

## Rainfall-Runoff Modeling of Khormazard and Bonab Hydrometric Stations Using Support Vector Machine and Random Forest Algorithms

Z. Bigdeli <sup>1</sup>, A. Majnooni-Heris <sup>2\*</sup>, R. Delirhasannia <sup>2</sup>, S. Karimi <sup>3</sup>

1, 2 and 3- Ph.D Candidate, Associate Professor and Postdoctoral Resercher, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran, respectively.

(\*- Corresponding Author Email: [majnooni@tabrizu.ac.ir](mailto:majnooni@tabrizu.ac.ir))

Received: 14-03-2023  
Revised: 25-11-2023  
Accepted: 01-12-2023  
Available Online: 02-12-2023

### How to cite this article:

Bigdeli, Z., Majnooni-Heris, A., Delirhasannia, R., & Karimi, S. (2024). Rain-runoff modeling of Khormazard and Bonab hydrometric stations using Support Vector Machine and Random Forest algorithms. *Journal of Water and Soil*, 37(6), 971-989. (In Persian with English abstract). <https://doi.org/10.22067/jsw.2023.81608.1264>

### Introduction

Water plays a crucial role in ensuring the sustainable development of any region. Given that our country consists primarily of arid and semi-arid regions, where the majority of rivers are also found, along with the critical state of groundwater extraction and the growing importance of surface water, It is crucial to have a deep understanding of the future condition of water resources within the country's watersheds (Fathollahi *et al.*, 2015). By utilizing intelligent models, it becomes feasible to represent the inherent relationships between data that cannot be solved by conventional mathematical methods. Support vector machine (SVM) and Random Forest algorithms are two types of machine learning methods that utilize essential algorithms for making repeated and accurate predictions (Kisi & Parmarm, 2016). The most recent study conducted by Zarei *et al.* (2022) evaluated the risk of flooding using data mining models of SVM and RF (case study: Frizi watershed). By analyzing the results, it was found that both the SVM algorithm and the new random forest algorithm showed higher accuracy in predicting flooding risks, both in terms of the educational data and algorithmic performance. The purpose of this study is to simulate the precipitation-runoff process in the hydrometric stations at the end of the Maragheh plain (Khormazard station on the Mahpari chai river and Bonab station on the Sufichai river) in East Azerbaijan province using support vector machine and random forest modeling algorithms. This study has been conducted over a period of 43 years, making it one of the few research cases in this area.

### Materials and Methods

The Maragheh Sufi chai basin is situated in the eastern region of Lake Urmia, within the East Azarbaijan province. It covers an area of 611.89 square kilometers and is located between longitudes 45° and 40' to 46° and 25' and latitudes from 37° and 15' to 37° and 55' north. The average height of the basin is 1767 meters above sea level (Sharmod *et al.*, 2015). Based on the substantial changes observed in the runoff trend in the data since 1994 (without any noticeable change in the precipitation trend), the available data was divided into two distinct periods. The first period spans from 1976 to 1994, and the second period covers the years 1995 to 2019. To simulate rainfall-runoff, first the average rainfall of Maragheh plain was calculated by polygonal method. Subsequently, this data was combined with the discharge output from Bonab and Khormazard stations, with a one-day time lag. These inputs were then utilized in two models, SVM (kernel function) and RF. For this purpose, 70% of the data was used for the training stage and 30% of the data was used for the validation stage. Then, the rainfall and runoff training sets from one day before were chosen as the predictor variables, while the runoff training set was designated as the target variable. Several combinations of runoff and rainfall inputs were evaluated for the purpose of modeling. The inputs consist of the monthly Q and P values that were recorded



©2023 The author(s). This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/), which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source.

<https://doi.org/10.22067/jsw.2023.81608.1264>

previously ( $P_t, Q_{t-1}$ ), while the output represents the current runoff data ( $Q_t$ ), with the subscript  $t$  indicating the time step. As a result, two input combinations were constructed from  $Q$  and  $P$  data (as seen in Table 3) and SVM and RF models were used for rainfall-runoff modeling to determine the optimal input combination.

### Calculating average rainfall through the Thiessen Polygons method

Thiessen polygons, which are Voronoi cells, are used to define rainfall polygons that correspond to the surface area ( $A_i$ ). These polygons are used to weight the rainfall measured by each rain gauge ( $r_i$ ). Consequently, the area-weighted rainfall is equivalent to:

$$(t) = \frac{\sum_{i=1}^n r_i(t) \cdot A_i}{\sum_{i=1}^n A_i} \quad (1)$$

### Random Forest Algorithm

Random forest is a modern type of tree-based methods that includes a multitude of classification and regression trees. This algorithm is one of the most widely used machine learning algorithms due to its simplicity and usability for both classification and regression tasks.

### Support Vector Machine (SVM) algorithm

Support vector machines works like other artificial intelligence methods based on data mining algorithm. The most important functions of the support vector machine model are classification and linearization or data regression.

### Evaluation Criteria

To evaluate the models and compare their effectiveness, this research employs metrics such as the root mean square error (RMSE), correlation coefficient ( $r$ ), explanation coefficient ( $R^2$ ) and Nash-Sutcliffe efficiency coefficient (NS) are used. Below are the relationships among these criteria:

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

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

$$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O}_i) \cdot (P_i - \bar{P}_i)]^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \cdot \sum_{i=1}^n (P_i - \bar{P}_i)^2} \quad (4)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (P_i - \bar{P})^2} \quad (5)$$

### Results and Discussion

Figure 6 displays the time series data for rainfall and runoff during the two study periods, before and after 1994. The analysis of the figures showed that for Bonab station, during the two study periods, the value of Kendall's statistic for precipitation variable was 0.044 and 0.028, respectively. For Khormazard station, this statistic value for the first and second period was 0.030, and 0.028, respectively. However, these values are not significant at the 95% level. This indicates that the annual rainfall for the two studied stations during these years is not statistically significant. Therefore, it is concluded that the annual rainfall in these stations between the years 1976 to 2019 did not show any significant trend. The variations observed during this period were deemed normal, suggesting that the time series of rainfall displayed fluctuating patterns. However, it should be noted that there were instances of both increasing and decreasing trends in certain years. Examining the time series reveals varying trends. Initially, the outflow from Bonab station (both a and b) displayed fluctuating patterns, followed by periods of both decreasing and increasing trends. However, in recent years, there has been an increase in outflow from this station. The Mann-Kendall test statistic for the two study periods for this station is 0.325 and 0.512, respectively. These values are significantly different at the 95% level, indicating that the increasing trend of discharge for both time periods was statistically significant. The reason for this trend at the Bonab station, compared to other entrance stations to Lake Urmia, is the lower demand for water in the Sofichai basin for agricultural and industrial purposes, in contrast to other rivers. To explore the root cause of this issue, studies should be conducted to examine both underground and surface water sources, as well as the utilization of water in the agricultural and industrial sectors of this region. On the contrary, the trend observed at Khormazard station (c and d) is different. Unlike Bonab station, the discharge from Khormazard station exhibited a complete downward trend. The Mann-Kendall test statistic for the discharge variable during our two research periods were -0.269 and -0.412, respectively. At the 95% level, the decreasing trend of discharge in this station was found to be significant. On the other

hand, it is apparent that the volume of discharge in this hydrometric station has decreased drastically since 1976 (d). Apart from 2007, when there was a sudden increase in discharge volume, the water inflow into lake Urmia has remained at its lowest level throughout the years. To analyze the Bonab and Khormazard stations during two distinct periods, rainfall and runoff statistics (average, minimum, maximum) for the first period (1976-1994) and the second period (1995-2019) are presented in Tables 4 and 5. Based on the data presented in both tables, the Bonab station displays the highest average rainfall and runoff values in the total data column, while the Khormazard station has the lowest average rainfall and runoff values.

As mentioned, in order to model rainfall-runoff data using SVM and RF models, a portion of the data was used for training purposes, while another portion was used for validation. Tables 5 and 6 present the values of the calculated statistical indicators associated with the results obtained from the training and validation sections for both SVM and RF models. According to the results of Tables 6 and 7, it is clear that in both study periods, the SVM model outperformed the RF model at the Bonab station. The SVM model demonstrated superior accuracy in simulating both flow rate and monthly rainfall. Conversely, at the Khormazard station during these periods, the RF model displayed better performance compared to the SVM model. The modeling results in the test set for both stations revealed that the mutual correlation values for the first and second study periods at the Bonab station were 0.85 and 0.84, respectively. For the Khormazard station, these values were 0.79 and 0.75, respectively.

## Conclusion

The results indicate that for both periods at the Bonab station, the SVM model exhibited higher efficiency compared to the RF model. Conversely, at the Khormazard station, the RF model outperformed the SVM model for both periods. Mutual correlation values for the test sets were 0.85 and 0.84 for the first and second study periods at the Bonab station, respectively, for the SVM model test set. For the Khormazard station, these values were 0.79 and 0.75, respectively, for the RF model test set. Other notable findings of this research include the analysis of the time series data for rainfall and runoff over 43 years. Graphs obtained for both stations, along with the Mann-Kendall statistic for precipitation and flow parameters, revealed no discernible trend in precipitation during the two study periods. Instead, precipitation in these areas displayed fluctuating patterns. However, the analysis of the time series and statistical values for the discharge of Sofichai and Mahpari chai rivers at the Bonab and Khormazard stations showed different results. In the Bonab station, the discharge exhibited fluctuations, with an increase observed in the second period. Conversely, at the Khormazard station, the discharge trend was downward in both study periods. The volume of Mahpari chai River outflow notably decreased in recent years, as evidenced by the Mann-Kendall statistic showing a decreasing trend.

**Keywords:** Maragheh Plain, Modeling, Rainfall-runoff, Random forest, Sufi Chai, Support Vector Machine

مقاله پژوهشی

جلد ۳۷، شماره ۶، بهمن-اسفند ۱۴۰۲، ص. ۹۸۹-۹۷۱

## مدل‌سازی بارش - رواناب ایستگاه‌های هیدرومتری خرمازرد و بناب با استفاده از الگوریتم ماشین بردار پشتیبان و جنگل تصادفی

زینب بیگدلی<sup>۱</sup> - ابوالفضل مجنونی هریس<sup>۲\*</sup> - رضا دلیر حسن نیا<sup>۲</sup> - سپیده کریمی<sup>۳</sup>

تاریخ دریافت: ۱۴۰۱/۱۲/۲۳

تاریخ پذیرش: ۱۴۰۲/۰۹/۱۰

### چکیده

شبیه‌سازی فرآیند بارش-رواناب می‌تواند نقش بسزایی در مدیریت منابع آب و مسائل هیدرولوژی داشته باشد. در این تحقیق با استفاده از مدل‌های داده‌کاوی ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) اقدام به مدل‌سازی بارش-رواناب دو ایستگاه بناب و خرمازرد به ترتیب واقع بر روی رودخانه‌های صوفی‌چای و ماهپری‌چای (دشت مراغه) شده است. در مطالعه حاضر داده‌های ایستگاه‌های هواشناسی و هیدرومتری منطقه از سال ۱۳۵۵ تا ۱۳۹۷ از شرکت آب منطقه‌ای و سازمان هواشناسی استان آذربایجان شرقی دریافت گردید. تغییر روند رواناب جاری در سال ۱۳۷۴، باعث گردید مدت مطالعه به دو دوره قبل و بعد آن تقسیم شود. مقدار بارش و رواناب با تاخیر زمانی یک ماه بعنوان ورودی به این مدل وارد و سپس مقادیر رواناب ماهانه مشاهده‌شده با رواناب ماهانه تخمین زده شده با استفاده از معیارهای ارزیابی خطا مورد بررسی گرفت. نتایج نشان داد که در هر دو دوره برای ایستگاه بناب مدل SVM کارایی بالاتری نسبت به مدل RF داشت و در ایستگاه خرمازرد نیز برای این دو دوره، مدل RF عملکرد بهتری از مدل SVM ارائه کرد. نتایج مدل‌سازی در مجموعه تست در دو ایستگاه نشان داد که مقدار همبستگی متقابل برای دو دوره مطالعاتی اول و دوم ایستگاه بناب به ترتیب برابر با ۰/۸۴ و ۰/۸۵ و برای ایستگاه خرمازرد برابر با ۰/۷۹ و ۰/۷۵ بدست آمد. با توجه به نتایج مقادیر آماره من کندال و سری‌های زمانی برای هر دو ایستگاه، روند مشخصی برای بارش در طول دوره مشاهده نشد، ولی دبی رودخانه صوفی‌چای در ایستگاه بناب، بخصوص بعد از سال ۱۳۷۴ روند صعودی و دبی رودخانه ماهپری‌چای روند کاملاً نزولی داشته است.

