




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

Fariborz Ahmadzadeh Kaleybar<sup>1</sup>, Ahad Molavi<sup>2</sup>, Bahman Mehrvarz Qoje Begloo<sup>3</sup>

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	ABSTRACT
<p><b>Article type:</b> Research Paper</p> <p><b>Article history</b>  <b>Received:</b> 25 May 2025  <b>Revised:</b> 29 July 2025  <b>Accepted:</b> 31 July 2025  <b>Published online:</b> 05 August 2025</p> <p><b>Keywords:</b> Artificial neural network, Support vector machine, Wavelet transform, Time delay</p> <p><b>Citation:</b> Ahmadzadeh Kaleybar, F., Molavi, A., &amp; Mehrvarz Qoje Begloo, B. (2025). Evaluation of intelligent models in predicting the discharge of Aladyzga and arbabkandy stations. <i>Iranian Journal of Rainwater Catchment Systems</i>, 13(2), 39-60.</p> <p><b>DOR:</b> 20.1001.1.24235970.1404.13.2.6.8</p> <p><b>Publisher:</b> Iranian Rainwater Catchment Systems Association</p>	<p>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<sup>3</sup> s<sup>-1</sup> to 23 % and 1.33 m<sup>3</sup> s<sup>-1</sup>, 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</p>
<p>© Author(s)</p>	

\*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



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

Fariborz Ahmadzadeh Kaleybar<sup>1</sup>, Ahad Molavi<sup>2</sup>, Bahman Mehrvarz Qoje Begloo<sup>3</sup>

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 ( $R=0.91$ ,  $NSE=0.78$ ,  $RMSE=1.33 \text{ m}^3 \text{ s}^{-1}$ ) 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 ( $R=0.50$ ,  $RMSE=0.15 \text{ m}^3 \text{ s}^{-1}$ ) 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

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.

## ارزیابی مدل‌های هوشمند در پیش‌بینی دبی ایستگاه‌های آلاذیزگه و ارباب‌کندی

فریبرز احمدزاده کلپیر<sup>۱</sup>، احد مولوی<sup>۲\*</sup>، بهمن مهرورز قوجه بگلو<sup>۳</sup>

۱. استادیار، گروه علوم و مهندسی آب، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران، [f.ahmadzadeh@iau.ac.ir](mailto:f.ahmadzadeh@iau.ac.ir)

۲. استادیار، گروه علوم و مهندسی آب، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران، [ahad.molavi@iau.ac.ir](mailto:ahad.molavi@iau.ac.ir)

۳. دانش‌آموخته کارشناسی ارشد، گروه علوم و مهندسی آب، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران، [mehrvarz13581365@Gmail.com](mailto:mehrvarz13581365@Gmail.com)

چکیده	مشخصات مقاله
تحقیق حاضر باهدف ارزیابی عملکرد مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و حالت هیبرید آن‌ها با مدل موجک در پیش‌بینی دبی ایستگاه‌های هیدرومتری آلاذیزگه و ارباب‌کندی واقع درحوضه قره سو انجام شد. با در نظر گرفتن شاخص همبستگی، در ایستگاه‌های هیدرومتری ارباب‌کندی و آلاذیزگه 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 آلاذیزگه 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 بالا بود. 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 ۱/۳۳ مترمکعب 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.	<p><b>نوع مقاله:</b> پژوهشی</p> <p><b>تاریخچه مقاله</b></p> <p><b>دریافت:</b> ۰۴ خرداد ۱۴۰۴</p> <p><b>بازنگری:</b> ۰۷ مرداد ۱۴۰۴</p> <p><b>پذیرش:</b> ۰۹ مرداد ۱۴۰۴</p> <p><b>انتشار برخط:</b> ۱۴ مرداد ۱۴۰۴</p> <p><b>واژه‌های کلیدی:</b> شبکه عصبی مصنوعی، ماشین بردار پشتیبان، تبدیل موجک، تأخیر زمانی</p>
<p><b>استناد:</b> احمدزاده کلپیر، فریبرز، مولوی، احد و مهرورز قوجه بگلو، بهمن (۱۴۰۴). ارزیابی مدل‌های هوشمند در پیش‌بینی دبی ایستگاه‌های آلاذیزگه و ارباب‌کندی. <i>سامانه‌های سطوح آبرگیر باران</i>، ۱۳(۲)، ۳۹-۶۰.</p> <p><b>DOR:</b> 20.1001.1.24235970.1404.13.2.6.8</p>	<p>ناشر: انجمن علمی سیستم‌های سطوح آبرگیر باران ایران</p>
<p>© نویسندگان</p>	

\* 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](mailto:ahad.molavi@iau.ac.ir)

