



## Combining Outlier Robust Extreme Learning Machine (ORELM) with seasonal autoregressive moving average linear model (SARIMA) to improve the accuracy of runoff modeling

Fereshteh Nourmohammadi Dehbalaei<sup>1</sup> | Arash Azari<sup>2</sup> | AliAkbar Akhtari<sup>3</sup>

1. Department of Civil Engineering, Razi University, Kermanshah, Iran Iran. E-mail: [Fereshteh\\_nn974@yahoo.com](mailto:Fereshteh_nn974@yahoo.com)

2. Corresponding Author, Department of Water Engineering, Razi University, Kermanshah, Iran. E-mail: [a.azari@razi.ac.ir](mailto:a.azari@razi.ac.ir)

3. Department of Civil Engineering, Razi University, Kermanshah, Iran E-mail: [akhtari@razi.ac.ir](mailto:akhtari@razi.ac.ir)

Article Info	ABSTRACT
<b>Article type:</b> Research Article	Accurate and reliable runoff forecasting has an important role in water resources management, but the complex nature of this parameter can create major challenges for the development of appropriate forecasting models. Two hybrid models based on the combination of two simple linear and non-linear models have been proposed for runoff modeling at hydrological station 02PL005 in the St. Lawrence River basin in Canada. Seasonal autoregressive moving average (SARIMA) linear model is proposed to address the linear and seasonal characteristics of runoff. While the artificial neural network (ANN) and Outlier Robust Extreme Learning Machine (ORELM) models have been used to deal with the nonlinear characteristics of the data through machine learning and pattern recognition. In order to increase the accuracy of the modeling, in the first stage of modeling, the normality and stationary of the data was examined, and by performing appropriate pre-processing, the data were prepared for modeling in the linear part. Then by defining different sub-scenarios and performing modeling through linear model, the best linear model was selected through different mathematical statistics including MAE, RMSE, R and AIC. In the final stage, the residuals of the linear model were modeled by two non-linear models including ANN and ORELM models. Comparing the results of the proposed hybrid models showed that the SARIMA-ORELM hybrid model with AIC=249.29, R=0.71, MAE=11.2 and RMSE=14.33 performs better than the SARIMA-MLP model in all mathematical criteria. Also, the results of the hybrid models were compared with the common MLP, ORELM and SARIMA models.
<b>Article history:</b>	
<b>Received:</b> Sep. 11, 2024	
<b>Revised:</b> Dec. 3, 2024	
<b>Accepted:</b> Dec. 7, 2024	
<b>Published online:</b> April. 2025	
<b>Keywords:</b> Hybrid Model, MLP, Monthly Runoff, ORELM, SARIMA, St. Lawrence River.	

Cite this article: Nourmohammadi Dehbalaei, F., Azari, A., & Akhtari, A. A. (2025). Combining Outlier Robust Extreme Learning Machine (ORELM) with seasonal autoregressive moving average linear model (SARIMA) to improve the accuracy of runoff modeling. *Iranian Journal of Soil and Water Research*, 56 (2), 331-349. <https://doi.org/10.22059/ijswr.2024.382136.669788>

© The Author(s).

Publisher: The University of Tehran Press.



DOI: <https://doi.org/10.22059/ijswr.2024.382136.669788>

## EXTENDED ABSTRACT

### Introduction

Runoff is an important factor in a hydrological system and is influenced by various factors such as geographic location, topography, and climate. Runoff forecasting plays an essential role in reducing the effects of floods and droughts, controlling erosion and sedimentation in the basin. Various hydrological models including empirical models, physical models and data-based models have been developed for runoff modeling. The data-driven methods due to the need for less knowledge of the physical behavior of the phenomenon have become more popular.

### Materials and Methods

At first, the data were divided into two categories, training (70% of the total data measured) and testing (30% of the total data measured). The value of the Hurst coefficient for the data was 0.63, which indicates that the length of the time series is sufficient for modeling. The results of the normality and stationarity test showed that the data have a non-normal distribution and a non-stationary behavior. Therefore, by performing normalization through normalizing functions and removing definite terms from the time series by performing seasonal differentiation, the data were normalized and stationary. By defining two scenarios (without preprocessing and with preprocessing) and by performing different modeling, the best linear model was selected. By calculating the residual of the linear model and checking the independence of the residuals through the Ljung–Box test, nonlinear modeling was performed by outlier robust extreme learning machine (ORELM) and multilayer perceptron (MLP) models. Then, the output of the nonlinear model was summed with the linear model.

### Results and Discussion

For linear modeling with SARIMA model, two scenarios were defined. The best linear model in the first scenario was obtained with MAE=13.28, RMSE=17.23, R=0.62 and AIC=267.54 using seasonal parameters and without preprocessing. In the second scenario, four sub-scenarios were implemented. Sub-scenario 4 using preprocessing through the standardization with MAE=12.76, RMSE=13.11, R=0.57 and AIC=264.41 shows better results than other sub-scenarios. The comparison of the results obtained from the implementation of different nonlinear models showed that model 6 with MAE=10.25, RMSE=13.48 and R=0.7 has the lowest error value and the highest correlation compared to other models. The comparison of the results obtained from the SARIMA-MLP models showed that model 4 with MAE=11.35, RMSE=14.67, AIC=254.41 and R=0.65 has the lowest error and the highest correlation as well as the least complexity compared to other combinations. Comparing the results obtained from the SARIMA-ORELM model showed that model 6 with AIC=249.29, R=0.71, MAE=11.2 and RMSE=14.33 has the best performance in terms of accuracy and complexity compared to other models. By comparing the statistical indicators, the best SARIMA-ORELM and SARIMA-MLP models were selected. The comparison of the results obtained from the implementation of different linear models through the two scenarios showed that preprocessing through standardization increases the accuracy of the model and reduces the complexity of the model.

### Conclusion

A summary of the comparison of the results of the hybrid models with the results obtained from modeling through SARIMA and MLP models is given below:

The results of comparing the predictions of the models through statistical indicators show SARIMA-ORELM model performs better than SARIMA-MLP model in all mathematical criteria.

SARIMA-MLP and SARIMA-ORELM models reduced the complexity of the model by 4.9% and 6.8%, respectively, compared to the linear modeling mode without preprocessing.

Among the six different models selected for runoff modeling, the weakest performance in terms of error and complexity criteria is achieved by modeling through the SARIMA model without preprocessing.

### Author Contributions

F.N.D.: Writing – original draft, Formal analysis, Conceptualization, Data curation, Methodology, Validation, Writing – review & editing. A.A.: Writing – original draft, Formal analysis, Conceptualization, Data curation, Methodology, Validation, Writing – review & editing. A.A.A.: Conceptualization, Data curation, Writing – review & editing.

### Data Availability Statement

Data is available on reasonable request from the authors.

**Acknowledgements**

The authors would like to thank all participants of the present study.

