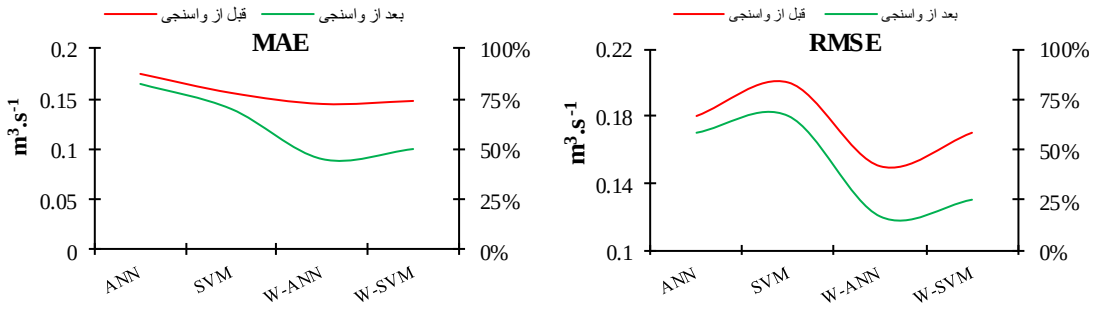


شکل ۸- شاخص‌های خطای RMSE و MAE قبل و بعد از اعمال ضرایب واسنجی ایستگاه هیدرومتری ارباب‌کندی

Figure 8- RMSE and MAE error indices before and after applying calibration coefficients for Arbabkandy hydrometric station

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]



شکل ۹- شاخص‌های خطای RMSE و MAE قبل و بعد از اعمال ضرایب واسنجی ایستگاه هیدرومتری آلادیزگه

Figure 9- RMSE and MAE error indices before and after applying calibration coefficients for the Aladyzga hydrometric station

مطابق شکل‌های (۸) و (۹) کاهش شاخص‌های خطای RMSE و MAE بعد از اعمال ضرایب واسنجی در مدل‌های ترکیبی موجک- شبکه عصبی مصنوعی و موجک- ماشین بردار پشتیبان مشهود است. برای بررسی جامع تر تحلیل عدم قطعیت مدل ها با شاخص‌های **d**-factor و 95PPU انجام شد که نتایج به‌صورت خلاصه در جدول (۴) ارائه شده است.

جدول ۴- نتایج تحلیل عدم قطعیت مدل‌های به‌کار رفته در ایستگاه‌های ارباب‌کندی و آلادیزگه

Table 4- Results of uncertainty analysis of models used at Arbabkandy and Aladyzga stations

مدل	95PPU ($m^3 s^{-1}$)	d-factor	نتیجه‌گیری
آلادیزگه			
ANN	[0.12, 0.22]	0.25	عدم قطعیت متوسط
W-ANN	[0.10, 0.20]	0.18	عدم قطعیت کم‌تر نسبت به ANN
SVM	[0.15, 0.25]	0.30	عدم قطعیت بالا
W-SVM	[0.11, 0.19]	0.20	بهبود قابل توجه نسبت به SVM
ارباب‌کندی			
ANN	[1.80, 2.26]	0.28	عدم قطعیت متوسط
W-ANN	[1.20, 1.46]	0.15	بهترین عملکرد با کمترین عدم قطعیت
SVM	[1.90, 2.50]	0.35	عدم قطعیت بالا
W-SVM	[1.30, 1.60]	0.18	بهبود نسبی نسبت به SVM