## مقدمه

از آنجایی که سری رواناب ویژگی‌های غیرخطی را نشان می‌دهد، ثبت تناوب و نظم در سری رواناب با استفاده از یک مدل منفرد چالش‌برانگیز است (Kaltch, 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 مقدر 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 فراکوشی 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 پیدا کرده 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 به پیش‌بینی 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 آتشفشان مورد ارزیابی قرار دادند. بررسی‌ها نشان داد الگوی بارش WMO در مدل SCS، و الگوی Huff2nd در مدل‌های CLARK و SNYDER دارای نتایج قابل قبول تری هستند. با هدف بررسی تغییرات کاربری اراضی، هیدروگراف سیلاب و دبی جریان حداکثر حوضه آتشفشان 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 قرار دادند. مطابق اظهارات ایشان مدل‌های ANN و نروفازی به ترتیب بالاترین دقت را در شبیه‌سازی دبی روزانه در ایستگاه‌ها داشتند.

کاکائی لعدانی 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 قرار دادند. 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. Kaltch 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 ANN و SVR مجزا، دارای کارایی بهتری می‌باشند. نجیب‌زاده و همکاران (۲۰۲۰) برای شبیه‌سازی رواناب در زیر حوضه سد صفارود واقع در حوضه آبریز هلیل‌رود با

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 قرار دادند. نتایج پژوهش آنان نشان از مقبولیت مدل Linear SVR5 برای پیش‌بینی رواناب ایستگاه هنجان با مقادیر شاخص‌های خطای MAE، RMSE و R (ضریب همبستگی) به ترتیب معادل 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 به منظور توصیف جنبه‌های فرآیند بارش-رواناب به کار 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 قرار دادند. 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 قرار دادند. 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.

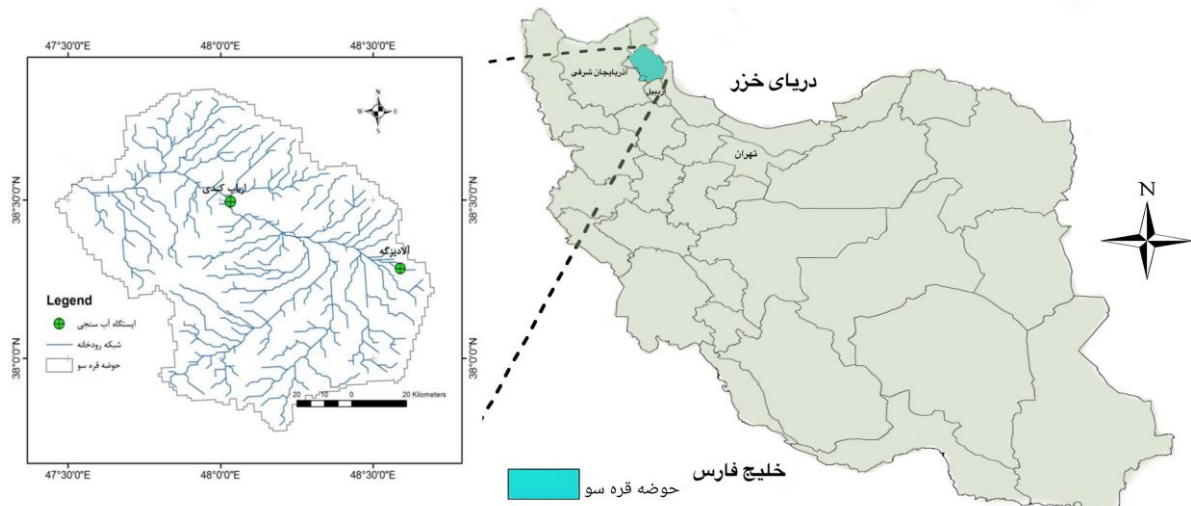
Agheli et al. (2024) در مطالعه‌ای مبتنی بر مدل‌های هوشمند شبکه عصبی پرسپترون چند لایه-MLP و داده‌های ۱۵۳ چاه در شمال غربی ایران، در نظر گرفتن ساختار مکانی از طریق افزودن فاصله تا چاه‌های مشاهده‌ای به همراه داده‌های رسانی الکتریکی (EC) به عنوان ورودی مدل، پیشنهاد شد. نتایج نشان داد استفاده از این رویکرد مکانی و تعداد بهینه چاه‌های همسایه (۸ تا ۲۰ چاه) منجر به تخمین دقیق‌تر شوری می‌شود. عملکرد 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 میانجا 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

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 ( $NSE=0.9$ ,  $RMSE=52.14$ ) به‌عنوان بهترین مدل شناخته شدند. با توجه به نتایج و کارایی قابل قبول 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 رودخانه‌ها آلاذیزگه و ارباب‌کنندی که به‌عنوان منابع آب حیاتی، تأمین‌کننده آب آشامیدنی و پشتیبانی‌کننده فعالیت‌های کشاورزی در منطقه و یک قطب کلیدی کشاورزی عمل می‌کند، انجام نشده 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 آلاذیزگه و ارباب‌کنندی واقع در حوضه قره سو انجام شد.