**Ethical considerations**

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

**Conflict of interest**

The authors declare no conflict of interest

## ترکیب مدل ماشین یادگیری افراطی مناسب داده پرت (ORELM) با مدل خطی میانگین متحرک اتورگرسیو فصلی (SARIMA) برای بهبود دقت مدل سازی رواناب

فرشته نورمحمدی ده‌بالایی<sup>۱</sup> | آرش آذری<sup>۲</sup> | علی اکبر اختری<sup>۳</sup>

۱. گروه مهندسی عمران، دانشکده فنی مهندسی، دانشگاه رازی، کرمانشاه، ایران. رایانامه: [Fereshteh\\_nn974@yahoo.com](mailto:Fereshteh_nn974@yahoo.com)

۲. نویسنده مسئول، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران. رایانامه: [A.azari@razi.ac.ir](mailto:A.azari@razi.ac.ir)

۳. گروه مهندسی عمران، دانشکده فنی مهندسی، دانشگاه رازی، کرمانشاه، ایران. رایانامه: [Akhtari@razi.ac.ir](mailto:Akhtari@razi.ac.ir)

چکیده	اطلاعات مقاله
پیش‌بینی دقیق و قابل اعتماد رواناب نقش مهمی در مدیریت منابع آب داشته، اما ماهیت پیچیده این پارامتر می‌تواند چالش‌های عمده‌ای را برای توسعه مدل‌های پیش‌بینی مناسب ایجاد کند. دو مدل هیبرید براساس ترکیب دو مدل خطی و غیرخطی ساده برای مدل‌سازی رواناب ماهانه در ایستگاه هیدرولوژیکی 02PL005 در حوزه رودخانه سنت لارنس در کشور کانادا پیشنهاد گردیده است. مدل خطی میانگین متحرک اتورگرسیو فصلی SARIMA برای پرداختن به ویژگی‌های خطی و فصلی رواناب پیشنهاد شده است. در حالیکه مدل پرسپترون چند لایه (MLP) و ماشین یادگیری افراطی (ORELM) برای پرداختن به ویژگی‌های غیرخطی داده‌ها از طریق یادگیری ماشین و تشخیص الگو به کار برده شده است. به منظور افزایش دقت مدل‌سازی در مرحله اول مدل‌سازی ایستایی و نرمال‌یته داده‌ها مورد بررسی قرار گرفت و با انجام پیش‌پردازش مناسب داده‌ها برای مدل‌سازی در بخش خطی آماده گردیدند. سپس با تعریف زیرساربه‌های مختلف و انجام مدل‌سازی از طریق مدل خطی، بهترین مدل خطی از طریق آماره‌های ریاضی مختلف شامل MAE، RMSE، R و AIC انتخاب گردید. در مرحله پایانی باقیمانده‌های مدل خطی توسط دو مدل غیرخطی شامل ANN و ORELM مدل‌سازی گردیدند. مقایسه نتایج مدل‌های هیبرید پیشنهادی نشان داد که مدل هیبرید SARIMA-ORELM با $AIC=249.29$ ، $R=0.71$ ، $MAE=11.2$ و $RMSE=14.33$ در تمامی معیارهای ریاضی بهتر از مدل SARIMA-MLP عمل می‌کند. همچنین نتایج مدل‌های هیبرید با مدل‌های متداول MLP، ORELM و SARIMA مقایسه گردید.	<b>نوع مقاله:</b> مقاله پژوهشی <b>تاریخ دریافت:</b> ۱۴۰۳/۶/۲۱ <b>تاریخ بازنگری:</b> ۱۴۰۳/۹/۱۳ <b>تاریخ پذیرش:</b> ۱۴۰۳/۹/۱۷ <b>تاریخ انتشار:</b> اردیبهشت ۱۴۰۴ <b>واژه‌های کلیدی:</b> رواناب ماهانه، رودخانه سنت لارنس، مدل هیبرید، MLP، ORELM، SARIMA

استناد: نورمحمدی ده‌بالایی، فرشته؛ آذری، آرش؛ و اختری، علی اکبر (۱۴۰۴). ترکیب مدل ماشین یادگیری ماشین یادگیری افراطی مناسب داده پرت (ORELM) با مدل خطی میانگین متحرک اتورگرسیو فصلی (SARIMA) برای بهبود دقت مدل‌سازی رواناب. مجله تحقیقات آب و خاک ایران، ۵۶ (۲)، ۳۳۹-۳۳۱.



<https://doi.org/10.22059/ijswr.2024.382136.669788>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2024.382136.669788>

## مقدمه

رواناب رودخانه یک عامل حیاتی در سیستم هیدرولوژیکی است و تحت تأثیر عوامل مختلفی مانند موقعیت جغرافیایی، توپوگرافی و آب و هوا قرار دارد. پیش‌بینی رواناب نقش اساسی در کاهش اثرات سیل و خشکسالی، کنترل فرسایش و رسوبگذاری در حوزه را ایفا می‌کند. مدل‌های هیدرولوژیکی زیادی شامل مدل‌های تجربی، مدل‌های فیزیکی و مدل‌های مبتنی بر داده از سال ۱۸۵۰ توسعه پیدا کرده‌اند. مدل‌های مفهومی و فیزیکی تمام فرایندهای فیزیکی درگیر در حوزه را در نظر می‌گیرند و برای مدل‌سازی به داده‌های زیادی نیاز داشته و مدل‌های زمانبری محسوب می‌شوند. این مدل‌ها برای مناطقی که دارای کمبود داده باشند، مناسب نیستند. در مقابل، روش‌های مبتنی بر داده به دلیل نیاز به دانش کمتر از رفتار فیزیکی پدیده، محبوبیت بیشتری پیدا کرده‌اند. امروزه توجه محققان به استفاده از روش‌های ساده‌تر، ارزان‌تر و آسان‌تر مدل‌سازی بیشتر شده است. روش داده محور مبتنی بر رابطه بین متغیرهای ورودی، داخلی و خروجی است (لیما و همکاران، ۲۰۱۴). در نتیجه، پیش‌بینی با این روش به راحتی انجام می‌شود و به دو دسته خطی (مانند مدل‌های رگرسیون خطی و سری‌های زمانی) و غیرخطی (مانند برنامه‌ریزی ژنتیکی (GP)، سیستم‌های استنتاج عصبی-فازی تطبیقی (ANFIS) و مدل‌های شبکه عصبی مصنوعی (ANN) تقسیم می‌شوند.

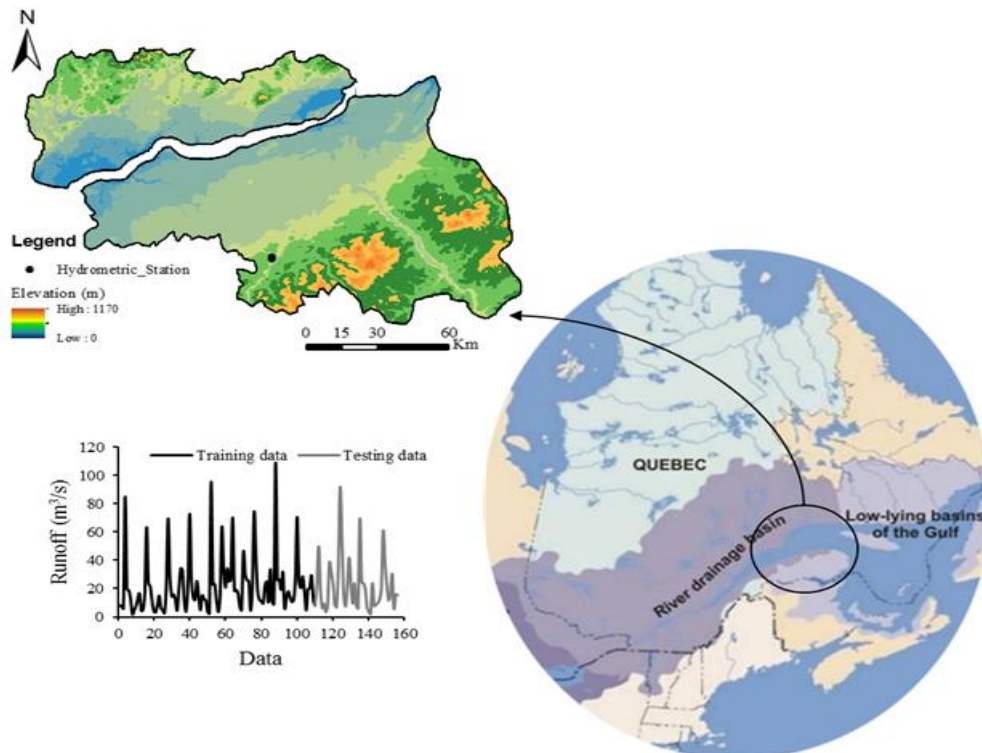
در میان روش‌های مختلف آماری خطی، تکنیک پیش‌بینی سری‌های زمانی انتخاب خوبی برای مدل‌سازی فرآیندهای هیدرولوژیکی است. تکنیک‌های سری زمانی مانند تکنیک باکس-جنکینز (Box and Jenkins, 1970) روش پرکاربردی برای مدل‌سازی سری زمانی می‌باشند. اکثر پارامترهای هیدرولوژیکی را می‌توان با این روش مدل‌سازی و پیش‌بینی کرد (Moeeni et al., 2017; Salih et al., 2020; Ebtehaj et al., 2020; Azari et al., 2021; Soltani et al., 2021; Nourmohammadi dehbalaee et al., 2023). مدل‌های غیرخطی نیز توسط محققان مختلف به عنوان تکنیکی مؤثر در مدل‌سازی پدیده‌های هیدرولوژیکی مورد استفاده قرار گرفته‌اند. این مدل‌ها از یک سیستم غیرخطی برای مدل‌سازی پدیده‌های دینامیکی استفاده می‌کنند و بنابراین برای مدل‌سازی سیستم‌هایی با رفتار پیچیده غیرخطی و به‌ویژه در سیستم‌هایی که روابط فیزیکی کاملاً مشخص نیست، مناسب هستند. نقطه ضعف مدل‌های غیرخطی این است که ممکن است نتایج متفاوتی را در مدل‌سازی خطی ارائه دهند. از طرفی تشخیص نوع سری‌های زمانی پارامترهای هیدرولوژیکی که دارای روابط خطی یا غیرخطی هستند، مشکل می‌باشد، زیرا ممکن است در یک سری زمانی روابط صرفاً خطی یا غیرخطی نباشد. بنابراین، توسعه مدلی که از مزایای سیستم‌های خطی و غیرخطی برای پیش‌بینی فرآیندهای هیدرولوژیکی که به عنوان یکی از فرآیندهای پیچیده در طبیعت شناخته می‌شوند، استفاده کند، می‌تواند بسیار مفید باشد.