نتایج تحلیل عدم قطعیت نشان می‌دهد که مدل‌های ترکیبی مبتنی بر موجک به‌ویژه W-ANN، بهبود چشمگیری در قابلیت اطمینان پیش‌بینی‌ها ایجاد کرده‌اند. در هر دو ایستگاه مدل‌های ترکیبی W-ANN و W-SVM کمترین شاخص d-factorو باریک‌ترین محدوده 95PPU را دارند. در ایستگاه آلادیزگه پهنه پیش‌بینی ۲۵ درصد باریک‌تر شده (از (۰/۲۲ و ۰/۱۲) به (۰/۲۰ و ۰/۱۰)) و شاخص d-factor تا ۲۸ درصد کاهش یافته (از ۰/۲۵ به ۰/۱۸)، در حالی‌که در ایستگاه ارباب‌کندی این بهبودها حتی قابل‌توجه‌تر بوده‌اند (۳۳/۳ درصد باریک‌شدن محدوده پیش‌بینی و ۴۶/۴ درصد کاهش d-factor). این امر نشان‌دهنده کاهش عدم قطعیت ناشی از تجزیه موجک است که الگوهای غیرخطی را بهتر شناسایی می‌کند. به‌ویژه در ایستگاه ارباب‌کندی، W-ANN با d-factor معادل با ۰/۱۵ و محدوده $95PPU=1.33\pm0.13\ m^3 s^{-1}$ بهترین عملکرد را نشان داده است. همچنین ANN عملکرد بهتری نسبت به SVM داشت، اما همچنان عدم قطعیت آن بالاتر از مدل‌های

[Downloaded from jircsa.ir on 2026-10-31]
[DOR: 20.1001.1.24235970.1404.13.2.6.8]

ترکیبی است. مدل هیبرید موجک- شبکه عصبی مصنوعی با کمترین d-factor و باریک‌ترین 95PPU در هر دو ایستگاه به‌عنوان مدل بهینه قابل انتخاب است.

نتایج حاصل از این مطالعه نشان‌دهنده برتری واضح مدل‌های ترکیبی مبتنی بر تبدیل موجک در پیش‌بینی دبی جریان در هر دو ایستگاه مطالعاتی است. یافته‌های این تحقیق با نتایج مطالعات مشابه مانند کالته (۲۰۱۳) و ژانک و همکاران (۲۰۲۵) که به برتری مدل‌های ترکیبی موجک-هوشمند در شبیه‌سازی سری‌های زمانی هیدرولوژیکی اشاره داشته‌اند، همخوانی دارد. بررسی شاخص‌های آماری نشان می‌دهد که ترکیب تبدیل موجک با مدل‌های هوشمند منجر به بهبود قابل توجهی در دقت پیش‌بینی شده است. این بهبود به‌ویژه در مدل W-ANN مشهود است که بالاترین ضریب همبستگی (۰/۹۱) و کمترین مقدار RMSE (۱/۳۳ مترمکعب بر ثانیه) را در ایستگاه ارباب‌کندی نشان داد. این موضوع را می‌توان به توانایی تبدیل موجک در تجزیه سیگنال اصلی به مؤلفه‌های فرکانسی مختلف و کاهش اثر نویز در داده‌ها نسبت داد. همانطور که میسیتی و همکاران (۱۹۹۶) اشاره کرده‌اند، تبدیل موجک امکان شناسایی بهتر الگوهای غیرخطی و نوسانات کوتاه‌مدت و بلندمدت را فراهم می‌کند. نتایج آزمون t نیز تأیید می‌کند که تفاوت معنی‌داری بین مقادیر مشاهداتی و پیش‌بینی‌شده توسط مدل‌های ترکیبی وجود ندارد (تأیید فرض صفر). این موضوع نشان‌دهنده قابلیت اطمینان بالای این مدل‌ها در شبیه‌سازی رواناب است. در مقابل، عملکرد ضعیف‌تر مدل SVM را می‌توان به حساسیت این مدل به انتخاب پارامترهای کرنل و همچنین ماهیت پیچیده روابط غیرخطی در داده‌های هیدرولوژیکی نسبت داد (Kavzoglu and Colkesen, 2009). تفاوت در دقت مدل‌ها بین دو ایستگاه (به‌ویژه در مقدار ضریب همبستگی) ممکن است ناشی از عوامل مختلفی از جمله تفاوت در ویژگی‌های هیدرولوژیکی دو حوضه، تفاوت در کیفیت و کامل بودن داده‌های مشاهداتی، تفاوت در تأخیرهای زمانی بهینه برای هر ایستگاه باشد. نتایج این مطالعه از یافته‌های چونگ سان و همکاران (۲۰۲۳) که بر مزایای ترکیب تبدیل موجک با مدل‌های هوشمند تأکید داشتند، حمایت می‌کند. با این حال، باید توجه داشت که مدل‌های ترکیبی نیازمند محاسبات پیچیده‌تر و زمان بیشتری برای آموزش هستند که این موضوع می‌تواند از محدودیت‌های کاربردی این روش‌ها محسوب شود.