**واژه‌های کلیدی:** بارش - رواناب، جنگل تصادفی، دشت مراغه، صوفی‌چای، ماشین بردار پشتیبان، مدل‌سازی

### مقدمه

مدیریت و کنترل تمامی عوامل در صورتی که تغییرات غیرطبیعی مانند دخالت‌های انسانی و تغییرات اقلیمی در حوزه‌های آبخیز مختلف بیش از حدی رخ دهد، به دلیل پیچیدگی آنها بسیار دشوار خواهد بود. همچنین، پیش‌بینی دقیق رواناب به یک چالش اساسی برای دانشمندان و مهندسان در دوران معاصر تبدیل شده است. از آنجا که تحلیل بارش-رواناب به دلیل وجود روابط پیچیده و غیرخطی در تبدیل بارش به رواناب با مشکلات بسیاری روبه‌رو است. با توجه به اینکه

آب یکی از عوامل مهم در توسعه پایدار هر منطقه می‌باشد. به نظر می‌رسد با توجه به شرایط اقلیمی، کمیت و کیفیت آب قابل دسترس برای توسعه اقتصادی و زیست‌محیطی در اکثر نقاط ایران کافی نمی‌باشد (Sharifi et al., 2014). در حال حاضر، به دلیل کاهش میزان بارش در ایران و ادامه روند خشکسالی، نیاز به مدیریت و برنامه‌ریزی منابع آب از هر زمان دیگری اهمیت بیشتری پیدا کرده است. اما

۲، ۱ و ۳- به ترتیب دانشجوی دکتری، دانشیار و محقق پسا دکتری، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران  
(Email: majnooni@tabrizu.ac.ir)  
\* نویسنده مسئول:

باتیس و همکاران (Botsis *et al.*, 2011) بارش-رواناب روزانه در کالیفرنیا را شبیه‌سازی کردند مدل ماشین بردار پشتیبان با سه نوع تابع کرنل با مدل شبکه عصبی مصنوعی مورد مقایسه قرار گرفت، در نتیجه این تحقیق ماشین بردار پشتیبان شبیه‌سازی دقیق‌تری از بارش-رواناب داشت. حسین و همکاران (Hussain *et al.*, 2020) جهت پیش‌بینی جریان رودخانه هنزه در پاکستان از مدل‌های شبکه عصبی مصنوعی پرسپترون چندلایه، (MLP) رگرسیون بردار پشتیبان (SVR) و جنگل تصادفی (RF) استفاده نموده اند. مجموعه‌ای از پنج پارامتر به اضافه سری زمانی جریان رودخانه با تاخیرهای مختلف بعنوان ورودی مدل‌ها استفاده شد. مقایسه عملکرد مدل‌ها نشان داد که به ترتیب مدل‌های RF، MLP و SCR بالاترین عملکرد را در پیش‌بینی جریان رودخانه هنزه داشتند. همچنین نتایج نشان داد که مدل‌های مبتنی بر الگوریتم‌های یادگیری ماشینی به ویژه مدل RF می‌تواند با دقت بسیار بالایی در پیش‌بینی جریان رودخانه به کار گرفته شوند. نجیب‌زاده و همکاران (Najibzade *et al.*, 2020) مطالعه‌ای در مورد بهره‌گیری از روش‌های رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی در مدل‌سازی بارش-رواناب (مطالعه موردی: حوضه آبریز سد صفارود) انجام دادند. نتایج حاکی از عملکرد مناسب روش‌های MLP و SVR Linear در مدل‌سازی بارش رواناب در محدوده مورد مطالعه می‌باشد. شهاب و همکاران (Band *et al.*, 2020) در حوضه آبخیز کلوان در همدان با مدل‌های الگوریتم یادگیری ماشینی (ML)، درخت رگرسیون تقویت شده (BRT)، جنگل تصادفی (RF)، جنگل تصادفی موازی (PRF)، جنگل تصادفی منظم (RRF) و درختان تصادفی (ERT) به این نتیجه رسیدند که مدل ERT با مقدار AUC ۰/۸۲ مناسب‌ترین مدل است و مقدار AUC برای مدل‌های RF، PRF و BRT به ترتیب ۰/۸۰، ۰/۷۹ و ۰/۷۸ است. شرفی و همکاران (Sharafi *et al.*, 2021) بارش ماهانه با استفاده از مدل‌های برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان را پیش‌بینی نمودند. نتایج نشان داد که عملکرد هر دو مدل خوب و تقریباً یکسان بوده (میانگین خطای مطلق به ترتیب ۰/۸۰ و ۰/۷۲) ولی با توجه به ارزیابی‌های انجام شده مدل رگرسیون بردار پشتیبان عملکرد نسبتاً بهتری داشته است (ضریب همبستگی ۰/۹۹۹). به‌طور کلی می‌توان گفت که مدل رگرسیون بردار پشتیبان برای مدل‌سازی و پیش‌بینی بارش ماهانه استان اردبیل مناسب‌تر بوده است. سهرابی گشنیگانی و همکاران (Sohrabi Geshnigani *et al.*, 2021) روی مدل‌سازی بارش-رواناب با استفاده از مدل HBV و الگوریتم تصادفی در حوضه آبخیز بازفت مطالعه کردند. مقایسه نتایج مدل مفهومی HBV و مدل RF نشان‌دهنده عملکرد بهتر مدل RF بود. بنابراین، مدل RF به‌عنوان مدل برتر انتخاب گردید که این مدل می‌تواند برای کاربردهای آینده به‌عنوان یک گزینه جدید برای پیش‌بینی رواناب در حوضه بازفت مورد استفاده قرار گیرد. در جدیدترین

ایران منطقه‌ای خشک و نیمه خشک است و بیشتر رودخانه‌ها در مناطق خشک جریان دارند، وضعیت بحرانی برداشت آب‌های زیرزمینی و لزوم توجه بیشتر به آب‌های سطحی، اطلاعاتی درباره وضعیت آینده منابع آبی در حوزه‌های آبریز کشور اهمیت بسیاری دارد (Fathollahi *et al.*, 2015). بنابراین، برآورد دقیق رواناب متناسب با بارش‌های بارانی، به عنوان یک گام حیاتی در فرآیند برنامه‌ریزی منابع آب بسیار حائز اهمیت است (Dastorani *et al.*, 2018). به‌عبارت دیگر، سیلاب‌ها به‌طور معمول در مناطق خشک و در دره‌هایی رخ می‌دهند که داده‌های اندازه‌گیری شده موجود نیست. به‌عنوان مثال، در استان آذربایجان شرقی، برای حوضه‌های کوچکتر از ۴۰ کیلومتر مربع، اطلاعات ایستگاه‌های هیدرومتری در دسترس نیست. بنابراین، توسعه روش‌های تخمین رواناب برای این نواحی امری ضروری است (Patil *et al.*, 2008) از آنجایی که اغلب داده‌های بارش در دوره‌های زمانی بلندتری نسبت به داده‌های رواناب موجود هستند، این ویژگی امکان پرکردن خلاءهای آماری در داده‌های رواناب را فراهم می‌کند (Rezazei *et al.*, 2017). به همین دلیل، در دسترس بودن اطلاعات پیوسته بارش و سایر متغیرهای اقلیمی که می‌توانند برای مدلسازی مقدار رواناب مورد استفاده قرار گیرد، بسیار ضروری می‌باشد (Lorrai & Sechi, 1995). با این گفته‌ها، اشاره شده است که از دهه ۱۹۶۰ مدل‌های مختلفی برای شبیه‌سازی فرآیند بارش-رواناب توسعه یافته‌اند. مدل در واقع یک ابزار است که می‌تواند بخشی از واقعیت را شبیه‌سازی کند. هدف از مدل‌سازی، نمایش عملکرد و رفتار یک پدیده طبیعی تحت شرایط خاص است (Phomcha *et al.*, 2011). به‌طور کلی، مدل‌های ریاضی بارش-رواناب را می‌توان به دو گروه مدل‌های دارای مبنای فیزیکی (مانند مدل‌های هیدرولوژیکی مفهومی) و مدل‌های داده‌محور (مانند شبکه‌های عصبی مصنوعی و ...) تقسیم‌بندی کرد. یک رده جدید از مدل‌های رگرسیون بر مبنای رویکردهای یادگیری ماشینی برای حل مشکلات مدل‌های سری زمانی کلاسیک ایجاد شده است. با استفاده از مدل‌های هوشمند، می‌توان روابط ذاتی میان داده‌ها را که ریاضیات کلاسیک قادر به حل آنها نیست، مدل‌سازی کرد. استفاده گسترده از یادگیری ماشینی و رویکردهای مدرن در مطالعه منابع آب در سال‌های اخیر مورد توجه قرار گرفته است. از جمله مدل‌های هوشمند می‌توان به مدل‌های شبکه‌های عصبی مصنوعی (ANNs)، برنامه‌ریزی بیان ژن (GEP) و مدل‌های جدیدی همچون ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) اشاره کرد. الگوریتم‌های ماشین بردار پشتیبان و جنگل تصادفی دو نوع روش یادگیری ماشینی هستند که از الگوریتم‌های ضروری برای پیش‌بینی‌های چندگانه مکرر استفاده می‌کنند (Kisi & Parmarm, 2016). تاکنون در مطالعات زیادی از مدل‌های هوشمند برای پیش‌بینی جریان بارش-رواناب، سیلاب و ... استفاده شده است که در ادامه به برخی از آنها اشاره می‌شود.

ما نیازمند بررسی دقیق همبستگی بین این دو متغیر هستیم. از آنجا که در فصول گرم، میزان بالای تخخیر باعث می‌شود که بارش به رواناب تبدیل نشود، لازم است تا روند سری زمانی در بازه‌های مختلف مورد بررسی قرار گیرد. این بررسی ما را قادر می‌سازد تا متوجه شویم آیا همبستگی بارش و دبی در تمام فصول سال وجود دارد یا خیر! با در نظر گرفتن این اطلاعات، در جهت ایجاد مدل دقیق برای مدل‌سازی بارش - رواناب، انجام روندسازی نیز از اهمیت ویژه برخوردار است تا نتایج به دقت و قابل اطمینانی منجر شوند.