مطالعات متعددی در مورد استفاده موفق از مدل‌های هیبریدی برای پیش‌بینی رواناب انجام شده است. (Niu et al., 2019) از یک مدل هیبریدی ساخته شده از مدل‌های تجزیه حالت تجربی مجموعه (EEMD)، ماشین یادگیری افراطی (ELM) و الگوریتم جستجوی گرانشی بهبودیافته (IGSA) برای مدل‌سازی رواناب ماهانه استفاده کردند. نتایج آن‌ها نشان داد که مدل ترکیبی نتایج بهتری را نسبت به مدل‌های دیگر در پیش‌بینی سری‌های زمانی هیدرولوژیکی ایجاد می‌کند. (Kim et al., 2019) هشت روش مختلف خطی از جمله مدل ساریمکس، ساریمکس و ANN و ترکیبی را برای پیش‌بینی جریان ورودی ماهانه به مخزن به کار بردند و نشان دادند که روش‌های ARX-ANN و AR-RF بهتر از روش‌های دیگر در پیش‌بینی رواناب عمل می‌کنند. همچنین آن‌ها نشان دادند که استفاده از شاخص‌های اقلیمی در مدل‌های هوش مصنوعی سبب بهبود عملکرد مدل می‌گردد. (Dwivedi and Shrivastava, 2019) مدل‌های ARIMA و ANN فصلی مدل‌سازی کردند و نشان دادند که روش ANN از نظر دقت نسبت به مدل ARIMA برتری دارد. سپس با استفاده از روش منحنی میزان رواناب در هر حوضه را پیش‌بینی کرد. (Nath et al., 2020) از مدل انفیس اصلاح شده از طریق الگوریتم بهینه‌سازی ذرات (PSO) برای مدل‌سازی رواناب استفاده کردند. سپس عملکرد انفیس اصلاح شده را با نتایج مدل اریما مقایسه کردند و نشان دادند که مدل PSO-ANFIS عملکرد بهتری نسبت به مدل آریمما و انفیس در پیش‌بینی رواناب دارد. (Zhihua et al., 2020) به ارزیابی عملکرد مدل‌های مبتنی بر فیزیک و مبتنی بر هوش مصنوعی با یک مدل ترکیبی ساخته شده از ترکیب این مدل‌ها پرداختند و نشان دادند که مدل ترکیبی پیشنهادی نسبت به مدل‌های دیگر عملکرد بهتری در مدل‌سازی رواناب دارد. (Nourani et al., 2020) از یک روش ترکیبی مبتنی بر تبدیل موجک (WT) به عنوان ابزار پیش‌بینی و روش هموارسازی نمایی (ES) و با تعریف دو سناریو مختلف به پیش‌بینی جریان پرداختند و به مقایسه عملکرد روش هیبرید

پیشنهادی با چهار روش مدل‌سازی مختلف دیگر از جمله روش آرپما و شبکه عصبی مصنوعی پرداختند و نشان دادند که مدل هیبریدی نتایج دقیق‌تری نسبت به مدل‌های دیگر دارد. Zhang et al., (2022) از ترکیب مدل ساریما و الگوریتم جستجوی گرانشی (GSA) برای پیش‌بینی رواناب استفاده کردند و نشان دادند که همه شاخص‌های ارزیابی این مدل از سایر مدل‌های توسعه‌یافته بهتر عمل می‌کند. Nourmohammadi Dehbalaei et al., (2023) از ترکیب مدل چند متغیره خطی با یک مدل چند لایه غیرخطی به مدلسازی رواناب در یک حوزه آبریز پرداختند و با مقایسه نتایج بدست آمده از مدل چند متغیره خطی و چند لایه غیرخطی نشان دادند که مدل هیبرید در مدل‌سازی رواناب بهتر از سایر مدل‌ها عمل می‌کند. مروری بر تحقیقات گذشته نشان می‌دهد که در زمینه مدل‌سازی رواناب تاکنون مدل‌سازی از طریق مدل هیبرید SARIM-ORELM انجام نگرفته است. هدف این مطالعه توسعه یک برنامه کامپیوتری در محیط نرم افزار متلب با استفاده از ترکیب دو مدل ساده خطی و غیرخطی و ارزیابی عملکرد آن با روش‌های خطی و غیرخطی می‌باشد. به منظور ارزیابی عملکرد مدل‌های هیبرید توسعه داده شده از داده‌های تاریخی رواناب ماهانه بدست آمده از یک ایستگاه در حوزه رودخانه سنت لارنس در کشور کانادا استفاده می‌گردد.

### ناحیه مورد مطالعه

در این مطالعه، بخشی از حوزه رودخانه سنت لارنس در کشور کانادا مورد مطالعه قرار می‌گیرد. این رودخانه با موقعیت جغرافیایی، سومین رودخانه بزرگ در این کشور می‌باشد که ۹۵ کیلومتر از طول آن در ناحیه مورد مطالعه قرار گرفته است. بیش از ۴۵ میلیون آمریکایی و کانادایی در این منطقه زندگی می‌کنند. شکل ۱ موقعیتی از حوزه رودخانه سنت‌لارنس و نقشه ارتفاعی ناحیه مورد مطالعه را نشان می‌دهد. مجموع ۱۵۶ داده رواناب ماهانه از ایستگاه هیدرومتریک 02PL005 از طریق وب سایت Environment Canada (EC) (<https://wateroffice.ec.gc.ca>) از اول ژانویه ۲۰۰۱ تا دسامبر ۲۰۱۳ جمع‌آوری گردیده است. از میان ۱۵۶ داده، ۱۰۹ داده مشاهداتی برای ساخت مدل و ۴۷ داده دیگر برای تست مدل در نظر گرفته شد. شاخص‌های آماری بدست آمده از این داده‌ها در دوره کالیبراسیون و صحت‌سنجی در جدول ۱ آورده شده است. در این جدول  $\bar{X}$ ،  $X_{min}$ ،  $X_{max}$  به ترتیب میانگین، حداقل و حداکثر داده‌ها می‌باشند. همچنین  $Q_1$ ،  $X_{50}$  و  $Q_3$  به ترتیب چارک اول، میانه و چارک سوم هستند.  $SD$ ،  $CV$  و  $Sk$  به ترتیب انحراف معیار، ضریب تغییرات و چولگی هستند. با مقایسه مقادیر آماری بدست آمده از این سری زمانی مشاهده گردید که داده‌های رواناب در دو دوره دارای شاخص‌های آماری تقریباً یکسان می‌باشد.