## مواد و روش تحقیق

### منطقه مورد مطالعه

محل مورد مطالعه ایستگاه‌های آب‌سنجی آلاذیزگه و ارباب‌کنندی واقع در حوضه آبریز قره‌سو بود. حوضه قره‌سو یکی از زیرحوضه‌های حوضه ارس است که در قسمت مرکزی استان اردبیل قرار گرفته و بخش کوچکی از آن در استان آذربایجان شرقی واقع شده است. این حوضه در مختصات جغرافیایی  $32^{\circ} 47'$  تا  $41^{\circ} 48'$  طول شرقی و  $37^{\circ} 47'$  تا  $52^{\circ} 38'$  عرض شمالی قرار گرفته و مساحت آن بالغ بر  $7706$  کیلومترمربع است. اختلاف ارتفاع پست‌ترین نقطه حوضه ( $774$  متر) و بلندترین نقطه آن در قله کوه سبلان ( $4786$  متر)  $4012$  متر می‌باشد. اقلیم حوضه در محدوده مدیترانه‌ای و نیمه‌خشک قرار دارد. حدود  $42$  درصد بارندگی حوضه در فصل بهار روی می‌دهد. کمترین میزان بارندگی فصلی با  $10$  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 بهار داشته و 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 آلاذیزگه و ارباب‌کنندی طی دوره آماری  $1378-1402$  استفاده شده است. این داده‌ها از سازمان آب منطقه‌ای 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 آلاذیزگه، حدود  $5$  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 ارباب‌کنندی کامل بوده و هیچ نقطه گم‌شده‌ای نداشتند. موقعیت ایستگاه‌های مذکور در حوضه قره‌سو در شکل (۱) ارائه شده است.



شکل ۱- موقعیت ایستگاه‌های مورد مطالعه در حوضه آبریز قره سو  
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 به صورت رابطه (۱) خواهد بود. تابع لاگرانژ دوگان نیز به صورت رابطه (۲) است.

$$f(x) = \phi(x)^T w + w_0 \quad (1)$$

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

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، در واقع 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) به ترتیب در روابط (۳) الی (۵) ارائه شده است.

$$K(x, x_i) = \exp\left(-\|x - x_i\|^2 / \sigma^2\right) \quad (3)$$

$$K(x, x_i) = (t + (x, x_i))^d \quad (4)$$

$$K(x, x_i) = \tanh(k_1(x, x_i) + k_2) \quad (5)$$

### کاربرد شبکه عصبی مصنوعی

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

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (6)$$

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-مارکواریت (همگرایی سریع و دقیق) انجام و حداکثر تعداد تکرار در فرآیند یادگیری شبکه ۱۰۰۰ 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 داده شده‌اند (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.

$$E = \int_{-\infty}^{+\infty} |\phi(t)|^2 dt < \infty \quad (7)$$

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

$$\int_0^{+\infty} \frac{|\phi(f)|^2}{f} df < \infty \quad (8)$$

### 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 تا ۲۰ نرون در لایه پنهان ارزیابی شد. در این روش آموزش شبکه‌های پرسپترون چندلایه به‌وسیله الگوریتم آموزش پس انتشار خطای لونبرگ-مارکواریت 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 انجام شده است.

## 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 قابل قبول از آزمون فرض ضریب همبستگی به شرح زیر استفاده به عمل آمد.

همبستگی معنی دار نمی‌باشد:  $H_0: \rho = 0$

همبستگی معنی دار می‌باشد:  $H_1: \rho \neq 0$

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

$$k = r \cdot \left( \frac{1-r^2}{n-2} \right)^{-1/2} \quad (9)$$

در این رابطه  $r$  ضریب همبستگی برای نمونه و  $n$  تعداد داده‌ها می‌باشد. هرگاه قدر مطلق  $k$  محاسبه شده از مقدار  $k$  جدول مربوط به سطح اطمینان ۹۵ درصد با درجه آزادی  $n-2$  بزرگ‌تر باشد، در این صورت ضریب همبستگی معنی دار خواهد بود. مقدار  $k$  مربوط به سطح اطمینان ۹۵ درصد با درجه آزادی ۱۰۰ در جدول احتمالات  $+1/98$  و  $-1/98$  می‌باشد، لذا چنانچه در هر سری رابطه (۱۰) برقرار گردد، همبستگی معنی دار خواهد بود.