در واقع سؤال اساسی تحقیق این است که آیا برای شبیه‌سازی فرایند بارش - رواناب، مدل ماشین بردار پشتیبان و جنگل تصادفی، در شرایط کمبود داده و اطلاعات در برخی ایستگاه‌های دشت مراغه، می‌تواند جوابگوی پیش‌بینی بارش و رواناب در دو ایستگاه مورد مطالعه (بناب و خرمازرد) و در این دوره مطالعاتی باشد؟ سؤال بعدی که مطرح است این است که کدام یک از مدل‌ها در دو ایستگاه پایانی دشت مراغه عملکرد بهتری در شبیه‌سازی بارش - رواناب دارند؟

## مواد و روش‌ها

حوضه صوفی چای مراغه در استان آذربایجان شرقی و تقریباً در قسمت شرق دریاچه ارومیه واقع شده است. این حوضه با مساحت ۶۱۱/۸۹ کیلومتر مربع که ۲۵ درصد آن را دشت و ۷۵ درصد آن را ارتفاعات تشکیل داده است و در حد فاصل طول‌های جغرافیایی ۴۵ درجه و ۴۰ دقیقه تا ۴۶ درجه و ۲۵ دقیقه و عرض‌های جغرافیایی ۳۷ درجه و ۱۵ دقیقه تا ۳۷ درجه و ۵۵ دقیقه شمالی قرار گرفته و ارتفاع متوسط آن از سطح دریا ۱۷۶۷ متر از سطح دریا می‌باشد (Sharmod *et al.*, 2015).

حوضه صوفی چای از دامنه جنوبی کوهستان سه‌سهند سرچشمه گرفته و از شمال به حوضه آبریز لیقوان و کندچای، از شرق به حوضه آبریز مردق چای، از غرب به حوضه آبریز قلعه‌چای و از جنوب بعد از عبور از محدوده سد علویان به دریاچه ارومیه منتهی می‌شود. رودخانه صوفی چای با طول ۲۰ کیلومتر در داخل حوضه آبریز صوفی چای قرار دارد. از ابتدای حوضه صوفی چای، رودخانه‌های اسفستانچ چای، اسپران، چکان چای و ماهپری چای به صوفی چای پیوستند. ۱۰ ایستگاه مختلف در دشت مراغه وجود دارد که از ایستگاه‌های مهم حوضه صوفی چای می‌توان به ایستگاه بناب (بر روی رودخانه صوفی چای) و ایستگاه خرمازرد (بر روی رودخانه ماهپری چای) اشاره کرد. این دو ایستگاه آخرین ایستگاه‌های هیدرومتری رودخانه صوفی چای و ماهپری چای و منتهی به دریاچه ارومیه می‌باشند. شکل ۱ موقعیت حوضه آبریز صوفی چای و ایستگاه‌های مذکور را نشان می‌دهد.

در جدول ۱ نیز خلاصه‌ای از مشخصات آماری دشت مراغه ارائه شده است. نکته قابل ذکر رودخانه‌های حوضه صوفی چای این است که

مطالعه انجام گرفته توسط بیگدلی و همکاران (Bigdeli *et al.*, 2023)، مدل‌سازی بارش - رواناب حوضه آبی‌چای با استفاده از مدل‌های جنگل تصادفی و شبکه عصبی مصنوعی را بررسی کردند و به این نتیجه رسیدند که برای حوضه آبی‌چای مدل ANN کارایی بالاتری نسبت به RF دارد. در جدیدترین مطالعه بیگدلی و همکاران (Bigdeli *et al.*, 2023)، کاربرد الگوریتم ماشین بردار پشتیبان و درخت تقویت شده برای مدل‌سازی بارش - رواناب (مطالعه موردی: دشت تبریز) را بررسی نمودند. نتایج حاصل از این تحقیق نشان داد که در دوره‌های مطالعاتی انجام شده، برای ایستگاه آخولا مدل SVM عملکرد بهتری نسبت به مدل BT داشت و در ایستگاه پل سنیخ، مدل BT عملکرد بهتری نسبت به مدل SVM ارائه کرد.

پورصالحی و همکاران (Poursalehi *et al.*, 2022) عملکرد الگوریتم جنگل تصادفی در پیش‌بینی نوسانات سطح ایستابی در مقایسه با دو مدل درخت تصمیم و شبکه عصبی مصنوعی (مطالعه موردی: آبخوان آزاد دشت بیرجند) را مطالعه کردند. نتایج حاصل از شبیه‌سازی با استفاده از الگوریتم جنگل تصادفی نشان می‌دهد این الگوریتم توانایی نسبتاً زیادی در شبیه‌سازی تراز سطح ایستابی آبخوان دارد.

زارعی و همکاران (Zarei *et al.*, 2020) پتانسیل وقوع سیل با استفاده از مدل‌های داده‌کاوی ماشین بردار پشتیبان، چاید و جنگل تصادفی (مطالعه موردی: حوزه آبخیز فریزی) را ارزیابی نمودند. بر اساس نتایج، هم در داده‌های تعلیمی و هم در داده‌های آموزشی در الگوریتم (SVM) و مدل الگوریتم نوین جنگل تصادفی دارای نتایج دقیق‌تری می‌باشد. این نتیجه بیانگر این مطلب است که هر دو مدل از نظر صحت و اعتبار مدل‌سازی مورد تأیید قرار گرفته‌اند. اشاره می‌گردد که، داده‌های تعلیمی معمولاً برای آموزش مدل‌ها و الگوریتم‌های یادگیری ماشینی استفاده می‌شوند و داده‌های آموزشی و آزمونی کمک می‌کنند تا مدل‌ها بهترین عملکرد را در پیش‌بینی و تحلیل داده‌های جدید از خود نشان دهند.

هدف از این مطالعه، شبیه‌سازی فرایند بارش - رواناب در ایستگاه‌های هیدرومتری انتهایی دشت مراغه (ایستگاه خرمازرد روی رودخانه ماهپری چای و ایستگاه بناب روی رودخانه صوفی چای) در استان آذربایجان شرقی با استفاده از نرم‌افزار STATISTICA و ایجاد مدل بارش - رواناب با روش‌های ماشین بردار پشتیبان و جنگل تصادفی می‌باشد.

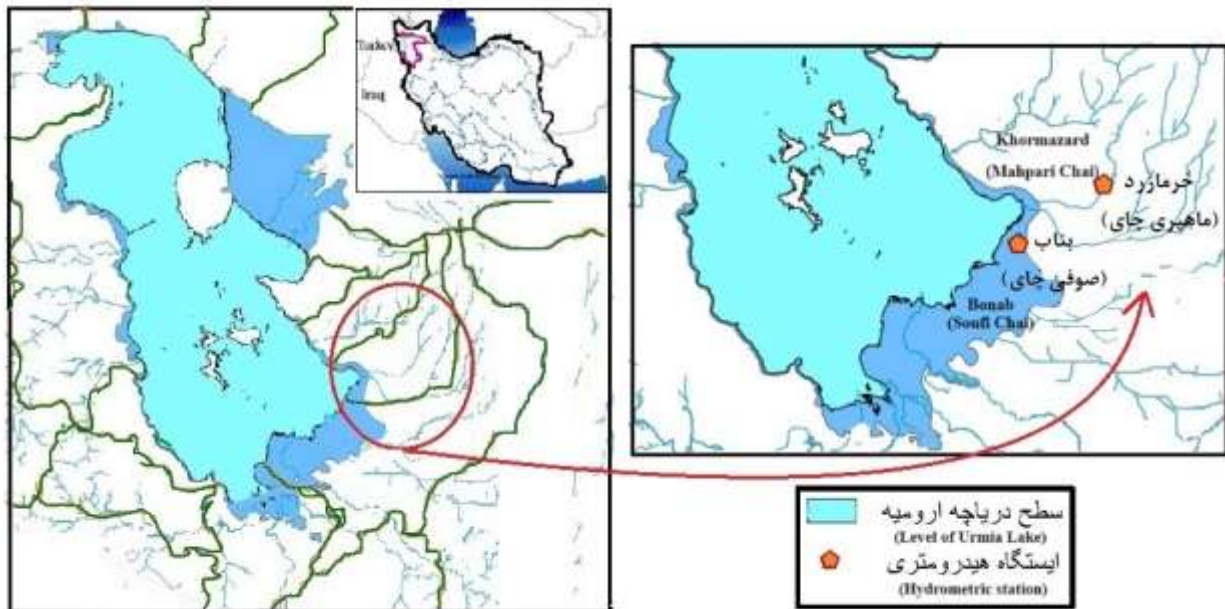
اگر چه در تعدادی از مطالعات اشاره شده، از مدل‌های این تحقیق استفاده شده است، اما با توجه به مطالعات انجام شده، تاکنون از روش‌های ماشین بردار پشتیبان و جنگل تصادفی برای مدل‌سازی بارش - رواناب دشت مراغه و دو ایستگاه بناب و خرمازرد، استفاده نشده است. این مطالعه در بازه زمانی ۴۳ ساله انجام شده است که در این موضوع مطالعاتی می‌تواند جزء موارد محدود تحقیقاتی در این منطقه باشد. از طرفی دیگر، به دلیل تغییرات فصلی و احتمال بارش در فصل‌های گرم،



سال ۱۳۷۴ (بدون تغییر محسوس در روند بارش)، داده‌های ۴۳ ساله به دو دوره (۱۳۵۵-۱۳۷۴) و (۱۳۷۵-۱۳۹۷) تقسیم شدند. برای شبیه‌سازی بارش - رواناب، ابتدا بارش متوسط دشت مراغه با روش پلیگون‌بندی محاسبه و سپس به همراه دبی خروجی از ایستگاه بناب و خرمازرد به همراه لگ زمانی یک ماهه وارد دو مدل SVM (تابع کرنل) و RF شدند. برای این منظور از ۷۰ درصد داده‌ها برای مرحله آموزش و ۳۰ درصد داده‌ها برای مرحله صحت‌سنجی استفاده گردید. سپس مجموعه آموزشی بارش و رواناب یک ماهه قبل به‌عنوان متغیر پیش‌بینی کننده و مجموعه آموزشی رواناب به‌عنوان متغیر هدف انتخاب شدند.

تمام این رودخانه‌های فصلی یا دائمی به شاخه اصلی رودخانه صوفی‌چای می‌ریزند و در نهایت دبی رودخانه صوفی‌چای و ماهپری در دو ایستگاه بناب (طول جغرافیایی ۴۶ درجه و ۴ دقیقه و عرض جغرافیایی ۳۷ درجه و ۲۰ دقیقه) و خرمازرد (طول جغرافیایی ۴۶ درجه و ۸ دقیقه و عرض جغرافیایی ۳۷ درجه و ۲۴ دقیقه) ثبت می‌شوند. داده‌های مورد استفاده برای مدل‌سازی در این پژوهش، شامل داده‌های باران (ماهانه) و دبی خروجی از دو ایستگاه مورد مطالعه (ماهانه) می‌باشد که از ۶ ایستگاه باران سنجی و سینوپتیک (از سال ۱۳۵۵ تا ۱۳۹۷) از شرکت آب منطقه‌ای و سازمان هواشناسی استان آذربایجان شرقی تهیه گردید. مشخصات ایستگاه‌های اشاره شده در جدول ۲ آورده شده است.