نتیجه‌گیری

در این تحقیق ارزیابی عملکرد و کارایی مدل‌های هوشمند شبکه عصبی مصنوعی، ماشین بردار پشتیبان و هوشمند-هیبریدی موجک- شبکه عصبی مصنوعی و موجک- ماشین بردار پشتیبان در شبیه‌سازی رواناب ماه آتی ایستگاه‌های هیدرومتری ارباب‌کندی و آلادیزگه انجام گرفت. در این راستا برای هرکدام از ایستگاه‌ها ترکیب مناسب ورودی مدل‌ها (رواناب با تعداد تأخیرهای قابل‌قبول) تعیین و شبیه‌سازی جریان به‌صورت خود همبسته صورت گرفت که دراین‌ارتباط نتایج زیر قابل‌بیان می‌باشند:

۱-ادغام تبدیل موجک با مدل‌های هوشمند منجر به بهبود چشمگیر دقت پیش‌بینی رواناب در هر دو ایستگاه مطالعاتی شد. این بهبود با کاهش ۴۵-۵۰ درصد در شاخص‌های خطا (RMSE و MAE) و افزایش ۶۰-۷۰ درصد در ضریب همبستگی (R) به وضوح قابل مشاهده بود. چنین بهبودی ناشی از توانایی منحصر به فرد تبدیل موجک در حذف نویز و تجزیه مؤثر سیگنال‌های هیدرولوژیکی به مؤلفه‌های فرکانسی است.

۲-در بین مدل‌های مورد بررسی، مدل ترکیبی موجک-شبکه عصبی مصنوعی (W-ANN) با کسب بالاترین ضریب همبستگی (۰/۹۱) و کمترین میزان خطا RMSE برابر با ۱/۳۳ مترمکعب درثانیه در ایستگاه ارباب‌کندی به‌عنوان کارآمدترین مدل شناسایی شد. این سطح از دقت، قابلیت بالای این رویکرد ترکیبی را در مدلسازی پدیده‌های هیدرولوژیکی پیچیده تأیید می‌نماید.

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]

۳-مقایسه مدل‌های پایه نشان داد که شبکه عصبی مصنوعی (ANN) در تمامی شاخص‌های ارزیابی عملکرد بهتری نسبت به ماشین بردار پشتیبان (SVM) ارائه می‌دهد. این تفاوت عملکرد احتمالاً ناشی از توانایی ذاتی ANN در مدل‌سازی روابط غیرخطی پیچیده‌تر است.

۴-مدل ترکیبی موجک (W-SVM) اگرچه نسبت به مدل پایه SVM بهبود قابل توجهی نشان داد، اما نتوانست به سطح دقت مدل W-ANN دست یابد. با این وجود، عملکرد نسبتاً مطلوب این مدل، امکان استفاده از آن به‌عنوان گزینه جایگزین در شرایط خاص را فراهم می‌سازد.

این یافته‌ها حاکی از آن است که ترکیب روش‌های هوشمند با تبدیل موجک می‌تواند راهکار مؤثری برای بهبود دقت پیش‌بینی در حوضه‌های با داده‌های محدود باشد. با این حال، برای توسعه بیشتر این روش‌ها، پیشنهاد می‌شود در مطالعات آتی موارد زیر مورد بررسی قرار گیرد.