شکل ۱. موقعیت و نقشه ارتفاعی ناحیه مورد مطالعه و موقعیت ایستگاه هیدرومتری قرار گرفته در ناحیه مورد مطالعه

جدول ۱. خصوصیات آماری از داده‌های رواناب در ایستگاه 02PL005 قرار گرفته در ناحیه مورد مطالعه

Sk	CV	SD	Q3	X50	Q1	Xmax	Xmin	$\bar{X}$	داده‌های رواناب (m <sup>3</sup> /s)
۲/۰۳	۰/۹۰	۱۹/۸۴	۲۵/۵۰	۱۷/۰۰	۸/۷۰	۱۰۹/۰۰	۲/۱۲	۲۲/۰۴	کل
۲/۱۳	۰/۹۲	۲۰/۳۴	۲۵/۵۰	۱۷/۴۰	۸/۷۰	۱۰۹/۰۰	۲/۱۹	۲۲/۱۵	کالیبراسیون
۱/۷۳	۰/۸۶	۱۸/۸۵	۲۴/۲۰	۱۵/۷۰	۸/۱۲	۹۱/۸۰	۲/۱۲	۲۱/۸۰	صحت سنجی

## مواد و روش‌ها

### پیش‌پردازش داده‌ها

برای مدل‌سازی رواناب با استفاده از داده‌های سری زمانی، لازم است ابتدا طول و قابلیت پیش‌بینی سری‌های زمانی مورد بررسی قرار گیرد. ضریب هرست یکی از روش‌های مورد استفاده برای بررسی این موضوع است. اگر مقدار به دست آمده از این ضریب بزرگتر از ۰/۵ باشد، سری زمانی دارای حافظه طولانی و قابلیت پیش‌بینی مناسب است (Ebttehaj et al., 2019; Bayesteh and Azari., 2019). مقدار ضریب هرست براساس رابطه زیر بدست می‌آید:

$$H_c = \frac{\log\left(\frac{R}{S_d}\right)}{\log\left(\frac{N_o}{2}\right)} \quad \text{رابطه (۱)}$$

که در آن  $H_c$  ضریب هرست،  $R$  نشان دهنده تفاوت بین کمترین و بالاترین مقدار اختلاف تجمعی از میانگین داده‌ها،  $S_d$  و  $N_o$  به ترتیب نشان دهنده انحراف معیار و تعداد مشاهدات هستند.

آنالیز سری‌های زمانی بر اساس روش‌های تصادفی با فرض توزیع نرمال متغیرها و ایستا بودن آنها توسعه یافته است. با توجه به اینکه اکثر پارامترهای مربوط به مسائل هیدرولوژیکی توزیع نرمال ندارند و همچنین هر سری زمانی شامل مولفه‌های غیرایستای مختلفی شامل روند، فصل، پرش و ترم استوکاستیک می‌باشد، لازم است نرمال بودن و ایستا بودن سری زمانی مورد بررسی قرار گیرد. روش‌های مختلفی توسط محققین مختلف برای بررسی ایستایی و نرمالیت داده‌ها معرفی شده است. در این مطالعه، از آزمون جارکوا برا (Jarque and Bera., 1980) برای بررسی نرمالیت داده‌ها و از آزمون‌های KPSS و PP برای بررسی ایستایی سری‌های زمانی که توسط Phillips and Perron (1988) و Kwiatkowski et al., (1992) به ترتیب معرفی شده اند، استفاده می‌شوند.

آماره آزمون جارکوا - برا به صورت زیر بیان می‌شود:

$$JB = N_o \left( \frac{1}{6} \left[ \frac{\frac{1}{N_o} \sum_{t=1}^n (Ru_t - \overline{Ru_t})^3}{\left( \frac{1}{N_o} \sum_{t=1}^n (Ru_t - \overline{Ru_t})^2 \right)^{\frac{3}{2}}} \right]^2 + \frac{1}{24} \left[ \left( \frac{\frac{1}{N_o} \sum_{t=1}^n (Ru_t - \overline{Ru_t})^4}{\left( \frac{1}{N_o} \sum_{t=1}^n (Ru_t - \overline{Ru_t})^2 \right)^2} \right) - 3 \right]^2 \right) \quad \text{رابطه (۲)}$$

جایی که  $\overline{Ru_t}$  و  $N_o$  به ترتیب میانگین حسابی داده‌ها و تعداد مشاهدات می‌باشند. زمانی که مقادیر احتمال (P-value) بدست آمده از آماره آزمون جارکوا- برا بیشتر از ۵ درصد باشد، سری زمانی دارای توزیع نرمال است. در غیر این صورت سری دارای توزیع غیرنرمال بوده و سری زمانی برای نرمال‌سازی باید از طریق توابع نرمال‌ساز مختلف انتقال داده شود. در میان روش‌های مختلف تبدیل داده‌ها، تبدیل‌های لگاریتمی (Log)، لگاریتم استاندارد (Logstd) و تبدیل‌های Box-Cox به طور گسترده برای نرمال‌سازی داده‌ها استفاده می‌شوند. آماره این روش‌ها در جدول ۲ آورده شده است.

جدول ۲- روابط مربوط به توابع مختلف نرمال‌ساز.

تابع نرمال‌ساز	معادله	رابطه
لگاریتم (Log)	$Y = \log(Ru)$	رابطه (۳)
لگاریتم استاندارد (Logstd)	$Y = \frac{\log(Ru) - \overline{Ru}}{S_d}$	رابطه (۴)

$$\text{Box-Cox} \quad Y(\lambda) = \begin{cases} \frac{Ru^\lambda - 1}{\lambda} & \lambda \neq 0 \\ \log(Ru) & \lambda = 0 \end{cases} \quad (\text{رابطه ۵})$$

آماره آزمون PP به صورت روابط زیر ارایه شده است:

$$y_i = \alpha + \rho y_{i-1} + \varepsilon_i \quad (\text{رابطه ۶})$$

$$Z_\rho = n(\hat{\rho}_n - 1) - \frac{1}{2} \frac{n^2(n-k)\hat{\sigma}^2}{\sum_{i=1}^n \hat{u}_i^2} (\hat{\gamma}_{o,n} + 2 \sum_{j=1}^q (1 - \frac{j}{q+1}) \hat{\gamma}_{j,n} - \hat{\gamma}_{o,n}) \quad (\text{رابطه ۷})$$

$$Z_\tau = \sqrt{\frac{\hat{\gamma}_{o,n}}{\hat{\lambda}_n^2} \frac{(\hat{\rho}_n - 1)}{\hat{\sigma}}} - \frac{1}{2} (\hat{\lambda}_n^2 - \hat{\gamma}_{o,n}) \frac{1}{\hat{\lambda}_n} \frac{n\sqrt{(n-k)}\hat{\sigma}}{\sqrt{\sum_{i=1}^n \hat{u}_i^2}} \quad (\text{رابطه ۸})$$

$$\hat{\lambda}_n = \sqrt{\hat{\gamma}_{o,n} + 2 \sum_{j=1}^q (1 - \frac{j}{q+1}) \hat{\gamma}_{j,n}} \quad (\text{رابطه ۹})$$

در جایی که ut باقیمانده حداقل مربعات، k و q به ترتیب تعداد متغیرهای کمکی در رگرسیون و تاخیر نبوی-وست می‌باشند. آزمون KPSS که برای وجود (یا عدم وجود) ریشه‌های واحد طراحی شده است براساس رابطه زیر بدست می‌آید:

$$S^2(h) = \frac{1}{r} \sum_{e=1}^n a_e^2 + \frac{2}{n} \sum_{e=1}^h (1-s(h+1)) \frac{1}{r} \sum_{t=s+1}^n a_e a_{e-s} \quad (\text{رابطه ۱۰})$$