براساس تغییرات قابل توجه روند رواناب مشاهده شده در داده‌ها از



شکل ۱- موقعیت جغرافیایی ایستگاه‌های بناب و خرمازرد

Figure 1- Geographical location of Bonab and Khormazard stations

جدول ۱- مشخصات دشت مراغه


Table 1- The properties of Maragheh Plain

زیر حوضه Sub - Basin	رودخانه‌های زیر حوضه Sub-Basin Rivers	ایستگاه Station	مساحت رودخانه های زیر حوضه Area of rivers sub-basin (km <sup>2</sup> )	ارتفاع ایستگاه Height of station (m)	متوسط بارش Average precipitation (mm)	متوسط دما Average temperature (°C)
مراغه - بناب Maragheh- Bonab	صوفی‌چای Soufi Chai	بناب Bonab	661	1440	345.7	13.11
	ماهپری‌چای Mahpari Chai	خرمازرد Khormazard	74	1600	350.7	8.70

جدول ۲- مشخصات ایستگاه‌های دشت مراغه

Table 2- The properties of Stations of Maragheh Plain

زیر حوضه Sub - Basin	مساحت Area (km <sup>2</sup> )	ایستگاه‌های منتخب Selected Stations	رودخانه‌های حوضه Basin Rivers	ارتفاع ایستگاه Stations Height	متوسط بارش Average precipitation (mm)	متوسط دما Average temperature (°C)
مراغه-بناب Maragheh- Bonab	1163	تازه کند Tazekand	صوفی چای Soufi Chai	1600	310.5	9.7
مراغه-بناب Maragheh- Bonab	1163	اسفناج Esfastanch	اسفناج چای Esfastanch Chai	1557	311.0	10.3
مراغه-بناب Maragheh- Bonab	1163	مراغه Maragheh	مراغه چای Soufi Chai	1478	312.7	12.8
مراغه-بناب Maragheh- Bonab	1163	چکان Chekan	چکان چای Chekan Chai	1289	285.6	12.2
مراغه-بناب Maragheh- Bonab	1163	بناب Bonab	صوفی چای Soufi Chai	1440	345.7	13.1
مراغه-بناب Maragheh- Bonab	1163	خرمازرد Khormazard	ماهپری چای Mahpari Chai	1600	350.7	8.7



شکل ۲- شماتیک ورودی و خروجی مدل SVM و RF

Figure 2 Schematic of SVM and BT model inputs and outputs

جدول ۳- ترکیب ورودی از داده‌های P و Q


Table 3- Input combination of Q and P data

خروجی Output	ورودی Input	مدل Model	ردیف No.
Q <sub>t</sub>	P <sub>t</sub> , Q <sub>t-1</sub>	جنگل تصادفی Random Forest	1
Q <sub>t</sub>	P <sub>t</sub> , Q <sub>t-1</sub>	ماشین بردار پشتیبان Support Vector Machin	2

دو ترکیب ورودی از داده‌های P و Q ساخته شد (همانطور که در جدول ۳ مشاهده می‌شود) و مدل SVM و RF برای مدل‌سازی بارش-رواناب برای ترکیب ورودی استفاده شد (شکل ۲).

ترکیب مشخص ورودی رواناب و بارندگی برای مدل‌سازی مورد ارزیابی قرار گرفت. ورودی‌ها مقادیر P و Q ماهانه قبلاً ثبت شده (P<sub>t</sub>، Q<sub>t-1</sub>) را ارائه می‌دهند و خروجی مربوط به داده‌های رواناب فعلی (Q<sub>t</sub>) است، که در آن، زیر نویس t نشان‌دهنده مرحله زمانی است. در نتیجه،





شکل ۳- تقسیم‌بندی چند ضلعی تیسسن دشت مراغه  
Figure 3- Thiessen polygon partitioning of the Eastern Lake Urmia Basin

یادگیری ماشین محسوب می‌شود. همان‌طور که از نام آن مشهود است، این الگوریتم جنگلی را به‌طور تصادفی می‌سازد (شکل ۴). جنگل ساخته شده در واقع گروهی از درخت‌های تصمیم است. کار ساخت جنگل با استفاده از درخت‌ها اغلب اوقات به روش کیسه‌گذاری انجام می‌شود. ایده اصلی روش کیسه‌گذاری آن است که ترکیبی از مدل‌های یادگیری، نتایج کلی مدل را افزایش می‌دهد. به بیان ساده، جنگل تصادفی چندین درخت تصمیم می‌سازد و آنها را با یکدیگر ادغام می‌کند تا پیش‌بینی‌های صحیح‌تر و پایدارتری به‌دست آید (Youssef *et al.*, 2015). این الگوریتم را نخستین بار بریمان (Breiman, 2001) ایجاد کردند و توسعه دادند. مدل پیش‌بینی کننده RF بر اساس میانگین‌گیری از نتایج حاصل از تمامی درخت‌های تصمیم مربوط استوار است و برای بسیاری از مجموعه داده‌ها، طبقه‌بندی با صحت بالایی را انجام می‌دهد (Catani *et al.*, 2013). درختان تصادفی با در نظر گرفتن بردار ورودی، آن را با هر درخت در جنگل، طبقه‌بندی کرده و خروجی، کلاس‌هایی هستند که از اکثریت آرا دریافت شده است. در این مدل از دو عامل میانگین‌کاهشی دقت و میانگین‌کاهشی جینی برای تعیین اولویت تأثیر هر یک از عوامل مؤثر استفاده می‌شود (Nicodemus *et al.*, 2011). الگوریتم جنگل تصادفی (RF) مبتنی بر دسته‌ای از درخت‌های تصمیم است و در حال حاضر یکی از بهترین الگوریتم‌های یادگیری است. هر درخت به صورت زیر تشکیل می‌شود:  
اگر  $N$  تعداد حالت‌ها در مجموعه داده‌های train (مجموعه کار)

محاسبه متوسط بارندگی از طریق روش Thiessen Polygons (چند ضلعی تیسسن)

چند ضلعی‌های تیسسن، که سلول‌های Voronoi هستند (Aurenhammer *et al.*, 2013) جهت تعریف چندضلعی بارش معادل مساحت سطح  $A_i$  برای وزن کردن بارندگی هر باران سنج  $r_i$  استفاده می‌شود. سپس، بارندگی با وزن مساحت معادل برابر است با:

$$r_{th}(t) = \frac{\sum_{i=1}^n r_i(t) \cdot A_i}{\sum_{i=1}^n A_i} \quad (1)$$

همان‌طور که در شکل ۳ نشان داده شده است، چند ضلعی‌های تیسسن مربوطه با استفاده از سیستم اطلاعات جغرافیایی کوانتومی تولید شدند (Shekar & Xiong, 2018)، و بارندگی معادل با استفاده از معادله (۱) محاسبه شد.

الگوریتم جنگل تصادفی (Random-Forest)

جنگل تصادفی، نوعی الگوریتم یادگیری ماشین و نظارت شده با قابلیت استفاده آسان است که اغلب اوقات نتایج بسیار خوبی را حتی بدون تنظیم پارامترهای آن، فراهم می‌کند (Catani *et al.*, 2013). جنگل‌های تصادفی یک نوع مدرن از روش‌های درخت-پایه هستند که شامل انبوهی از درخت‌های کلاس‌بندی و رگرسیونی می‌باشند (Breiman 2001). این الگوریتم به‌دلیل سادگی و قابلیت استفاده، هم برای دسته‌بندی و هم رگرسیون، از پرکاربردترین الگوریتم‌های

ماشین‌های بردار پشتیبان، طبقه‌بندی و خطی‌سازی یا رگرسیون داده‌ها است. روشی است که هم برای گروه‌بندی و هم برای تخمین و برآورد تابع برازش داده‌ها در مسائل رگرسیون به کار می‌رود به طوری که کمترین خطا در گروه‌بندی داده‌ها یا تابع برازش رخ دهد. SVM الگوریتمی است که نوع خاصی از مدل‌های خطی را می‌یابد که حداکثر حاشیه ابر صفحه را حاصل می‌کنند. به نزدیک‌ترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان گفته می‌شود و تنها از این بردارها (نقاط) برای مشخص کردن مرز بین طبقات استفاده می‌شود. شکل ۵ فرآیند مدل SVM را نشان می‌دهد. هدف پیدا کردن فرم تابعی برای  $f(x)$  است.

$$f(x) = W^T \cdot \phi(x) + b \quad (2)$$

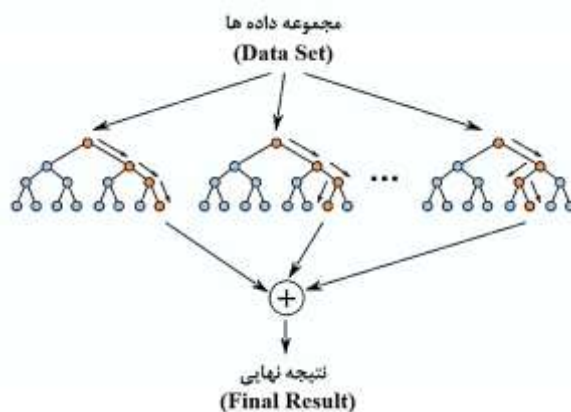
$$y(t) = \sum_{k=1}^k w_k \cdot h_{a,b}(t) \quad (3)$$

بردار ضریب  $W$  و ثابت  $b$  و تابع کرنل  $\phi$  در این رابطه با حل مساله بهینه‌سازی محدب و با استفاده از روش لاگرانژین و اصل کمینه‌سازی خطای ساختاری بدست می‌آیند. می‌توان از توابع مختلف کرنل برای ساخت انواع مختلف SVM استفاده کرد. انواع کرنل عبارتند از: کرنل چند جمله‌ای با سه مشخصه هدف، کرنل توابع پایه (RBF) با یک مشخصه هدف و کرنل خطی. در مطالعات بارش - رواناب عمدتاً از تابع RBF استفاده می‌شود زیرا ماشین بردار پشتیبان با این نوع تابع در مقایسه با سایر توابع از دقت بیشتری در شبیه‌سازی این پدیده برخوردار است (Eskandari et al., 2011)، که رابطه آن به صورت (۳) می‌باشد.


باشد،  $N$  حالت به صورت تصادفی با جای‌گذاری از داده‌های اصلی، نمونه‌گیری می‌شود. این نمونه مجموعه کار برای این درخت می‌باشد. اگر  $M$  متغیر وجود داشته باشد و  $m$  کوچکتر از  $M$  در نظر گرفته شود، به طوری که در هر گره،  $m$  متغیر به صورت تصادفی از  $M$  انتخاب می‌شوند و بهترین جداسازی روی این  $m$  متغیر برای جداسازی گره استفاده می‌شود. مقدار  $m$  در طول ساخت جنگل ثابت در نظر گرفته می‌شود. هر درخت به اندازه ممکن بزرگ می‌شود. هیچ هرسی وجود ندارد. نرخ خطای جنگل به دو مورد زیر بستگی دارد: الف - همبستگی بین هر دو درخت در جنگل: افزایش همبستگی نرخ خطای جنگل را افزایش می‌دهد. ب - قدرت هر یک از درختان در جنگل: هر درخت با نرخ خطای کم، یک طبقه‌بند قوی است. افزایش قدرت هر یک از درختان نرخ خطای جنگل را کاهش می‌دهد. از جمله مزیت‌های جنگل تصادفی می‌توان به موارد زیر اشاره نمود: ۱. در میان الگوریتم‌های فعلی از نظر دقت کم نظیر است. ۲. روی داده‌های بسیار بزرگ قابل اجراست. ۳. می‌تواند هزاران متغیر را بدون حذف متغیرها مدیریت کند. ۴. برآوردی از مهم‌ترین متغیرها در طبقه‌بندی می‌دهد. ۵. راهکارهایی برای برآورد داده‌های گم شده دارد (Geshnigani et al., 2021).