$$|k_{cat}| \geq 1.98 \quad (10)$$

از این رو 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 معنی دار بودن آن با رابطه (۱۰) مقایسه می‌شود. در صورتی که  $r$  رواناب با هر یک از تأخیرهای در نظر گرفته شده بزرگ‌تر از  $0.2$  یا کوچک‌تر از  $-0.2$  حاصل شود، گویای معنی دار 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-ساکلیف یا کارایی)، RE (خطای نسبی)، GMER (نسبت خطای متوسط هندسی) (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).

$$R = \frac{\sum_{i=1}^N (Q_{xi} - \bar{Q}_x)(Q_{yi} - \bar{Q}_y)}{\sqrt{\sum_{i=1}^N (Q_{xi} - \bar{Q}_x)^2} \sqrt{\sum_{i=1}^N (Q_{yi} - \bar{Q}_y)^2}} \quad (11)$$

$$RMSE = \left( \sum_{i=1}^n (Q_{yi} - Q_{xi})^2 / n \right)^{1/2} \quad (12)$$

$$MAE = \left( \sum_{i=1}^n |Q_{yi} - Q_{xi}| / n \right) \quad (13)$$

$$RE = \left( \sum_{i=1}^n |Q_{yi} - Q_{xi}| / \sum_{i=1}^n Q_{xi} \right) \quad (14)$$

$$GMER = EXP \left( \frac{1}{N} \sum_{i=1}^n Ln \left( \frac{Q_{xi}}{Q_{yi}} \right) \right) \quad (15)$$


$$NSE = 1 - \left( \frac{\sum_{i=1}^n (Q_{y_i} - Q_{x_i})^2}{\sum_{i=1}^N (Q_{x_i} - \bar{Q}_x)^2} \right) \quad (16)$$

در این روابط  $Q_{y_i}$  و  $Q_{x_i}$ ، به ترتیب مقادیر مشاهداتی و محاسباتی دبی در گام زمانی  $n$ ام، تعداد داده‌ها،  $\bar{Q}_y$  و  $\bar{Q}_x$  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 (Raof et. al, 2022).

## نتایج و بحث


### تعیین تأخیرهای قابل قبول 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 آلاذیزگه انجام شد. نتایج به دست آمده از ترکیب مزبور در شکل‌های (۲) و (۳) ارائه شده 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 آلاذیزگه

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  $Q_{t-3}$  به ترتیب مقادیر دبی جریان با یک الی سه ماه تأخیر می‌باشند. به طوری که 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 به عنوان ورودی مدل

رواناب منظور شد. در ایستگاه آلاذیزگه (شکل ۲) رواناب ماه حاضر با یک تأخیر (رواناب یک ماه قبل) همبستگی معنی‌دار دارد. بر این اساس جهت مدل‌سازی رواناب در ایستگاه آب‌سنجی آلاذیزگه 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 جدول‌های (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 هر کدام از نرون‌ها در مرحله صحت سنجی ارائه شده است. تعیین دقیق تعداد بهینه نرون‌های لایه پنهان با بهره‌گیری از روش اعتبارسنجی متقابل و بر مبنای شاخص‌های آماری ذکر شده 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 نرون‌ها 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 آلاذیزگه

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

نرون	آلاذیزگه									
	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 تقریباً شاخص‌های آماری R, RMSE, RE, GMER و NSE به‌ترتیب با مقادیر ۰/۱۸ مترمکعب بر ثانیه، ۰/۳۵۷، ۰/۴۴، ۱/۴۱ و ۰/۱۳ حالت بهینه را ایجاد کرده اند. در به‌کارگیری مدل هیبریدی موجک- شبکه عصبی مصنوعی به دلیل بهینه بودن مقادیر

شاخص‌های آماری فوق استفاده از پنج نرون انتخاب شد، به‌طوری‌که شاخص‌های RMSE و R به‌ترتیب برابر با ۰/۱۵۳ 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 آلودیزگه 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