که در آن  $a_e$  تعداد مراحل و  $r$  باقیمانده سری زمانی است. آمار زیر برای تست ثابت "سطح" استفاده می‌شود.

$$\eta_\tau = \frac{1}{r^2} \sum_{e=1}^n \frac{S_e^2}{S^2(l)} \quad (\text{رابطه ۱۱})$$

جایی که  $S_e^2$  میانگین مربعات خطا است. همچنین از آمار زیر برای تست ثابت "Trend" استفاده می‌شود.

$$\eta_\mu = \frac{1}{r^2} \sum_{e=1}^n \frac{S_e^2}{S^2(l)} \quad (\text{رابطه ۱۲})$$

غیر ایستا بودن سری زمانی ناشی از وجود ترم‌های قطعی در سری زمانی است. علاوه بر ترم تصادفی، سری زمانی ممکن است شامل ترم‌های قطعی باشد. ترم‌های قطعی (روند، دوره و پرش) در صورت افزایش یا کاهش (تدریج یا ناگهانی) در ویژگی‌های آماری مانند واریانس و میانگین رخ می‌دهند. همچنین وجود تغییرات تناوبی سینوسی در سری‌های زمانی باعث تعبیر فصل می‌شوند. اگر در سری‌های زمانی ترم‌های قطعی وجود داشته باشند، باید آنها را کاهش یا از سری زمانی حذف کرد تا تنها ترم تصادفی در سری زمانی باقی بماند و داده‌ها برای مدل‌سازی آماده شوند. برای بررسی دقیق‌تر وجود ترم‌های قطعی در سری‌های زمانی از آزمون‌های مختلفی استفاده می‌شود. نمودار همبستگی ACF و PACF برای بررسی وجود ترم فصل در سری زمانی استفاده شد. اگر سری زمانی دارای تغییرات فصلی باشد، نوسانات سینوسی در نمودار مشهود است. برای بررسی وجود ترم پرش در سری زمانی از آزمون من ویتنی استفاده شد. معادله ریاضی آزمون من ویتنی به صورت زیر است:

$$U_{MW} = \frac{\sum_{t=1}^N (O(S(t)) - \frac{Ru_1(Ru_1 + Ru_2 + 1)}{2})}{\sqrt{\frac{Ru_1 Ru_2 (Ru_1 + Ru_2 + 1)}{12}}} \quad (\text{رابطه ۱۳})$$

در جایی که  $Ru_1$  و  $Ru_2$  زیر مجموعه‌های سری اصلی رواناب هستند،  $O(S(t))$  داده‌های مرتب‌سازی شده به صورت نزولی سری‌های زمانی رواناب هستند.

دو آزمون ناپارامتریک شامل آزمون من-کندال (MK) و آزمون من-کندال فصلی (SMK) برای ارزیابی افزایش یا کاهش در طول



زمان رواناب استفاده می‌شود.

معادله ریاضی آزمون من کندال (MK) به صورت زیر است:

$$U_{MK} = \begin{cases} (MK - 1) \text{var}(MK)^{-0.5} & MK > 0 \\ 0 & MK = 0 \\ (MK - 1) \text{var}(MK)^{-0.5} & MK < 0 \end{cases} \quad \text{رابطه ۱۴}$$

$$MK = \sum_{i=1}^{N-1} \sum_{j=i+1}^N \text{sgn}(Ru_j - Ru_i) \quad \text{رابطه ۱۵}$$

$$\text{var}(MK) = \frac{1}{18} \left[ N_o(N_o - 1)(2N_o + 5) - \sum_g^p N_{op}(N_{op} - 1)(2N_{op} + 5) \right] \quad \text{رابطه ۱۶}$$

جایی که p برابر است با تعداد گروه‌های یکسان.  $N_{op}$  تعداد داده‌ها در گروه p است،  $\text{sgn}$  و  $N_o$  تابع علامت و تعداد مشاهدات هستند. آماره آزمون SMK به شرح زیر است:

$$R_{sk} = \sum_{i=1}^{N_k} \sum_{j=i+1}^{N_{k-1}} \text{sgn}(Ru_{ki} - Ru_{kj}) \quad \text{رابطه ۱۷}$$

$$SMK = \sum_{k=1}^{\omega} (R_{sk} - \text{sgn}(R_{sk})) \quad \text{رابطه ۱۸}$$

$$\text{var}(SMK) = \sum_j^{\omega} \frac{N_j(N_j - 1)(2N_j + 5)}{18} + 2 \sum_{m=1}^{\omega-1} \sum_{n=i+1}^{\omega} \sigma_{mn} \quad \text{رابطه ۱۹}$$

$$U_{SMK} = MK \text{var}(MK)^{-0.5} \quad \text{رابطه ۲۰}$$

جایی که،  $N_j$  و  $\sigma_{mn}$  داده‌های N امین فصل ز و کوواریانس در فصل‌های m و n ام (به ترتیب) هستند.

در صورت تایید وجود هر یک از ترم‌های قطعی در سری زمانی، آن مولفه باید از سری زمانی حذف شود یا با روش‌های مناسب اثر آن کاهش یابد. برای ایستایی سری‌های زمانی، روش تفاضل‌گیری یکی از روش‌های مناسب است. این روش به دو صورت تفاضل‌گیری فصلی و غیرفصلی انجام می‌گیرد. در هر دو روش با انجام تفاضل‌گیری، همبستگی‌های فصلی و یا غیرفصلی از سری زمانی حذف می‌شوند. با انجام تفاضل‌گیری غیر فصلی با کم کردن هر مقدار از مقدار قبلی آن، عبارت روند را میتوان از سری زمانی حذف کرد. با انجام تفاضل‌گیری فصلی از طریق معادله ۲۴ و با توجه به شماره فصل می‌توان عبارت فصل را از سری زمانی حذف کرد. روش استانداردسازی نیز برای حذف یا کاهش عبارت پرش از سری زمانی استفاده می‌شود. این روش که از معادله ۲۵ برای حذف میانگین و انحراف معیار از سری زمانی استفاده می‌کند، سری را به سری زمانی با میانگین صفر و انحراف استاندارد ۱ تبدیل می‌کند.

$$\text{Diff}(Y) = Y(t) - Y(t - s) \quad \text{رابطه ۲۱}$$

$$SStd = \frac{Ru(t, i) - \overline{Ru}(i)}{Sd(i)} \quad \text{رابطه ۲۲}$$

جایی که  $s$ ،  $\overline{Ru}$  و  $Sd$  به ترتیب عدد فصل، میانگین و انحراف استاندارد داده‌ها هستند.

معادله کامل میانگین متحرک یکپارچه رگرسیون فصلی به شرح زیر است:

$$\Phi(B^S) \Psi(B) (1 - B^S)^D (1 - B)^d Ru(t) = \Theta(B^S) \theta(B) \varepsilon(t) \quad \text{رابطه ۲۳}$$

$$\Phi(B^S) = (1 - \Phi_1(B^S) - \Phi_2(B^{2S}) - \dots - \Phi_p(B^{pS})) \quad \text{رابطه ۲۴}$$

$$\Psi(B) = (1 - \Psi_1(B) - \Psi_2(B^2) - \dots - \Psi_p(B^p)) \quad \text{رابطه ۲۵}$$

$$\Theta(B^S) = (1 - \Theta_1(B^S) - \Theta_2(B^{2S}) - \dots - \Theta_Q(B^{QS})) \quad \text{رابطه ۲۶}$$

$$\theta(B) = (1 - \theta_1(B) - \theta_2(B^2) - \dots - \theta_q(B^q)) \quad \text{رابطه (۲۷)}$$

که در آن  $Ru(t)$  رواناب مشاهداتی،  $S$  شماره فصل،  $D$  و  $d$  تفاضل‌گیری فصلی و غیرفصلی،  $\theta$  و  $\varphi$  پارامترهای رگرسیون خودکار (AR) و میانگین متحرک (MA)،  $\Theta$  و  $\Phi$  پارامترهای فصلی AR و فصلی MA و  $\varepsilon(t)$  عبارت تصادفی یا باقیمانده است.  $p$  و  $Q$  به ترتیب پارامترهای خود رگرسیون فصلی و خود رگرسیون غیرفصلی،  $q$  و  $Q$  به ترتیب پارامترهای خود رگرسیون فصلی و غیرفصلی هستند.