۱-بررسی تأثیر تغییرات اقلیمی بر عدم قطعیت پیش‌بینی‌ها در مطالعات آینده و دبی رودخانه.

۲-استفاده از الگوریتم‌های بهینه‌سازی مانند PSO برای تنظیم پارامترهای مدل‌های ترکیبی.

۳-کاربرد مدل‌های ترکیبی در حوضه‌های فاقد داده.

ملاحظات اخلاقی

دسترسی به داده‌ها: داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

حمایت مالی: این پژوهش از هیچ سازمانی پشتیبانی مالی نشده است.

مشارکت نویسندگان: فریبرز احمدزاده کلیبر، احد مولوی و بهمن مهرورز قوجه بگلو، بخش‌های مختلف مقاله توسط نام‌بردگان انجام و نگاشته شده است.

تضاد منافع نویسندگان: نویسندگان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافعی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

منابع

۱. اسفندیاری، فریبا و قراچورلو، مرتضی (۱۴۰۲). برآورد منطقه‌ای رسوب‌دهی با استفاده از منحنی سنجه رسوب ماهانه در حوضه آبریز قره سو. *تحقیقات کاربردی علوم جغرافیایی*، (۲۳)۶۹، ۵۲-۳۳. doi: 10.61186/jgs.23.69.33

۲. اسکندری، علی و نوری، روح الله (۱۳۸۹). توسعه مدلی مناسب بر مبنای شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش‌بینی به هنگام اکسیژن خواهی بیوشیمیایی ۵ روزه. *محیط‌شناسی*، ۳۸(۶۱)، ۷۶-۷۴. doi: 10.22059/JES.2012.29013

۳. توکلی قاضی جهانی، هدیه، رئوف، مجید، رسول‌زاده، علی و میرزایی، سجاد (۱۳۹۶). ارزیابی اثر تغییرات کاربری بر روی هیدروگراف سیل و دبی پیک حوضه آتشگاه اردبیل. *سامانه‌های سطوح آبگیر باران*، ۵(۴)، ۷۱-۵۹. https://jircsa.ir/article-1-291-fa.html

۴. زارع ابیانه، حمید، بیات ورکشی، مریم، اخوان، سمیرا و محمدی، محمد (۱۳۸۹). تخمین نیترات آب زیرزمینی دشت همدان- بهار با استفاده از شبکه عصبی مصنوعی و اثر تفکیک داده‌ها بر دقت پیش‌بینی. *محیط‌شناسی*، ۳۷(۵۸)، ۱۴۰-۱۲۹. Doi:20.1001.1.10258620.1390.37.58.14.4

۵. رئوف، مجید، اکبری باصری، زینب، رسولزاده، علی و عزیزی مبصر، جوانشیر (۱۴۰۱). تحلیل حساسیت نرم‌افزار Hydrus نسبت به داده‌های ورودی در شبیه‌سازی حرکت آب و جذب ریشه گیاه مرجع چمن. *مدل‌سازی و مدیریت آب و خاک*، ۲(۳)، ۱۰۷-۹۴.

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]

۶. دهقانی، رضا، ترابی پوده، حسن، یونسی، حجت‌اله و شاهی نژاد، بابک (۱۴۰۰). کاربرد مدل هیبریدی ماشین بردار پشتیبان-موجک در تخمین جریان رودخانه‌ها، مطالعه موردی: حوضه دز. *مهندسی و مدیریت آبخیز*، ۱۳(۱)، ۱۱۰-۹۸. https://doi.org/10.22092/ijwmse.2020.128735.1748