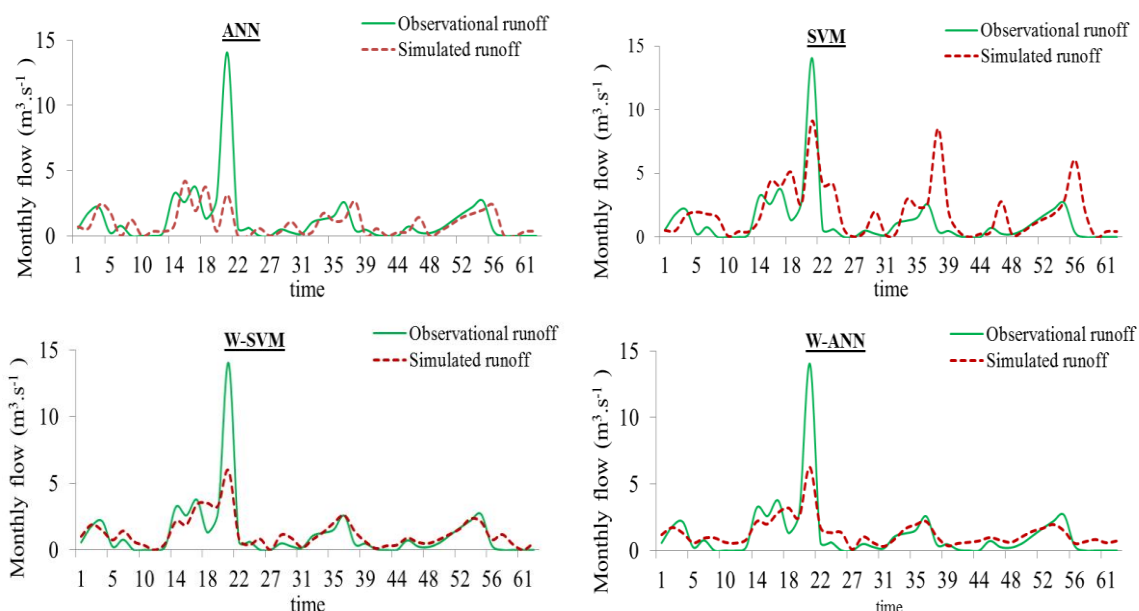
نرون	ارباب‌کندی					ارباب‌کندی				
	WAV-ANN					ANN				
	R	RMSE	RE	GMER	NSE	R	RMSE	RE	GMER	NSE
1	0.91	1.334	23.0	0.94	0.78	0.36	2.24	42.10	1.35	0.12
2	0.78	1.457	25.2	0.95	0.65	0.28	2.26	43.50	1.37	0.08
3	0.82	1.561	26.8	0.97	0.70	0.39	2.13	41.00	1.33	0.15
4	0.81	1.518	25.9	0.96	0.68	0.39	2.30	44.20	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, RE, GMER و NSE به‌ترتیب با مقادیر ۰/۴۴۳، ۰/۳۵، ۰/۲، ۰/۴۱، 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 آلودیزگه باشد. همچنین ایستگاه ارباب‌کندی نسبت به آلودیزگه دارای آمار کاملی بود، به‌طوری‌که ایستگاه آلودیزگه 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 شده‌اند. این مقادیر منفی در جدول 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

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.

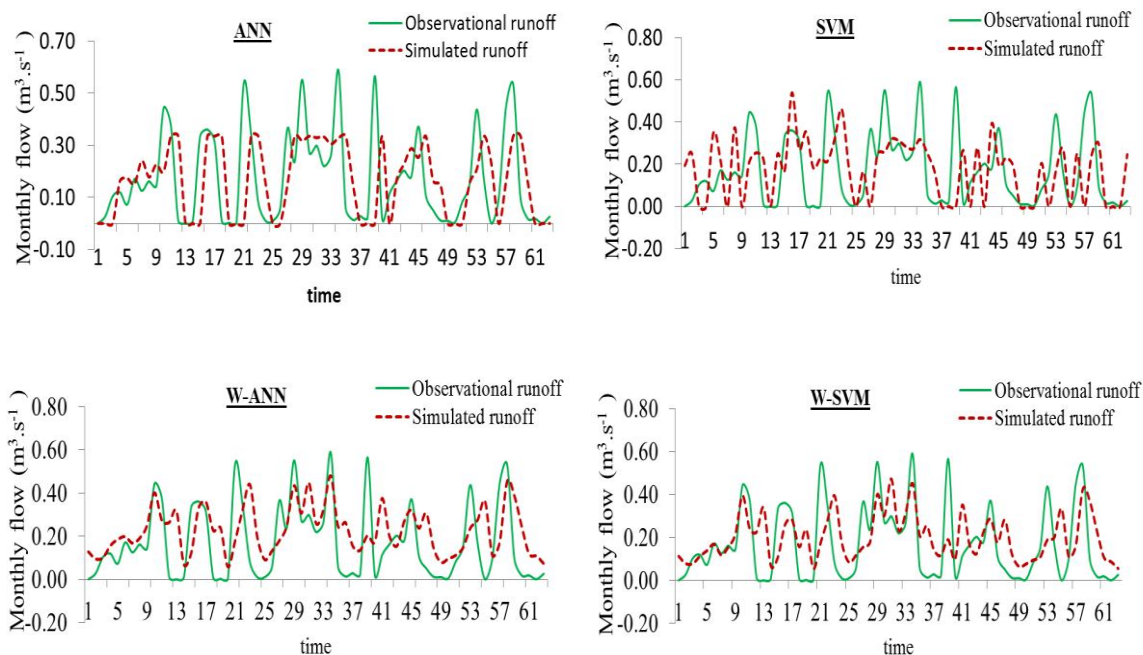
در استفاده از مدل‌های ماشین بردار پشتیبان و هیبرید موجک-ماشین بردار پشتیبان با در نظر گرفتن آنکه در ایستگاه هیدرومتری ارباب‌کندی رواناب با دو ماه تأخیر و در ایستگاه هیدرومتری آلاذیزگه با یک ماه تأخیر همبستگی معنی‌دار داشتند، بر این اساس مدل‌سازی رواناب با روش‌های فوق با دو ماه تأخیر و یک ماه تأخیر قابل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