#### مدل غیرخطی پرسپترون چندلایه (MLP)

مدل MLP از سه لایه مجزا تشکیل شده است. عنصر اصلی در این مدل نرون‌ها می‌باشد که در سه لایه ورودی، میانی و خروجی قرار گرفته و با نرون‌های لایه بعدی در ارتباط هستند. با اتصال این نرون‌ها به یکدیگر در لایه‌های مختلف یک سیستم عصبی مشابه با مغز انسان ایجاد می‌شود. هر نرون از یک تابع فعال‌سازی غیر خطی استفاده می‌کند. در این سیستم، انتقال و دریافت اطلاعات از طریق این ارتباطات ایجاد می‌شود. اطلاعات ورودی به مدل از طریق تاخیرهای زمانی از سری زمانی رواناب بدست می‌آید. این تاخیرهای زمانی براساس دیاگرام ACF بدست می‌آیند. بنابراین تعداد نرون‌ها در لایه ورودی براساس ترکیبات مختلف از تاخیرهای زمانی مهم بدست می‌آیند. ترکیبات مختلف انتخاب شده در این مطالعه در زیر آورده شده است.

Model-1:	$f(Rut-1)$	Model-6:	$f(Rut-1, Rut-24)$
Model-2:	$f(Rut-1, Rut-2)$	Model-7:	$f(Rut-6)$
Model-3:	$f(Rut-1, Rut-2, Rut-3)$	Model-8:	$f(Rut-6, Rut-12)$
Model-4:	$f(Rut-1, Rut-6)$	Model-9:	$f(Rut-12)$
Model-5:	$f(Rut-1, Rut-12)$		

بعد از دریافت اطلاعات از طریق نرون‌ها در لایه ورودی، این اطلاعات از طریق ارتباطات وزنی، تابع انتقال و بایاس به لایه بعدی انتقال داده می‌شود. مجموع مقادیر وزنی که از نرون‌های لایه پنهان ارسال می‌شود همراه با یک مقدار بایاس به نرون‌های لایه بعدی وارد می‌شود. تعداد نرون‌ها در لایه پنهان از طریق سعی و خطا مشخص می‌گردد.

#### مدل ماشین‌های یادگیری افراطی (ORELM)

به منظور مدل‌سازی با استفاده از مدل‌های مبتنی بر هوش مصنوعی همیشه داده‌های به صورت *outlier* وجود دارند و به دلیل اینکه عموماً وجود چنین نمونه‌هایی در بسیاری از موارد به طبیعت موجود در مساله برمی‌گردد، امکان حذف آنها وجود ندارد. بنابراین، درصدی از کل خطای آموزش ( $e$ ) را شامل می‌شود. به منظور برخورد با چنین داده‌هایی، وجود *outliers* با *sparsity* تعریف می‌شود. Zhang and Luo (2015) با دانش اینکه استفاده از  $l_0$ -norm، *sparsity* را نسبت به  $l_2$ -norm بهتر منعکس می‌کند، جهت محاسبه ماتریس وزن خروجی ( $\beta$ )، به جای استفاده از  $l_2$ -norm، خطای آموزش ( $e$ ) را به گونه‌ای در نظر می‌گیرند که *sparse* باشد.

$$\min_{\beta} C \|e\|_0 + \|\beta\|_2^2 \quad \text{subject to } \mathbf{y} - \mathbf{H}\beta = \mathbf{e} \quad \text{رابطه (۲۸)}$$

$$\beta = [\beta_1, \dots, \beta_N]^T$$

( $\beta$ )، ماتریس وزن‌های خروجی است ( $w_o$  یا همان  $w_{output}$  است).

(یا در برخی منابع به این شکل نوشته می‌شود ( $w_o$ ) ماتریس وزن‌های خروجی است):

$$\min_{w_o} C \|e\|_0 + \|w_o\|_2^2 \quad \text{subject to } T - Hw_o \quad \text{رابطه (۲۹)}$$

رابطه فوق یک مساله برنامه‌نویسی غیرمحدب<sup>۲</sup> است. یکی از ساده‌ترین راه‌ها جهت حل این مساله، نوشتن آن به صورت یک مساله محدب قابل کنترل بدون از بین رفتن ویژگی پراکندگی<sup>۳</sup> است. ترم پراکنده یا *sparse* با استفاده از  $l_1$ -norm بدست می‌آید. جایگذاری  $l_0$ -norm با  $l_1$ -norm، نه تنها منجر به حداقل سازی تحدب<sup>۴</sup> (کم شدن تابع خطا) میشود بلکه وجود مشخصات پراکندگی یا وجود وقایع

1. Outlier Robust Extreme Learning Machines (ORELM)  
 2. Non-convex programming  
 3. Tractable convex relaxation form without loss of the sparsity characteristic  
 4. Minimization convex

حدی (داده‌های نادر) را نیز تضمین می‌کند.

$$\min_{\beta} \|\mathbf{e}\|_1 + \frac{1}{C} \|\beta\|_2^2 \quad \text{subject to } \mathbf{y} - \mathbf{H}\beta = \mathbf{e} \quad \text{رابطه ۳۰}$$

رابط فوق یک مساله بهینه‌سازی محدب مقید<sup>۱</sup> است به طوری که به طور کامل دامنه مناسب رویکرد تکمیل شده ضرب لاگرانژی<sup>۲</sup> را تطبیق می‌کند.

$$L_{\mu}(\mathbf{e}, \beta, \lambda) = \|\mathbf{e}\|_1 + \frac{1}{C} \|\beta\|_2^2 + \lambda^2 (\mathbf{y} - \mathbf{H}\beta - \mathbf{e}) + \frac{\mu}{2} \|\mathbf{y} - \mathbf{H}\beta - \mathbf{e}\|_2^2 \quad \text{رابطه ۳۱}$$

که  $\mu = 2N / \|\mathbf{y}\|_1$  (یانگ و ژانگ (۲۰۱۱) بر پارامتر جریمه<sup>۳</sup> دلالت دارد و  $\lambda \in R^n$  بردار ضرب لاگرانژی است. جواب بهینه  $(\mathbf{e}, \beta)$  و بردار ضرب لاگرانژی  $(\lambda)$  با استفاده از حداقل‌سازی تابع زیر طی فرایند تکراری، بدست می‌آید.

$$\left\{ \begin{array}{l} (\mathbf{e}_{k+1}, \beta_{k+1}) = \arg \min_{\mathbf{e}, \beta} L_{\mu}(\mathbf{e}, \beta, \lambda) \quad \text{(a)} \\ \lambda_{k+1} = \lambda_k + \mu(\mathbf{y} - \mathbf{H}\beta_{k+1} - \mathbf{e}_{k+1}) \quad \text{(b)} \end{array} \right. \quad \text{رابطه ۳۲}$$