#### الگوریتم ماشین بردار پشتیبان (SVM)

ماشین‌های بردار پشتیبان همانند دیگر روش‌های هوش مصنوعی بر مبنای الگوریتم داده کاوی عمل می‌کنند. مهم‌ترین وظایف مدل



شکل ۴- ساختار الگوریتم جنگل تصادفی  
Figure 4- Structure of RF Algorithm



شکل ۵- فرایند مدل SVM (سیدیان و همکاران، ۱۳۹۳)  
Figure 5- SVM model process (Seyedian et al., 2014)

### معیارهای ارزیابی

برای ارزیابی مدل‌ها و مقایسه کارایی آن‌ها، در این پژوهش از معیارهای، جذر میانگین مربعات خطا (RMSE)، ضریب همبستگی (r)، ضریب تبیین (R<sup>2</sup>) و ضریب کارایی نش- ساتکلیف (NS) استفاده می‌شود. در ادامه روابط این معیارها ارائه شده است:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (۴)$$

$$r = \frac{n(\sum_{i=1}^n O_i \cdot P_i) - (\sum_{i=1}^n O_i) \cdot (\sum_{i=1}^n P_i)}{\sqrt{(n \sum_{i=1}^n O_i^2 - (\sum_{i=1}^n O_i)^2) \cdot (n \sum_{i=1}^n P_i^2 - (\sum_{i=1}^n P_i)^2)}} \quad (۵)$$

$$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O}_i) \cdot (P_i - \bar{P}_i)]^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \cdot \sum_{i=1}^n (P_i - \bar{P}_i)^2} \quad (۶)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (P_i - \bar{P})^2} \quad (۷)$$

در روابط فوق، n تعداد داده‌ها، P<sub>i</sub> داده‌های مشاهداتی  $\bar{Q}$  میانگین داده‌های مشاهداتی و Q<sub>i</sub> داده‌های محاسباتی می‌باشد. هر چقدر مقدار r به عدد یک نزدیک‌تر باشد، برآورد و برازش بهتر را نشان می‌دهد. ضریب کارایی نش- ساتکلیف می‌تواند از منفی بی‌نهایت تا ۱ تغییر کند، هرچه مقادیر به عدد یک نزدیک‌تر باشد، مدل برازش بهتری دارد و عدد یک برازش عالی را نشان می‌دهد. RMSE جذر میانگین مربع خطاهای داده‌های محاسباتی و مشاهداتی را بیان می‌کند. واضح است که هر چه مقدار این عدد کمتر باشد، عملکرد مدل در شبیه سازی داده‌ها بهتر است. امروزه یکی از ابزارهای تعیین تغییرهای اقلیمی تحلیل روند می‌باشد. روش‌های متفاوتی برای تعیین روند وجود دارند که به دو دسته تقسیم می‌شوند: روش پارامتریک و ناپارامتریک. در اصل گفته می‌شود که آزمون‌های پارامتریک در صورتی که داده‌ها به صورت نرمال باشند، قوی‌تر از آزمون‌های ناپارامتریک هستند ولی در شرایط داده‌های غیرنرمال، آزمون ناپارامتریک قوی‌تر از پارامتریک است (Sabouhi & Soltani, 2008).

از آنجایی که توزیع تعدادی از سری‌های اقلیمی از جمله بارش و دبی نرمال نیست، در چنین حالت‌هایی روش من- کندال مناسب‌تر است (Pasquini, 2006). تحلیل روند در این مطالعه با استفاده از آزمون ناپارامتریک من-کندال انجام شد. آزمون من- کندال ابتدا توسط Mann (1945) مطرح و سپس توسط Kendall (1975) بسط و توسعه یافت (Serrano et al., 1999). این روش بطور متداول و گسترده‌ای در تحلیل روند سری‌های زمانی هیدرولوژیکی و هواشناسی بکار گرفته می‌شود (Lettenmaier, 1994). از نقاط قوت این روش می‌توان به مناسب بودن کاربرد آن برای سری‌های زمانی‌ای که از توزیع آماری خاصی پیروی نمی‌کنند، اشاره کرد. اثرپذیری ناچیز این روش از مقادیر حدی که در برخی از سری‌های زمانی مشاهده می‌گردند نیز از دیگر مزیت‌های استفاده از این روش است (Turgay & Ercan, 2005). فرض صفر این آزمون بر تصادفی بودن و وجود نداشتن روند در سری داده‌ها دلالت دارد و پذیرش فرض یک (رد فرض صفر) دال بر وجود روند در سری داده‌ها می‌باشد. آزمون من - کندال با تعریف آماره S به شکل زیر تعریف می‌شود:

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sign}(X_i + X_j) \quad (۸)$$

که در آن X<sub>i</sub> و X<sub>j</sub> مقادیر مرتب شده‌ی نمونه و n تعداد نمونه است. مقدار Sign (x<sub>j</sub> - x<sub>i</sub>) برای 0 < (x<sub>j</sub> - x<sub>i</sub>) برابر با منفی یک، 0 = (x<sub>j</sub> - x<sub>i</sub>) برابر با صفر و برای 0 > (x<sub>j</sub> - x<sub>i</sub>) برابر با یک است. مقدار نمره استاندارد شده Z و واریانس آماره S نیز از رابطه‌ی زیر محاسبه می‌شود:

$$Z_c = \begin{cases} \frac{S-1}{\sqrt{\text{Var}(S)}} & , S > 0 \\ 0 & , S = 0 \\ \frac{S+1}{\sqrt{\text{Var}(S)}} & , S < 0 \end{cases} \quad (۹)$$

مقادیر مثبت Z نشان‌دهنده‌ی روندهای افزایشی و مقادیر منفی Z نشان‌دهنده‌ی روندهای کاهشی است. در شرایطی که s=0 باشد داده‌ها فاقد روند بوده و هیچ روند معنی‌داری یا غیر معنی‌داری در داده‌ها وجود ندارد که این شرایط ایده‌آل برای داده‌های هیدرولوژیکی

به ندرت ممکن است اتفاق بیفتد. در این مطالعه سطح‌های معنی‌داری  $P=0.05$  بکار گرفته شده است.


## نتایج و بحث

سری زمانی مربوط به بارش و رواناب در دو دوره مطالعاتی قبل و بعد ۱۳۷۴ در شکل ۶ نشان داده شده است. بررسی اشکال فوق نشان داد که در ایستگاه بناب و برای دو دوره مطالعاتی، مقدار آماره‌ی من کندال برای متغیر بارش به ترتیب برابر با  $0.044$  و  $0.028$  و برای ایستگاه خرمازرد این مقدار آماره برای دوره اول و دوم به ترتیب برابر با  $0.030$  و  $0.028$  بدست آمد که در سطح ۹۵ درصد معنادار نمی‌باشد که مؤید این است که بارش سالانه در این سال‌ها برای دو ایستگاه مورد مطالعاتی از نظر آماری معنادار نیست. بنابراین این گونه استنباط می‌شود که بارش سالانه در این ایستگاه‌ها در سال‌های ۱۳۵۵ تا ۱۳۹۷ دارای روند نبوده و تغییرهای رخ داده در این دوره زمانی طبیعی می‌باشد و سری زمانی بارش نوسانی می‌باشد و در برخی سال‌ها روند افزایشی و در برخی دیگر روند کاهشی داشته است. صالحی و همکاران (Salehi Bavi et al., 2017) گزارش کردند که نوسانات بارش در زیرحوضه‌های دریاچه ارومیه وجود دارد و در بارندگی‌های ماهانه کمتر از ۵ میلی‌متر در سطح احتمال ۱ درصد افزایش معنی‌داری داشته و در برخی محدوده‌ها روند معنی‌داری نشان نداده است، در حالی که محدوده ۱۰ تا ۱۵ میلی‌متر روند کاهش معنی‌داری را نشان می‌دهد. اما شکل ۶ سری زمانی دبی‌های خروجی از هر دو ایستگاه را نیز نشان می‌دهد. بررسی سری‌های زمانی نتایج متفاوتی را نشان می‌دهد، همانطور که مشاهده می‌شود در دوره مطالعاتی دبی خروجی از ایستگاه بناب (a و b) روند نوسانی داشته و بصورت کاهشی-افزایشی است و نهایتاً در سال‌های آخر جریان خروجی از این ایستگاه افزایش یافته است. مقدار آماره آزمون من کندال برای دو دوره مطالعاتی برای این ایستگاه به ترتیب برابر با  $0.325$  و  $0.512$  بوده و در سطح ۹۵ درصد معنادار می‌باشد و نشان می‌دهد در دو دوره زمانی مورد مطالعه، روند افزایشی دبی معنادار بوده است که می‌تواند به این دلیل باشد که در ایستگاه بناب نسبت به سایر ایستگاه‌های ورودی به دریاچه ارومیه، میزان تأمین نیاز آب اراضی کشاورزی و صنایع در حوضه صوفی‌چای نسبت به سایر رودخانه‌ها کمتر بوده است که برای بررسی دقیق علت این موضوع، باید مطالعاتی جهت بررسی آب‌های زیرزمینی و سطحی و همچنین مصرف آب در بخش‌های کشاورزی و صنعت این منطقه انجام داد. از طرفی با توجه به این تغییرات بارش و دبی، می‌توان با توجه به نتایج تحقیق منتصری و همکاران (Montaseri et al., 2018) که روی این منطقه انجام داده‌اند، می‌توان دوره اول را ترسالی و دوره دوم را خشکسالی دانست. در تحقیق ایشان، وضعیت منطقه مطالعه شده در هفت گروه شامل قبل از سال ۱۳۶۰ شرایط نرمال با گرایش به خشکسالی ضعیف،

۱۳۶۱-۱۳۶۷ وضعیت نرمال و ترسالی ضعیف، ۱۳۶۸-۱۳۷۱ نرمال با گرایش به خشکسالی ضعیف، ۱۳۷۲-۱۳۷۷ وضعیت نرمال و ترسالی ضعیف، ۱۳۷۸-۱۳۸۲ شرایط نرمال با گرایش به خشکسالی ضعیف، ۱۳۸۴-۱۳۸۶ نرمال با گرایش به ترسالی ضعیف و ۱۳۸۷-۱۳۹۲ شرایط نرمال با گرایش به خشکسالی ضعیف طبقه‌بندی شد.