شکل ۴- مقایسه رواناب مشاهداتی و شبیه‌سازی شده ایستگاه هیدرومتری ارباب‌کندی با دو ماه تأخیر

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

به طوری که از شکل (۴) که مربوط به ایستگاه هیدرومتری ارباب‌کندی می‌باشد مشهود است، تطابق بین مقادیر مشاهداتی رواناب و مقادیر رواناب شبیه‌سازی شده در به کارگیری 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 شبیه‌سازی شده حاصل از مدل شبکه عصبی مصنوعی بهتر از مدل ماشین بردار پشتیبان بود.



شکل ۵- مقایسه رواناب مشاهداتی و شبیه‌سازی شده ایستگاه هیدرومتری آلاذیزگه

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 آلاذیزگه در جدول (۳) ارائه شده است.

جدول ۳- مقادیر شاخص‌ها و آزمون آماری مدل‌های به کار رفته در ایستگاه‌های ارباب‌کندی و آلاذیزگه

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

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

\*: تائید فرض صفر (H<sub>0</sub>: μ<sub>1</sub>=μ<sub>2</sub>) در سطح معنی‌داری ۵ درصد.

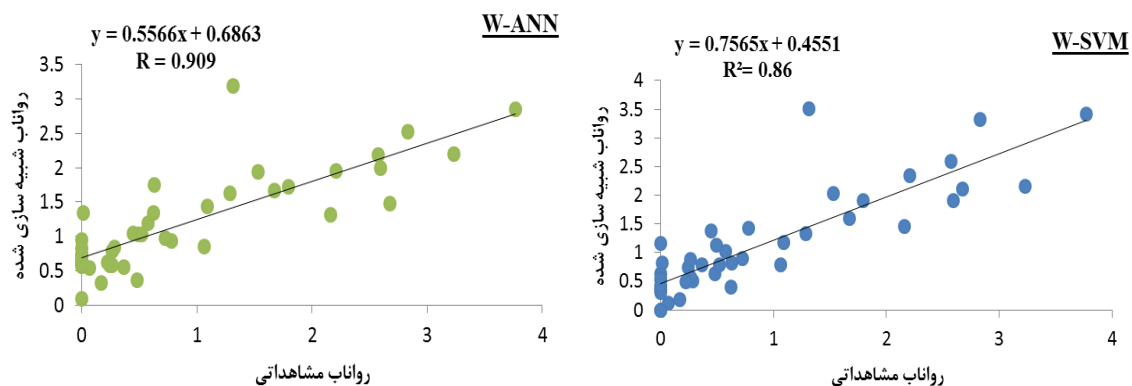
در جدول (۳) از نتایج مقایسه داده‌های مشاهداتی و شبیه‌سازی شده دو ایستگاه آلودیزگه و ارباب‌کندی با چهار مدل شبکه عصبی مصنوعی، ماشین بردار پشتیبان، ترکیب موجک- شبکه عصبی مصنوعی و ترکیب موجک- ماشین بردار پشتیبان تحت شاخص‌های آماری RMSE، MAE و R و همچنین آزمون آماری t موارد زیر قابل استنباط است.