### مدل‌های هیبرید

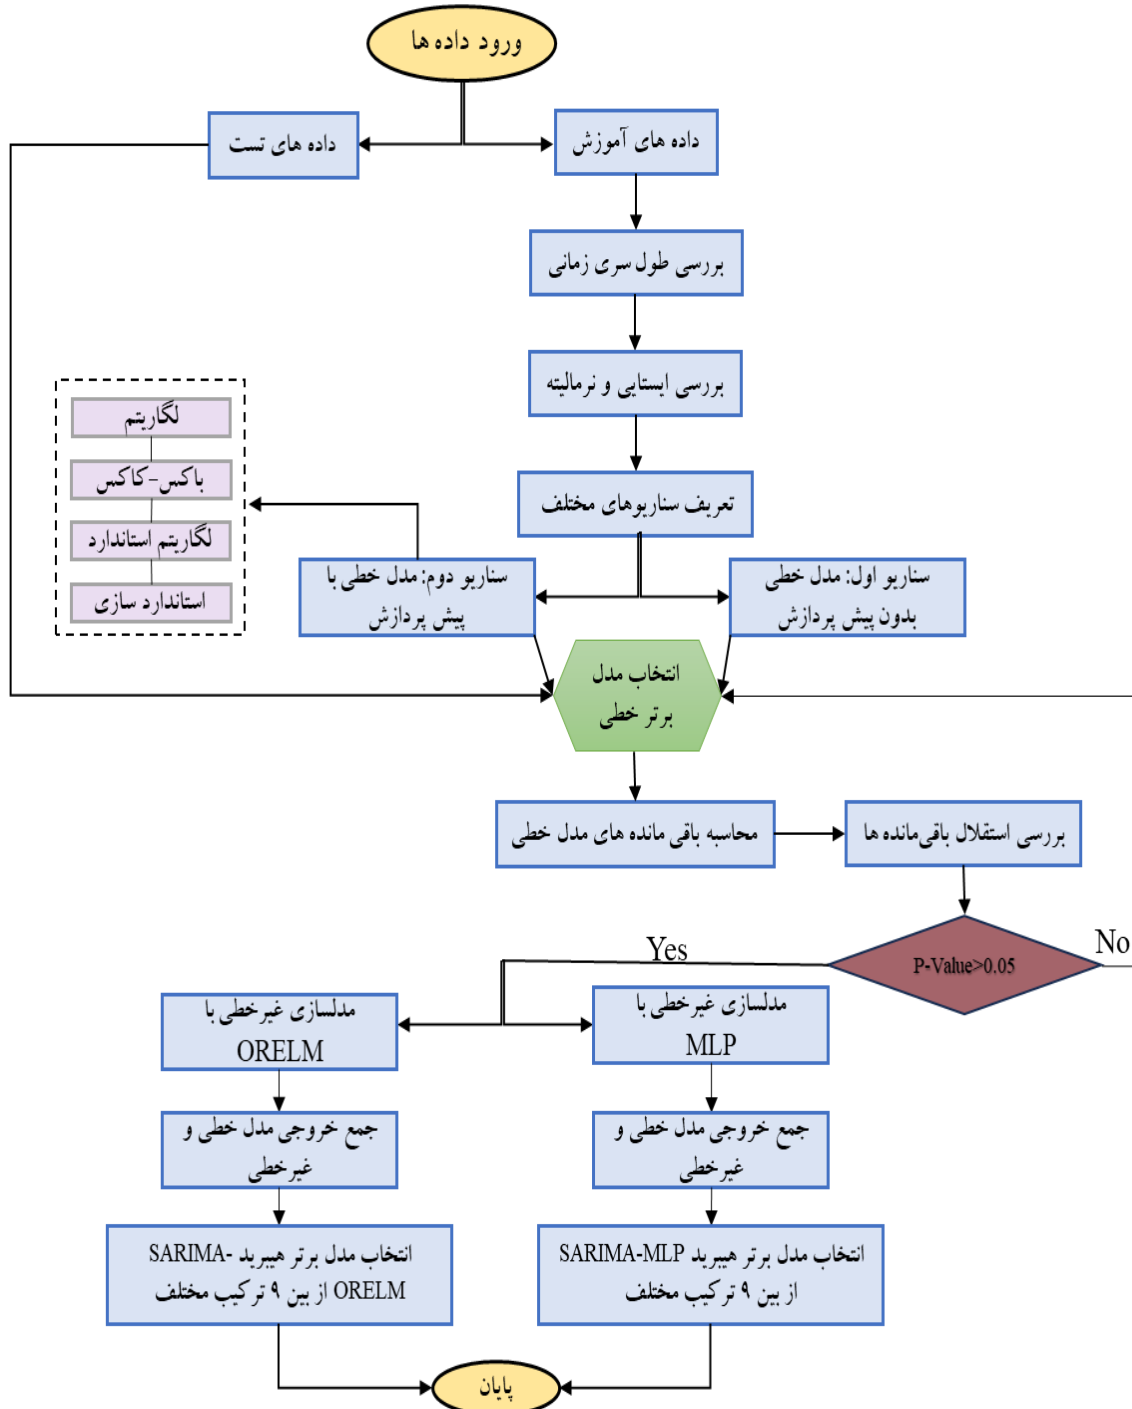
به منظور استفاده همزمان از مزایای روش‌های خطی و غیرخطی در این مطالعه، دو مدل هیبرید براساس ترکیب مدل خطی و مدل‌های غیرخطی انتخابی برای مدل‌سازی رواناب پیشنهاد گردید. متدولوژی پیشنهاد شده در نرم افزار متلب کدنویسی شده و مراحل آن در شکل ۲ نشان داده شده است. متدولوژی پیشنهادی شامل سه مرحله اساسی پیش‌پردازش داده‌ها (مرحله اول)، مدل‌سازی خطی (مرحله دوم) و مدل‌سازی غیرخطی (مرحله سوم) می‌باشد. در مرحله اول طول سری زمانی، ایستایی و نرمالیت داده‌ها مورد بررسی قرار می‌گیرد. در مرحله دوم بخش خطی با تعریف دو سناریو و پنج زیرسناریو مدل‌سازی می‌گردد. در سناریو اول داده‌ها بدون انجام پیش‌پردازش مدل‌سازی می‌گردد، در نتیجه این سناریو شامل یک زیرسناریو می‌باشد. در سناریو دوم داده‌ها با انجام پیش‌پردازش با توجه به آزمون‌های مرحله اول مدل‌سازی می‌شوند و به این ترتیب چهار زیرسناریو تعریف گردید. این زیرسناریوها شامل ۱- انجام پیش‌پردازش از طریق تابع *Box-Cox*، ۲- انجام پیش‌پردازش از طریق تابع *Log*، ۳- انجام پیش‌پردازش از طریق تابع *Logstd*، ۴- انجام پیش‌پردازش از طریق استاندارد سازی می‌باشند. سپس با انجام مدل‌سازی و محاسبه معیارهای ریاضی مختلف و مقایسه نتایج بدست آمده از زیرسناریوهای مختلف مدل برتر برای هر زیر سناریو انتخاب گردید. به منظور تایید مدل برای هر زیر سناریو ابتدا میانگین باقی‌مانده‌های هر مدل محاسبه می‌گردد در صورتی که دارای میانگین باقی‌مانده‌های صفر باشد آزمون استقلال باقی‌مانده‌ها بر روی آن انجام می‌گیرد. به منظور بررسی استقلال باقی‌مانده‌ها از آزمون لجنجنگ باکس (*Ljung box 1978*) استفاده و مدل خطی اعتبار سنجی می‌گردد. در آزمون لجنجنگ باکس که آماره آن از رابطه ۲۷ بدست می‌آید در صورتی که مقدار *P-value* بدست آمده از این آزمون بزرگتر از ۵ درصد باشد، استقلال باقی‌مانده‌ها تایید می‌گردد و نشان دهنده عدم ارتباط خطی بین باقی مانده می‌باشد. در هر زیر سناریو با در نظر گرفتن مقادیر مختلف برای پارامترهای مختلف  $(P, Q, D, p, q, d)$  مدل‌سازی انجام می‌گیرد. با تغییر پارامترها ۸۰۰ مدل خطی برای هر زیرسناریو و در مجموع ۴۰۰۰ مدل خطی برای تمام زیر سناریوها انجام گرفت. پس از محاسبه معیارهای ریاضی مختلف و مقایسه نتایج بدست آمده از هر زیر سناریو یک مدل برتر خطی و سپس با مقایسه نتایج بدست آمده از تمام زیر سناریوها با یکدیگر مدل برتر خطی انتخاب می‌گردد.