از طرف دیگر، در ایستگاه خرمازرد (c و d) رودخانه ماهپری‌چای روند متفاوتی را ثبت کرده است، بدین‌صورت که در این ایستگاه، دبی خروجی از آن برخلاف ایستگاه بناب کاملاً روند نزولی داشته است و مقدار آماره آزمون من کندال برای متغیر دبی در دو دوره تحقیقاتی ما به ترتیب میزان  $-0.269$  و  $-0.412$  بوده‌اند و در سطح ۹۵ درصد روند کاهشی دبی در این ایستگاه معنادار بوده است. از طرفی همانطور که مشاهده می‌شود حجم دبی در این ایستگاه هیدرومتری بعد از سال ۱۳۷۴ (d) به شدت کاهش یافته است و بغیر از سال ۱۳۸۶ که میزان دبی به طور ناگهانی افزایش داشته است، در تمامی سال‌ها، میزان حجم آب ورودی به دریاچه ارومیه در کمترین حد خود بوده است که با توجه به این که در سایر مطالعات اخیر ایستگاه‌های مطالعاتی زیرحوضه ارومیه این کاهش دبی ورودی به دریاچه محسوس است، می‌تواند زنگ خطری برای دریاچه ارومیه محسوب شود. ناظری و همکاران (Nazeri Tahroudi et al., 2018) روند کاهشی داده‌های سطح آب دریاچه ارومیه را یک سال پس از روند کاهشی داده‌های جریان گزارش کرد. عوامل بسیاری در کاهش جریان رواناب دخیل هستند که یکی از دلایل اصلی آن استفاده از آب رودخانه‌ها در کشاورزی و صنعت می‌باشد. دلیل بعدی را می‌توان احداث سد بر روی رودخانه‌ها نام برد. مطالعات زیادی برای بررسی تغییرات روند جریان رودخانه و میزان بارش حوضه دریاچه ارومیه انجام شده است و همه آنها تأیید می‌کنند که کاهش رواناب رودخانه‌های حوضه دریاچه ارومیه چشمگیر بوده است. دلایل زیادی برای این کاهش وجود دارد چنانچه در مقابل ۱۳ رودخانه ورودی به دریاچه سدسازی شده است (Hosseini-Moghari et al., 2020، Lari et al., Bashirian et al., 2020، Javadzadeh et al., 2020، Hamidi-Razi et al., 2019، et al., 2019، Vaheddoost et al., 2018).

جهت بررسی ایستگاه‌های بناب و خرمازرد در دو دوره، آمار بارندگی و رواناب (میانگین، حداقل، حداکثر) برای دوره اول (۱۳۷۴-۱۳۵۵) و دوره دوم (۱۳۹۷-۱۳۷۵) در جدول ۴ و جدول ۵ ارائه شده است. همانطور که مشاهده می‌شود، ابتدا جداول به پنج ستون تقسیم شده و سپس ستون‌های سوم، چهارم و پنجم به دو قسمت تقسیم شدند. ستون سوم (تمام داده‌ها) شامل بخش‌های P و Q بود. در ستون چهارم و پنجم، مجموعه آموزشی و تست نشان داده شده است. بنابراین، مدل‌های RF و SVM (تابع کرنل) با داده‌های واقعی آموزش و آزمایش شدند.



شکل ۶- سری زمانی متوسط بارش و دبی خروجی از ایستگاه‌های بناب (a و b) و خرم‌زرد (c و d) در دوره‌های قبل و بعد ۱۳۷۴

Figure 6- Time series plots of the observed rainfall and runoff values at Bonab (a and b) and Khormazard (c and d) stations before and after 1995

جدول ۴- پارامترهای آماری داده‌های بارندگی و رواناب در مدت ۱۳۷۴-۱۳۵۵

Table 4- Statistical parameters of the rainfall and runoff data 1976-1994

ایستگاه Station	پارامتر Parameter	داده ورودی Entire data 1976-1994		مجموعه آموزشی Training set		مجموعه تست Test set	
		P	Q	SVM	RF	SVM	RF
بناب Bonab	میانگین Mean	31.48	2.02	2.00	1.99	2.15	1.96
	حداقل Minimum	0.00	0.00	0.00	0.00	0.00	0.00
	حداکثر Maximum	98.46	14.81	14.57	11.70	14.81	14.81
	میانگین Mean	28.16	0.34	0.36	0.36	0.33	0.30
خرمازرد Khormazard	حداقل Minimum	0.00	0.00	0.00	0.03	0.03	0.00
	حداکثر Maximum	88.15	2.86	2.86	1.94	1.68	2.86

جدول ۵- پارامترهای آماری داده‌های بارندگی و رواناب در مدت ۱۳۹۷-۱۳۷۵

Table 5- Statistical parameters of the rainfall and runoff data 1995-2019

ایستگاه Station	Parameter	Entire data 1995-2019		Training set		Test set	
		P	Q	SVM	RF	SVM	RF
بناب Bonab	میانگین Mean	27.85	2.07	1.87	1.98	2.30	2.03
	حداقل Minimum	0.00	0.00	0.00	0.00	0.00	0.00
	حداکثر Maximum	99.93	14.37	13.98	13.98	14.37	13.8
	میانگین Mean	25.59	0.19	0.18	0.18	0.13	0.20
خرمازرد Khormazard	حداقل Minimum	0.00	0.00	0.00	0.00	0.00	0.00
	حداکثر Maximum	94.18	3.23	3.23	3.23	1.38	2.11

دوره مطالعاتی در ایستگاه بناب مدل SVM نسبت به مدل RF عملکرد بهتری داشته است و با دقت خوبی توانسته دبی جریان و بارش ماهانه را شبیه‌سازی کند. همچنین در این دوره‌ها در ایستگاه خرمازرد مدل RF کارایی بهتری را نسبت به مدل SVM نشان می‌دهد.

همانطور که در جدول ۶ (دوره اول) به وضوح دیده می‌شود همبستگی متقابل (CC) در مدل SVM در ایستگاه بناب برای داده‌های آموزشی ۰/۸۶ و در داده‌های تست ۰/۸۵ بدست آمده است. عدد  $R^2$  نیز در این مدل برای داده‌های آموزشی و تست به ترتیب برابر با ۰/۷۴ و ۰/۷۳ تعیین شد. شاخص کارایی نش سانتکلیف داده‌های آموزشی و تست به ترتیب برابر است با ۰/۷۳ و ۰/۷۲ و آخرین شاخص که در این مطالعه مورد بررسی قرار گرفته است خطای جذر میانگین مربعات می باشد و مقدار آن برای داده‌های آموزشی و تست به ترتیب برابر با ۱/۵۲ و ۱/۷۳ بدست آمده است. اما در این دوره برای ایستگاه خرمازرد، مقدار

طبق جداول در هر دو مقطع، در ستون داده کل، ایستگاه بناب بیشترین میانگین بارندگی و رواناب را داشته و کمترین مقادیر میانگین بارندگی و رواناب به ایستگاه خرمازرد مربوط می‌شود.

#### نتایج مدل‌سازی رواناب با استفاده از مدل ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF)

همانطور که گفته شد به منظور مدل‌سازی داده‌های بارش-رواناب با استفاده از دو مدل SVM و RF بخشی از داده‌ها جهت آموزش و بخشی دیگر جهت صحت‌سنجی مورد استفاده قرار گرفت. در جدول ۵ و جدول ۶ مقادیر شاخص‌های آماری محاسبه شده مربوط به نتایج بخش آموزش و صحت‌سنجی در هر دو مدل SVM و RF ارائه شده است. با توجه به نتایج جدول ۶ و جدول ۷ مشخص است که در هر دو



ایستگاه‌های بناب و خرمازرد زیرحوضه مراغه مناسب دانست. از طرفی دیگر با توجه به نتایج **جدول ۶** و **جدول ۷**، مشاهده می‌شود که اثر سال‌های ترسالی و خشکسالی در دوره مطالعاتی اول و دوم، بر روی دقت مدل‌ها مؤثر بوده است و در دوره خشکسالی (دوم) در این مطالعه، دقت مدل‌ها کاهش یافته است. بنابراین می‌توان برای پیش‌بینی رواناب در سال‌های آینده از مدل‌های برتر این مطالعه استفاده کرد. همچنین در **شکل ۷** نمودار پراکنش مقادیر مشاهداتی در برابر مقادیر شبیه‌سازی شده دبی‌های ماهانه، توسط مدل‌های ماشین بردار پشتیبان و جنگل تصادفی برای دو ایستگاه بناب و خرمازرد در دو دوره مطالعاتی نشان داده شده است. خط‌های برازش داده شده در **شکل ۷** نشان‌دهنده همبستگی بین داده‌های مشاهداتی و داده‌های مدل می‌باشد که نتایج بدست آمده از جداول بالا نیز این موضوع را تصدیق می‌کند.

در **شکل ۷** نمودار پراکنش مقادیر مشاهداتی در برابر مقادیر شبیه‌سازی شده دبی‌های ماهانه توسط مدل ماشین بردار پشتیبان و جنگل تصادفی برای داده‌های بخش صحت سنجی دو ایستگاه مورد مطالعاتی نشان داده شد. با توجه به شکل‌های پراکنش پیش‌بینی دو مدل، مدل SVM برای ایستگاه بناب و مدل RF برای ایستگاه خرمازرد نه تنها با درجه همبستگی (R) بیشتری فرآیند بارش - رواناب ماهانه را در این تحقیق شبیه‌سازی نموده است، بلکه تا حدودی در برآورد مقادیر حداکثر رواناب عملکرد بهتری داشته‌اند.

CC برای دوره‌های آموزشی و تست مدل RF برابر با ۰/۸۰ و ۰/۷۹ ثبت گردید. مقدار  $R^2$  برای این مدل، برای داده‌های آموزشی ۰/۶۴ و برای داده‌های تست ۰/۶۲ تعیین شد. شاخص NSE برای این مدل و دوره‌های آموزشی و تست، ۰/۸۰ و ۰/۵۶ تعیین شد. اما آخرین شاخص خطای جذر میانگین مربعات به ترتیب برابر با ۰/۲۰ و ۰/۳۰ برای مجموعه آموزشی و تست ثبت گردید. اما در **جدول ۷** (دوره دوم (۱۳۹۷-۱۳۷۵)) و برای ایستگاه بناب، مقدار CC برابر با ۰/۸۶ و ۰/۸۴ (آموزشی و تست) بدست آمد.