در حالت کلی مدل شبکه عصبی مصنوعی نتایج قابل قبول تری 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 می‌شود. نتایج حاصل از تحلیل آزمون t در رابطه با ایستگاه آلودیزگه 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 آلودیزگه 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 آلودیزگه به ترتیب برابر با ۱/۳۳ و ۰/۱۶ مترمکعب بر ثانیه است. بیشتر بودن مقدار شاخص آماری جذر میانگین خطا ایستگاه ارباب‌کندی نسبت به ایستگاه آلودیزگه به دلیل زیاد بودن مقادیر دبی جریان در ایستگاه ارباب‌کندی نسبت به ایستگاه آلودیزگه 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 آلودیزگه با مقدار ۱/۵۱ در استفاده از روش ماشین بردار پشتیبان بود که حاکی از بیش برآوردی این مدل می‌باشد. 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 به ترتیب از ۴۱ درصد و ۲/۰۳ مترمکعب بر ثانیه به ۲۳ درصد و ۱/۳۳ مترمکعب بر ثانیه شده است.

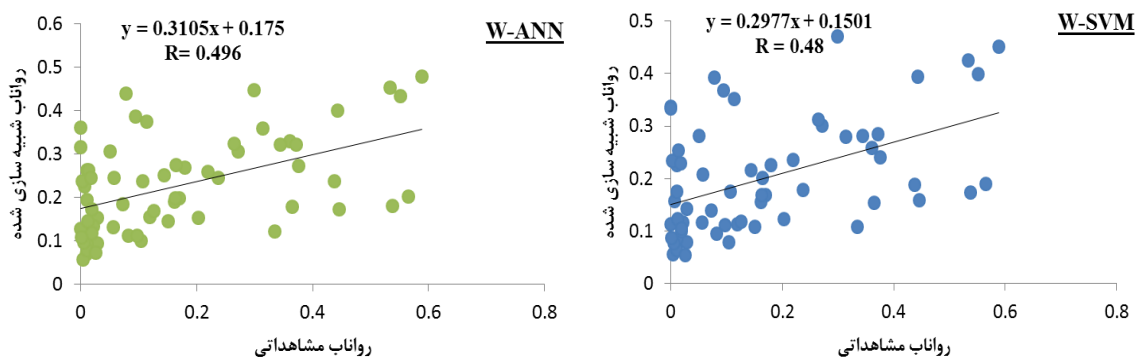
ب- ایستگاه آلودیزگه موجب افزایش پارامتر R از ۰/۳۶ به ۰/۵ و نیز کاهش پارامترهای RE و RMSE به ترتیب از ۴۴ درصد و ۰/۱۸ مترمکعب بر ثانیه به ۲۴ درصد و ۰/۱۵ مترمکعب بر ثانیه شده است.

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 در نهایت 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) ارائه شده است. بعد از لحاظ ضرایب واسنجی در مقادیر رواناب حاصل از مدل‌های ترکیبی موجک- شبکه عصبی مصنوعی و موجک- ماشین بردار پشتیبان، مجدداً 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.




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



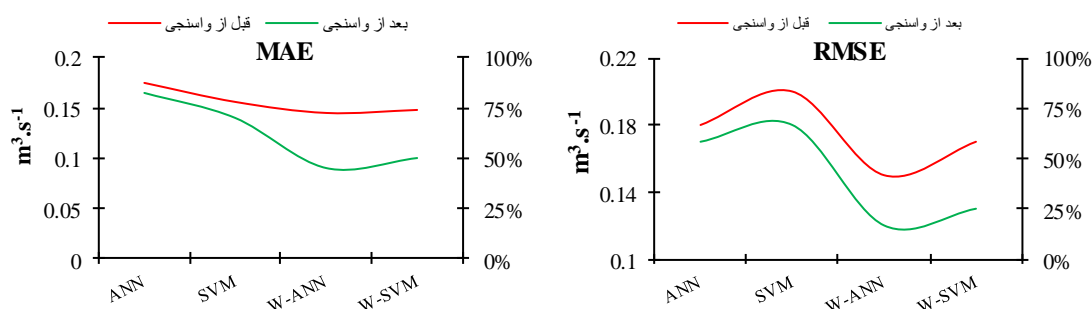
شکل ۷- ضرایب واسنجی مدل‌های W-ANN و W-SVM ایستگاه هیدرومتری آلاذیگه

Figure 7- Calibration coefficients of W-ANN and W-SVM models of Aladzyga 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



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

Figure 9- RMSE and MAE error indices before and after applying calibration coefficients for the Aladzyga 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 مدل‌ها با شاخص‌های **d-factor** و 95PPU انجام شد که نتایج به صورت خلاصه در جدول (۴) ارائه شده است.