۷. میرزائی، سجاد، رئوف، مجید، رسول‌زاده، علی و پوراسکندر، ساناز (۱۳۹۴). شبیه سازی هیدروگراف سیلاب رودخانه حوضه آتشگاه استان اردبیل با بهره‌گیری از الگوی بارش بهینه. *پژوهش‌های حفاظت آب و خاک*، ۲۲(۵)، ۸۰-۶۳. Doi: 20.1001.1.23222069.1394.22.5.4.4

۸. نجیب زاده، نازنین، قادری، کورش و احمدی، محمد مهدی (۱۳۹۸). بهره‌گیری از روش‌های رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی در مدل‌سازی بارش رواناب (مطالعه موردی: حوضه آبریز سد صفارود). *آبیاری و زهکشی ایران*، ۱۳(۶)، ۱۷۰۹-۱۷۲۰. doi: 20.1001.1.20087942.1398.13.6.15.1

References

1. Agheli, E., Ashrafzadeh, A,. & Janatrostami, S. (2024). Modeling the spatial dependence of quality data using distance-based inputs and a data-driven model. *Groundwater for Sustainable Development*, (24), 101061. https://doi.org/10.1016/j.gsd.2023.101061
2. Chongxun, M., Zhiwei, Y., Rongyong, M., Xingbi, L., Yun, D., Shufeng, L., Keke, H,. & Xixi, M. (2023). Investigation of the EWT–PSO–SVM Model for runoff forecasting in the Karst Area. *Applied Sciences*, 13(9). https://doi.org/10.3390/app13095693.
3. Dehghani, R., Torabipoodeh, H., Younesi, H,. & Shahinjad, B. (2022). Application of hybrid support vector machine wavelet (wsvm) model in predicting river flow, case study: Dez watershed. *Watershed Engineering and Management*, 13(1), 98-110. https://doi.org/10.22092/ijwmse.2020.128735.1748 [In Persian]
4. Erich. C.F., Gilmour, J., Machin, T,. & Hendry, L. (2022). Statistics for Research Students. *University of Southern Queensland*. https://doi.org/https://do.
5. Esfandiyari, F,. & Qarachoorloo, M. (2023). Regional estimation of sediment yield using monthly sediment rating curve in Qarasu watershed. J*ournal of Applied Research in Geographical Sciences*, 23(69), 33-52. doi: 10.61186/jgs.23.69.33 [In Persian]
6. Eskandari, A,. & Nouri, R. (2010). Developing a Proper Model for Online Estimation of the 5-Day Biochemical Oxygen Demand Based on Artificial Neural Network and Support Vector Machine. *Ecology*, 38(61), 76-74. Doi: 10.22059/JES.2012.29013 [In Persian]
7. Jain, A., & Kumar, A. M. (2007). Hybrid neural network models for hydrologic time series forecasting. *Applied Soft Computing Journal*, 7(2), 585-592. https://doi.org/10.1016/j.asoc.2006.03.002
8. Kakaei Lafadani, E., Moghaddamnia, A., Ahmadi, A., Jajarmizadeh, M., & Ghafari Gosheh, M. (2013). Stream flow simulation using SVM, ANFIS and NAM models (A case study). *Caspian Journal of Applied Sciences Reaserch*, 2(4), 86-93. https://www.researchgate.net/publication/257001623_Stream_Flow_Simulation_using_SVM_ANFIS_and_NAM_Models_A_Case_Study
9. Kalteh, A.M. (2013). Monthly river flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform, *Computers & Geosciences*, 54(2), 1–8. https://doi.org/10.1016/j.cageo.2012.11.015
10. Kavzoglu, T,. & Colkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11(5), 352-359. doi:10.1016/j.jag.2009.06.002
11. Kisi, O., Moghaddam Nia, A., Ghafari Gosheh, M., Jamalizadeh Tajabadi, M.R,. & Ahmadi, A. (2012). Intermittent streamflow forecasting by using several data driven techniques. *Water Resource Manage*, 26(2), 457–474. https://scienceon.kisti.re.kr/srch/selectPORSrchArticle.do?cn=NART58368385
12. Kwon, M., Kwon, H.H., & Han, D. (2020). A hybrid approach combining conceptual hydrological models, support vector machines and remote sensing data for rainfall-runoff modeling. *Remote Sensing*, 12(11). https://doi.org/10.3390/rs12111801
13. Mirzaei, S., Raoof, M., Rasoulzadeh, A,. & Poreskandar, S. (2016). Simulating flood hydrograph of Atashgah basin river of Ardabil province using optimized rainfall pattern. *Journal of Water and Soil Conservation*, 22(5), 63-80. doi:20.1001.1.23222069.1394.22.5.4.4 [In Persian]
14. Misiti, M., Misiti, Y., Oppenheim, G,. & Poggi, J.M. (1996). Wavelet Toolbox. *The Math Works Ins*, 2-36. https://scholar.google.fr/citations?user=Ghy6ZgoAAAAJ&hl=en
15. Misra, D., Oommen, T., Agarwal, A,. & Mishra, S.K. (2009). Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosystems Engineering*, 103, 527-535.