همچنین مقدار  $R^2$  برای دوره‌های آموزشی و تست، ۰/۷۳ و ۰/۷۱ و مقدار شاخص NSE برای مجموعه آموزشی و تست ۰/۷۰ و ۰/۶۶ تعیین گردید. آخرین پارامتر خطای جذر میانگین مربعات برای دوره آموزش و تست به ترتیب برابر با ۱/۱۹ و ۱/۶۷ بدست آمد. اما مقادیر مدل RF برای ایستگاه خرمازرد و برای پارامتر CC و مجموعه آموزشی و تست به ترتیب ۰/۷۳ و ۰/۷۵، پارامتر  $R^2$ ، ۰/۵۳ و ۰/۴۳، پارامتر NSE برابر با ۰/۵۲ و ۰/۵۶ و آخرین پارامتر RMSE به ترتیب با ۰/۲۴ و ۰/۲۳ تعیین گردید. حال با توجه به اینکه در تحلیل مقالات از داده‌های تست برای بررسی عملکرد مدل‌ها استفاده می‌شود، می‌توان گفت در این مطالعه نیز CC،  $R^2$ ، NSE و RMSE بدست آمده در داده‌های تست، برای بارش و رواناب اعداد قابل قبولی هستند و می‌توان کارایی و عملکرد مدل ماشین بردار پشتیبان و جنگل تصادفی را برای

جدول ۶- عملکرد مدل‌های RF و SVM در مجموعه‌های آموزشی و آزمایشی در مدت ۱۳۷۴-۱۳۵۵

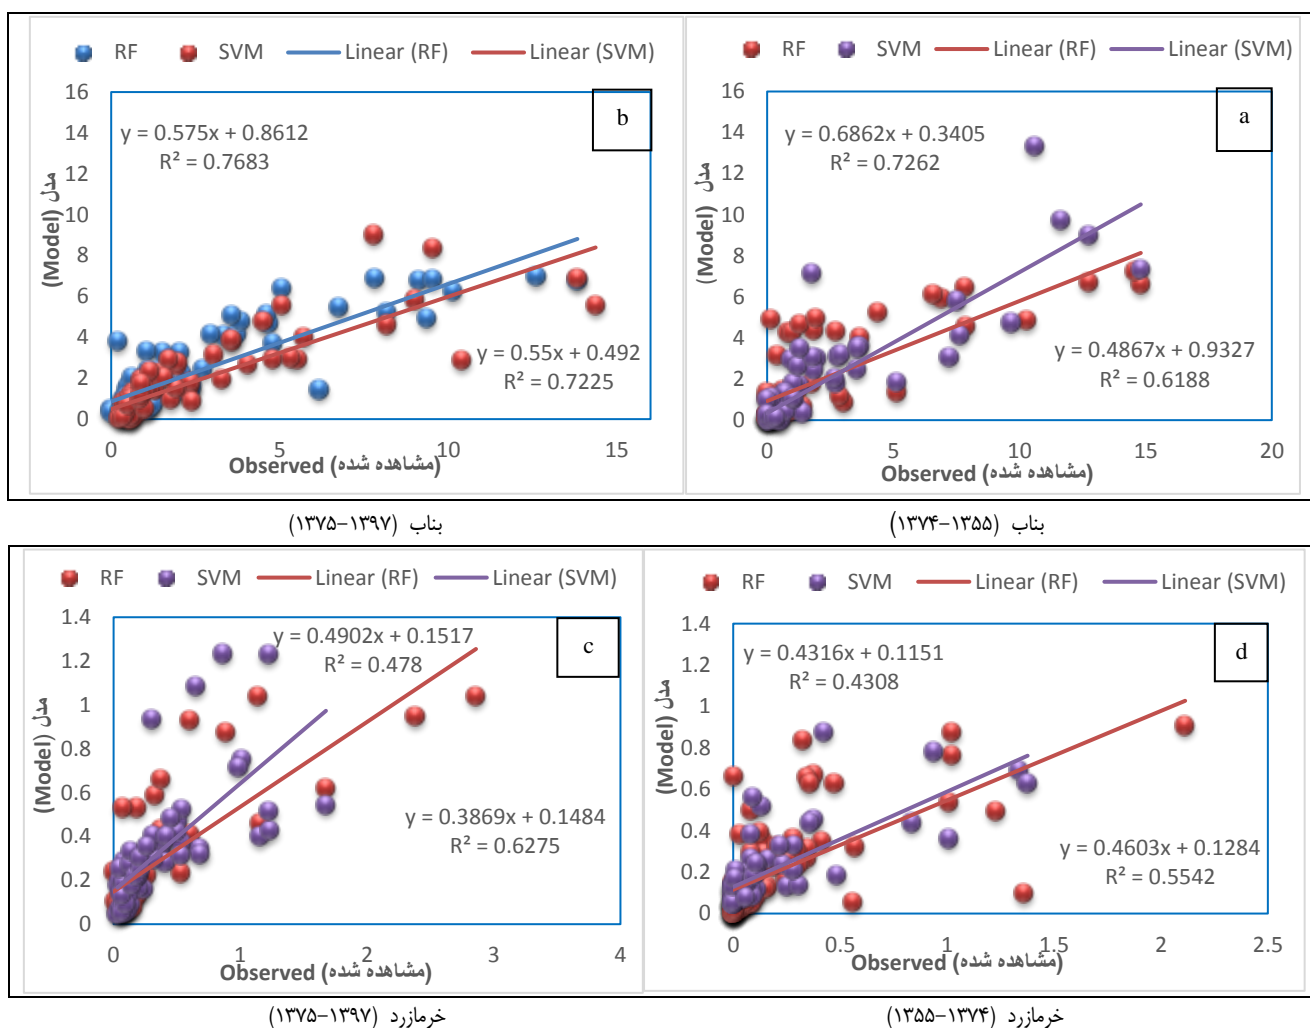
Table 6- Performance of RF and SVM models in the training and testing sets 1976-1994

ایستگاه Station	داده ورودی Entire data 1976-1994	Cross Correlation		$R^2$		NSE		RMSE	
		SVM	RF	SVM	RF	SVM	RF	SVM	RF
بناب Bonab	آموزش Train	0.86	0.86	0.74	0.75	0.73	0.73	1.52	1.42
	تست Test	0.85	0.79	0.73	0.62	0.72	0.59	1.73	2.15
خرمازرد Khormazard	آموزش Train	0.82	0.80	0.67	0.64	0.66	0.80	0.28	0.20
	تست Test	0.69	0.79	0.48	0.62	0.48	0.56	0.25	0.30

جدول ۷- عملکرد مدل‌های RF و SVM در مجموعه‌های آموزشی و آزمایشی در مدت ۱۳۹۷-۱۳۷۵

Table 7- Performance of RF and SVM models in the training and testing sets 1976-1994

ایستگاه Station	داده ورودی Entire data 1995-2019	Cross Correlation		$R^2$		NSE		RMSE	
		SVM	RF	SVM	RF	SVM	RF	SVM	RF
بناب Bonab	آموزش Train	0.86	0.89	0.73	0.79	0.70	0.78	1.19	1.04
	تست Test	0.84	0.83	0.71	0.69	0.66	0.72	1.67	1.29
خرمازرد Khormazard	آموزش Train	0.62	0.73	0.38	0.53	0.36	0.52	0.27	0.24
	تست Test	0.74	0.75	0.55	0.43	0.49	0.56	0.19	0.23



شکل ۷- نمودارهای پراکنده رواناب شبیه‌سازی شده با استفاده از SVM و RF ایستگاه بناب (a و b) و خرمزرد (c و d) در دوره‌های مطالعاتی قبل و بعد سال ۱۳۷۴

Figure 7- Verification scatter plots of simulated runoff using RF and SVM at Bonab (a and b) and Khormazard (c and d) stations before and after 1995

### نتیجه‌گیری

(۱۳۵۵) و بعد آن (۱۳۷۵-۱۳۹۷) تقسیم شود. مقدار بارش و رواناب با لگ زمانی یک ماهه بعنوان ورودی به این مدل وارد و سپس مقادیر رواناب ماهانه مشاهداتی با رواناب ماهانه تخمین زده شده با استفاده از معیارهای ارزیابی مورد بررسی گرفت. نتایج نشان داد که در هر دو دوره برای ایستگاه بناب مدل SVM کارایی بالاتری نسبت به مدل RF داشت و در ایستگاه خرمزرد نیز برای این دو دوره، مدل RF عملکرد بهتری از مدل SVM ارائه کرد. نتایج نشان داد که مقدار همبستگی متقابل برای مجموعه تست و در دو دوره مطالعاتی اول و دوم ایستگاه بناب به ترتیب ۰/۸۵ و ۰/۸۴ بدست آمد. اما مقدار این شاخص برای ایستگاه خرمزرد در دو دوره مطالعاتی مطرح شده و برای مجموعه تست

شبیه‌سازی دقیق فرآیند رواناب می‌تواند نقش بسزایی در مدیریت منابع آب و مسائل مربوطه داشته باشد. در این تحقیق با استفاده از مدل‌های داده‌کاوی الگوریتم ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) اقدام به شبیه‌سازی بارش- رواناب دو ایستگاه خرمزرد و بناب (روی رودخانه‌های صوفی‌چای و ماهپری‌چای) شده است. در مطالعه حاضر داده‌های ایستگاه‌های هواشناسی و هیدرومتری دشت مراغه از سال ۱۳۵۵ تا ۱۳۹۷ از شرکت آب منطقه‌ای و سازمان هواشناسی استان آذربایجان شرقی دریافت گردید. تغییر روند رواناب جاری در سال ۱۳۷۴، باعث گردید مدت مطالعه به دو دوره قبل (۱۳۷۴-۱۳۵۵)

بصورت افزایشی مشاهده گردید. اما در ایستگاه خرمازرد وضعیت بصورت دیگری است و در هر دو دوره مطالعاتی روند دبی بصورت نزولی بوده و حجم جریان خروجی رودخانه ماهپری‌چای در سال‌های اخیر به شدت کاهش یافته است، مقدار آماره من کندال نیز روند کاهشی را نشان داد. از دلایل مهم کاهش دبی ورودی رودخانه ماهپری‌چای در ایستگاه خرمازرد، استفاده از جریان آب در بخش کشاورزی و صنعت می‌باشد. با توجه به عملکرد خوب این مدل‌ها در شبیه‌سازی بارش- رواناب، می‌توان برای سایر ایستگاه‌های پایانی در حوضه دریاچه ارومیه نیز از این روش‌های یادگیری ماشین استفاده کرد.

مدل جنگل تصادفی به‌ترتیب برابر با  $0/79$  و  $0/75$  تعیین گردید. نتایج دیگر این پژوهش می‌توان به سری زمانی بارش و رواناب طی ۴۳ سال اشاره کرد. با توجه به نمودارهای بدست آمده برای هر دو ایستگاه و همچنین مقدار آماره من کندال برای هر دو ایستگاه و هر دو پارامتر بارش و دبی، در طی این دو دوره روند مشخصی برای بارش دیده نشد، در واقع نتایج نشان داد که بارش در این مناطق بصورت نوسانی بوده است. اما سری زمانی و مقدار آماره برای دبی رودخانه‌های صوفی‌چای و ماهپری‌چای در ایستگاه بناب و خرمازرد، نتایج متفاوتی نشان داد. در ایستگاه بناب، دبی خروجی از این ایستگاه در دوره اول مطالعاتی بصورت کاهشی و افزایشی بود اما در دوره دوم حجم خروجی از ایستگاه