جدول ۴- نتایج تحلیل عدم قطعیت مدل‌های به کار رفته در ایستگاه‌های ارباب‌کندی و آلاذیزگه

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

آلاذیزگه			
نتیجه گیری	d-factor	95PPU ( $m^3 s^{-1}$ )	مدل
عدم قطعیت متوسط	0.25	[0.12, 0.22]	ANN
عدم قطعیت کم‌تر نسبت به ANN	0.18	[0.10, 0.20]	W-ANN
عدم قطعیت بالا	0.30	[0.15, 0.25]	SVM
بهبود قابل توجه نسبت به SVM	0.20	[0.11, 0.19]	W-SVM
ارباب‌کندی			
عدم قطعیت متوسط	0.28	[1.80, 2.26]	ANN
بهترین عملکرد با کمترین عدم قطعیت	0.15	[1.20, 1.46]	W-ANN
عدم قطعیت بالا	0.35	[1.90, 2.50]	SVM
بهبود نسبی نسبت به SVM	0.18	[1.30, 1.60]	W-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-factor** و باریک‌ترین محدوده 95PPU را دارند. در ایستگاه آلاذیزگه 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 حالی که در ایستگاه ارباب‌کندی این بهبودها حتی قابل توجه‌تر 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 ۰/۱۵ و محدوده  $95PPU=1.33\pm 0.13 m^3 s^{-1}$  بهترین عملکرد را نشان داده است. همچنین ANN عملکرد بهتری نسبت به SVM داشت، اما همچنان عدم قطعیت آن بالاتر از مدل‌های

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 آبی ایستگاه‌های هیدرومتری ارباب‌کندی و آلودیزگه انجام گرفت. در این راستا برای هر کدام از ایستگاه‌ها ترکیب مناسب ورودی مدل‌ها (رواناب با تعداد تأخیرهای قابل قبول) تعیین و شبیه‌سازی جریان به‌صورت خود همبسته صورت گرفت که در این ارتباط 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 در ثانیه 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.

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 کلپیر، احد مولوی و بهمن مهرورز قوجه بگلو، بخش‌های مختلف مقاله توسط نام‌برندگان انجام و نگاشته شده است.

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

### منابع

- اسفندیاری، فریبا و قراچورلو، مرتضی (۱۴۰۲). برآورد منطقه‌ای رسوب‌دهی با استفاده از منحنی سنج رسوب ماهانه در حوضه آبریز قره سو. *تحقیقات کاربردی علوم جغرافیایی*، ۶۹(۲۳)، ۵۲-۳۳. doi: 10.61186/jgs.23.69.33
- 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.2012.29013.74-76
- توکلی قاضی جهانی، هدیه، رئوف، مجید، رسول‌زاده، علی و میرزایی، سجاد (۱۳۹۶). ارزیابی اثر تغییرات کاربری بر روی هیدروگراف سیل و دبی پیک حوضه آتشیگاه اردبیل. *سامانه‌های سطوح آبگیر باران*، ۵(۴)، ۷۱-۵۹. <https://jirca.ir/article-1-291-fa.html>
- زارع ایبانه، حمید، بیات ورکشی، مریم، اخوان، سمیرا و محمدی، محمد (۱۳۸۹). تخمین نترات آب زیرزمینی دشت همدان- بهار با استفاده از شبکه عصبی مصنوعی و اثر تفکیک داده‌ها بر دقت پیش‌بینی. *محیط‌شناسی*، ۳۷(۵۸)، ۱۴۰-۱۲۹. Doi:20.1001.1.10258620.1390.37.58.14.4.129
- 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.

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)، ۹۸-۱۱۰.  
<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 آتشفشان استان اردبیل با بهره‌گیری از الگوی بارش بهینه. *پژوهش‌های حفاظت آب و خاک*، ۲۲(۵)، ۶۳-۸۰.  
 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*، ۶(۱۳)، ۱۷۰۹-۱۷۲۰.  
 doi: 20.1001.1.20087942.1398.13.6.15.1.1720-1709

## References

- 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>
- 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>.
- Dehghani, R., Torabipodeh, 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]
- Erich. C.F., Gilmour, J., Machin, T., & Hendry, L. (2022). Statistics for Research Students. *University of Southern Queensland*. <https://doi.org/https://do>.
- Esfandiyari, F., & Qarachoorloo, M. (2023). Regional estimation of sediment yield using monthly sediment rating curve in Qarasu watershed. *Journal of Applied Research in Geographical Sciences*, 23(69), 33-52. doi: 10.61186/jgs.23.69.33 [In Persian]
- 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]
- 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>
- 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](https://www.researchgate.net/publication/257001623_Stream_Flow_Simulation_using_SVM_ANFIS_and_NAM_Models_A_Case_Study)
- 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>
- 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
- 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>
- 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>
- 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]
- 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>
- 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.

16. Mugume, S.N., Murungia, J., Nyenje, P.M., Sempewo, J.I., Okedi, J., & Sørensen, 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]