[Downloaded from jircsa.ir on 2026-10-31]

[DOR: 20.1001.1.24235970.1404.13.2.6.8]

16. Mugume, S.N., Murungia, J., Nyenjea, P.M., Sempewo, J.I., Okedi, J,. & Sörensen, J. (2024). Development and application of a hybrid artificial neural network model for simulating future stream flows in catchments with limited in situ observed data. *Journal of Hydroinformatics*, 26(8), 1944-1969. doi: 10.2166/hydro.2024.066
17. Najibzade, N., Qaderi, K,. & Ahmadi, M.M. (2020). Rainfall-Runoff modelling using Support Vector Regression and Artificial Neural Network models (Case study: SafaRoud Dam Watershed). *Iranian Journal of Irrigation and Drainage*, 13(6), 1709-1720. doi:20.1001.1.20087942.1398.13.6.15.1 [In Persian]
18. Raoof, M., Akbari Baseri, Z., Rasoulzadeh, A,. & Azizi Mobaser, J. (2022). Sensitivity analysis of Hydrus software to input data in simulating water movement and root uptake of grass as a reference plant. *Water and Soil Management and Modeling*, 2(3), 94-107. doi: 10.22098/MMWS.2022.10847.1090 [In Persian]
19. Samantaray, S., Sawan, S., Sahoo, A,. & Satapathy, P.S. (2022). Monthly runoff prediction at Baitarani river basin by support vector machine based on Salp swarm algorithm. *Ain Shams Engineering Journal*, 13(5), 1-18. https://doi.org/10.1016/j.asej.2022.101732.
20. Taie, S. M,. & Koch, M. (2024). Statistical downscaling of precipitation in northwestern Iran using a hybrid model of discrete wavelet transform, artificial neural networks, and quantile mapping. *Theoretical and Applied Climatology*, 155(7), 6591–6621. doi:10.1007/s00704-024-05033-2
21. Tavakoli Ghazi Jahani, M., Raoof, M., Rasoulzadeh, A,. & Mirzayi, S. (2018). Evaluation of effect of land use change on flood hydrograph and peak of flow in Atashgah Basin of Ardabil. *Iranian Journal of Rainwater Catchment Systems*, 5(4), 59-71. https://jircsa.ir/article-1-291-fa.html [In Persian]
22. Zare Abyaneh, H., Bayat Varkshi, M., Akhavan, S,. & Mohammadi, M. (2010). Estimation of nitrate in hamedan-bahar plain groundwater using ANN and the effect of data resolution on prediction accuracy. *Journal of Environment Studies*, 37(58), 129-140. doi: 20.1001.1.10258620.1390.37.58.14.4 [In Persian]

[Downloaded from jircsa.ir on 2026-10-31]
[DOR: 20.1001.1.24235970.1404.13.2.6.8]