## منابع

- Adnan, R.M., Yuan, X., Kisi, O., Adnan, F., & Mehmood, A. (2018). Stream flow forecasting of poorly gauged mountainous watershed by Least Square Support Vector Machine, Fuzzy Genetic Algorithm and M5 Model Tree using climatic data from Nearby Station. *Water Resources Management*, 32, 4469-4486. <https://doi.org/10.1007/s11269-018-2033-2>
- Aurenhammer, F., Klein, R., & Lee, D.T. (2013). *Voronoi Diagrams and Delaunay Triangulations*. World Scientific Publ. Co., Singapore p. 337.
- Band, S.S., Janizadeh, S., Chandra Pal, S., Saha, A., Chakraborty, R., Melesse, A.M., & Mosavi, A. (2020). Flash flood susceptibility modeling using new approaches of hybrid and ensemble tree-based machine learning algorithms. *Remote Sensing*, 12(21), 3568. <http://doi.org/10.3390/rs12213568-2-23>
- Bashirian, F., Rahimi, D., Movahedi, S., & Zakerinejad, R. (2020). Water level instability analysis of Urmia Lake Basin in the northwest of Iran. *Arabian Journal of Geosciences*, 13(4), 1-14. <https://doi.org/10.1007/s12517-020-5207-1>
- Bigdeli, Z., Majnooni Heris, A., Delirhasannia, R., & Karimi, S. (2023). Rainfall-runoff modeling of Aji Chai basin using random forest and artificial neural network models. *New Research Sustainable Water Engineering*, 1(2), 27-42. <http://doi:10.22103/mrswe.2023.20278.1013>
- Bigdeli, Z., Majnooni-Heris, A., Delirhasannia, R., & Karimi, S. (2023). Application of support vector machine and boosted tree algorithm for rainfall-runoff modeling (Case study: Tabriz plain). *Environment and Water Engineering*, 9(4), 532-547. <http://doi.org/10.22034/ewe.2023.366913.1816>
- Botsis, D., Latinopoulos, P., & Diamantaras, K. (2011). Rainfall-runoff modeling using support vector regression and artificial neural networks. *Journal Rhodes, Greece*. <https://doi.org/20.1001.1.20087942.1398.13.6.15.1>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- Catani, F., Lagomarsino, D., Segoni, S., & Tofani, V. (2013). Landslide susceptibility estimation by random forests technique: sensitivity and scaling issues. *Natural Hazards Earth System Science*, 13, 2815-2831. <https://doi.org/10.5194/nhess-13-2815-2013>
- Dastorani, M.T., Mahjoobi, J., Talebi, A., & Fakhar, F. (2018). Application of machine learning approaches in rainfall-runoff modeling (Case study: Zayandeh\_Rood Basin in Iran). *Civil Engineering Infrastructures Journal*, 51(2), 293-310. <https://doi.org/20.1001.1.23222093.2018.51.2.4.1>
- Eskandari, A., Noori, R., Meeraji, H., & Kiaghaderi, A. (2011). Development of an appropriate model based on artificial neural network and support vector machine to predict the 5-day biochemical oxygen demand while. *Ecology*, 38, 71-82. <https://doi.org/20.1001.1.10258620.1391.38.1.8.1>
- Fathollahi, S., Mirshahi, D., & Abbasipour, B. (2015). *Water and climate change: prediction of runoff from rainfall in the Aji Chai River basin using artificial neural network*, the first national congress of irrigation and drainage in Iran. (In Persian)
- Hamidi-Razi, H., Mazaheri, M., Carvajalino-Fernández, M., & Vali-Samani, J. (2019). Investigating the restoration of Lake Urmia using a numerical modelling approach. *Journal of Great Lakes Research*, 45(1), 87-97. <https://doi.org/10.1016/j.jglr.2018.10.002>
- Hosseini-Moghari, S.M., Araghinejad, S., Tourian, M.J., Ebrahimi, K., & Döll, P. (2020). Quantifying the impacts of human water use and climate variations on recent drying of Lake Urmia basin: the value of different sets of spaceborne and in situ data for calibrating a global hydrological model. *Hydrology & Earth System Sciences*, 24(4). <https://doi.org/10.5194/hess-24-1939-2020>
- Hussain, D., & Khan, A.A. (2020). Machine learning techniques for monthly river flow forecasting of Hunza River.

- Pakistan. *Earth Science Informatics*, 13(3), 939-949. <https://doi.org/10.1007/s12145-020-00450-z>
16. Javadzadeh, H., Ataie-Ashtiani, B., Hosseini, S.M., & Simmons, C.T. (2020). Spectral analysis of periodic behavior of Lake Urmia water level time series Interaction of lake-groundwater levels using cross correlation analysis: A case study of Lake Urmia Basin, Iran. *Science of The Total Environment*, 138822.
  17. Kendall, M.G. (1975). *Rank correlation methods*. fourth ed. Charles Griffin, London.
  18. Kisi, O., & Parmar, K.S. (2016). Application of least square support vector machine and multivariate adaptive regression spline models in long term prediction of river water pollution. *Journal of Hydrology*, 534, 104-112. <https://doi.org/10.1016/j.jhydrol.2015.12.014>
  19. Lari, A., Pishvae, M.S., & Khodabakhsh P. (2019). A system dynamics approach for basin policy design: Urmia Lake case study. *Kybernetes*. <https://doi.org/10.1108/K-04-2019-0226>
  20. Lettenmaier, D.P., Wood, E.F., & Wallis, J.R. (1994). Hydro-climatological Trends in the Continental United States, 1948-88. *Journal of Climate*, 7, 586-607. [https://doi.org/10.1175/1520-0442\(1994\)007<0586:HCTITC>2.0.CO;2](https://doi.org/10.1175/1520-0442(1994)007<0586:HCTITC>2.0.CO;2)
  21. Lorrai, M., & Sechi, M.G. (1995). Neural nets for modeling rainfall-runoff transformation. *Water Resources Management*, 9, 299-313. <https://doi.org/10.1007/BF00872489>
  22. Mann H.B. (1945). non-parametric test against trend. *Journal of Econometrical*, 13, 245-259.
  23. Montaseri, M., Nourjou, A., Behmanesh, J., & Akbari, M. (2018). Investigation of heteorological drought in Southern basins of Urmia lake (Case study: Zarrineh rud and Simeneh rud). *Iranian journal of Ecohydrology*, 5(1), 189-202. <http://doi.org/10.22059/ije.2018.245903.781>
  24. 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 & Drainage*, 13(6), 1709-1720. <https://doi: 20.1001.1.20087942.1398.13.6.15.1>
  25. Nazeri Tahroudi, M., Ahmadi, F., & Khalili, K. (2018). Impact of 30 years changing of river flow on Urmia lake basin. *AUT Journal of Civil Engineering*, 2(1), 115-122. <https://doi.org/10.22060/AJCE.2018.14520.5481>
  26. Nicodemus, K.K. (2011). Letter to the Editor: On the stability and ranking of predictors from random forest variable importance measures. *Briefings in Bioinformatics*, 12, 369-373. <https://doi.org/10.1093/bib/bbq011>
  27. Pasquini, A.I., Lecomte, K.L., Piovano, E.L., & Depetris, P.J. (2006). Recent rainfall and runoff variability in central Argentina. *Q. Int.* 158(1), 127-139. <https://doi.org/10.1016/j.quaint.2006.05.021>
  28. Patil, J. P., Sarangi, A., Singh, O.P., Singh, A.K., & Ahmad, T. (2008). Development of a GIS interface for estimation of runoff from watersheds. *Water Resources Management*, 22(9), 1221-1239. <https://doi.org/10.1007/s11269-007-9222-8>
  29. Phomcha, P., Wirojanagud, P., Vangpaisal, T., & Thaveevouthti, T. (2011). Suitability of SWAT model for simulating of monthly streamflow in Lam Sonthi watershed. *The Journal of Industrial Technology*, 7(2), 49-56.
  30. Poursalehi, F., KhasheiSiuki, A., & Hashemi, S.R. (2022). Investigating the performance of random forest algorithm in predicting water table fluctuations Compared with two models of decision tree and artificial neural network (Case study: unconfined aquifer of Birjand). *journal of Ecohydrology*, 8(4), 961-974. <https://doi.org/10.22059/IJE.2022.327263.1526>
  31. Rezazei, H., Jabbari, A., Behmanesh, J., & Hessari, B. (2017). Modelling the daily runoff of Nazloo Chai watershed at the west side of Urmia Lake. *Journal of Water and Soil Conservation*, 23(6), 123-141. <https://doi.org/10.22069/JWFST.2017.9735.2401>
  32. Sabouhi, R., & Soltani, S. (2008). Analysis of the climate trend in the major cities of Iran. *Journal of Agricultural Science and Technology*, 12(46). (In Persian)
  33. Salehi Babil, S., Zeinalzadeh, K., & Hessari, B. (2017). The changes in the frequency of daily precipitation in Urmia Lake basin, Iran. *Journal of Theoretical and Applied Climatology*, 1-10. <https://doi.org/10.1007/s00704-017-2177-7>
  34. Serrano, A., Mateos, V.L., & Garcia, J.A. (1999). Trend analysis of monthly precipitation over the Iberian Peninsula for the period 1921-1995. *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 24(1-2), 85-90. [https://doi.org/10.1016/S1464-1909\(98\)00016-1](https://doi.org/10.1016/S1464-1909(98)00016-1)
  35. Seyedian, S. M., Soleimani, M. & Kashani, M. (2014). Predicting streamflow using data-driven model and time series. *Iranian Journal of Ecohydrology*, 1(3), 167-179. (In Persian). <https://doi:10.22059/IJE.2014.54219>
  36. Shafeizadeh, M., Fathian, H., & Nikbakht Shahbazi, A. (2019). Continuous rainfall-runoff simulation by artificial neural networks based on efficient input variables selection using partial mutual information (PMI) algorithm. *Iran-Water Resources Research*, 15(2), 144-161. <https://doi.org/20.1001.1.17352347.1398.15.2.12.1>
  37. Sharafi, M., Samadian Fard, S., & Hashemi, S. (2021). Monthly rainfall forecasting using genetic programming and support vector machine. *Iranian Journal of Rainwater Catchment Systems*, 8(4), 63-71.
  38. Sharifi, A., Dinpashoh, Y., Fakheri-Fard, A., & Moghaddamnia, A. (2014). Optimum combination of variables for runoff simulation in Amameh watershed using Gamma test. *Water and Soil Science*, 23(4), 59-72. (In Persian)
  39. Sharmod, T., Hosseini, A., & Mohammadzade, H. (2017). Hydrogeochemical report of the study areas of Azarshahr, Shiramin, Ajab Shir and Maragheh. *Geological Survey and Mineral Exploration of IRAN*.
  40. Shekar, S., & Xiong, H. (2018). *Encyclopedia of GIS*. Springer Science & Business Media. New York, USA, 1370.

41. Sohrabi Geshnigani, F., Mirabbasi Najafabadi, R., & Golabi, M.R. (2021). Rainfall-runoff modeling using HBV model and random forest algorithm in Bazoft watershed. *Iranian Journal of Soil and Water Research*, 52(5), 1395-1407. <https://doi:20.1001.1.2008479.1400.52.5.18.2>
42. Turgay, P., & Ercan, K. (2005). Trend analysis in Turkish precipitation data. *Hydrological Processes: An International Journal*, 20(9), 2011-2026. <https://doi.org/10.1002/hyp.5993>
43. Vaheddoost, B., & Aksoy, H. (2018). Interaction of groundwater with Lake Urmia in Iran. *Hydrological Processes*, 32(21), 3283-3295. <https://doi.org/10.1002/hyp.13263>
44. Youssef, A.M., Pourghasemi, H.R., Pourtaghi Z.S., & Al-Katheeri, M.M (2015). Landslide susceptibility mapping using random forest, boosted regression tree, classification and regression tree, and general linear models and comparison of their performance at Wadi Tayyah Basin, Asir Regio. *Saudi Arabia Landslides*. <https://doi.org/10.1007/s10346-015-0614-1>
45. Zarei, M., Zandi, R., & Naemitabar, M. (2022). Assessment of flood occurrence potential using data mining models of support vector machine, chaid and random forest (case study: Frizi watershed). *Jwmr*, 13(25), 133-144. <http://jwmr.sanru.ac.ir/article-1-1140-en.html>