$$LB = N_o(N_o + 2) \sum_{i=1}^h \frac{r_i^2}{N_o - 1} \quad \text{رابطه ۳۳}$$

که در آن  $N$  تعداد کل مشاهدات، مقدار  $h$  برابر با یک چهارم طول داده‌ها،  $r_i$  ACF بدست آمده از باقی‌مانده‌ها در تاخیر  $i$ ، اگر مقدار *P-value* بدست آمده از این آزمون بیشتر از ۵ درصد باشد، باقی‌مانده‌ها مستقل هستند و هیچ ارتباط خطی بین باقی‌مانده‌ها وجود ندارد. در غیر این صورت مدل مورد بازبینی قرار می‌گیرد. پس از انتخاب مدل برتر خطی، مدل‌سازی غیر خطی در مرحله سوم انجام می‌گیرد. در

1. Constrained convex  
2. Augmented Lagrangian (AL) multiplier  
3. Penalty

مرحله سوم، باقی مانده‌های مدل خطی با دو مدل غیر خطی مدل‌سازی می‌گردند. در مدل اول هیبرید مدل غیرخطی MLP برای مدل‌سازی بخش غیرخطی و برای مدل دوم هیبرید مدل غیرخطی ORELM انتخاب گردید. در بخش غیرخطی، ۱۶ ترکیب مختلف مشابه با ترکیبات در نظر گرفته شده برای مدل‌سازی بخش غیرخطی در نظر گرفته شد. سرانجام خروجی مدل غیرخطی به مدل خطی اضافه شده و دو مدل هیبرید برتر براساس معیارهای ریاضی انتخاب گردید.



شکل ۲. فلوچارتی از متدولوژی پیشنهاد شده برای مدل‌سازی رواناب براساس مدل‌های هیبرید SARIMA-MLP و SARIMA-ORELM

### ملاک‌های ارزیابی مدل

از بین معیارهای ریاضی مختلف، چهار معیار ریاضی شامل میانگین خطای مطلق (MAE)، ریشه میانگین مربع خطا (RMSE)، معیار ایک

<sup>۱</sup>(AIC) و ضریب همبستگی (R) برای ارزیابی دقت و پیچیدگی انتخاب شدند. معیارهای MAE و RMSE بر اساس خطای نسبی برای نشان دادن دقت مدل، معیار AIC برای نشان دادن دقت و پیچیدگی مدل و معیار R برای نشان دادن رابطه خطی بین مقادیر مدل شده و مقادیر مشاهده شده به کار برده می‌شوند.

این معیارهای ریاضی به صورت زیر محاسبه می‌شوند:

$$MAE = \frac{1}{N_o} \sum_{t=1}^n |Ru_{o(t)} - Ru_{f(t)}| \quad \text{رابطه ۳۴}$$

$$RMSE = \frac{1}{N_o} \sqrt{\sum_{t=1}^n (Ru_{o(t)} - Ru_{f(t)})^2} \quad \text{رابطه ۳۵}$$

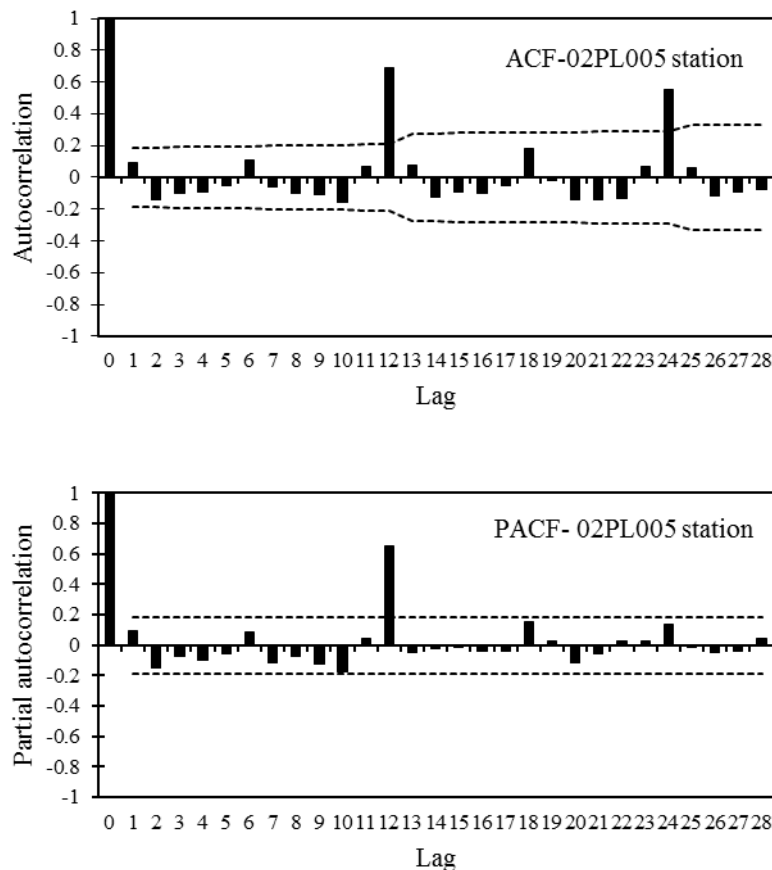
$$AIC = N_o \times \log((RMSE)^2) + 2 \times k_o \quad \text{رابطه ۳۶}$$

$$R = \frac{\sum_{t=1}^n (Ru_{o(t)} - \overline{Ru_o})(Ru_{f(t)} - \overline{Ru_f})}{\sqrt{\sum_{t=1}^n (Ru_{o(t)} - \overline{Ru_o})^2 \sum_{t=1}^n (Ru_{f(t)} - \overline{Ru_f})^2}} \quad \text{رابطه ۳۷}$$

که در آن  $Ru_{o(t)}$  مقادیر مشاهداتی و  $Ru_{f(t)}$  مقادیر پیش‌بینی شده می‌باشد.  $N_o$  و  $k_o$  به ترتیب تعداد کل داده‌ها و تعداد کل پارامترها هستند.

## نتایج و بحث

قبل از شروع مدل‌سازی، ابتدا داده‌ها به دو دسته آموزش و تست تقسیم می‌شوند که برای این منظور ۷۰ درصد از کل داده‌های اندازه‌گیری شده برای آموزش مدل و بقیه داده‌ها که شامل ۳۰ درصد داده‌ها می‌باشد، برای تست مدل در نظر گرفته شده است. سپس قابلیت پیش‌بینی داده‌ها با آزمون هرست (H) و با استفاده از داده‌های آموزش مورد ارزیابی قرار گرفت. مقدار ضریب هرست بدست آمده از داده‌ها برابر با ۰/۶۳ می‌باشد، که نشان دهنده کفایت طول سری زمانی برای مدل‌سازی رواناب می‌باشد. تست JB نرمالیده سری زمانی را مورد بررسی قرار می‌دهد. مقدار احتمالی بدست آمده از این آزمون برابر با ۰/۰۰۰۱ می‌باشد. با توجه به اینکه مقدار آماره بدست آمده از این آزمون کمتر از ۵ درصد می‌باشد در نتیجه سری زمانی دارای توزیع غیرنرمال می‌باشد. سه تابع نرمال‌ساز شامل Logstd، Log و Box-Cox برای نرمال‌سازی داده‌های رواناب در نظر گرفته شد. با انتقال داده‌ها از طریق این توابع، آزمون JB به صورت مجدد بر روی داده‌ها انجام و مقدار P-value بدست آمده از طریق تابع Log برابر با ۰/۸۶، از طریق تابع Logstd برابر با ۰/۶۴ و از طریق تابع Box-Cox برابر با ۰/۸۷ بدست آمد. با توجه به اینکه مقدار P-value بدست آمده از تمامی توابع بزرگتر از ۵ درصد شده است، در نتیجه تمام سری‌های زمانی دارای توزیع نرمال می‌باشند. مقایسه نتایج بدست آمده از توابع مختلف نشان داد که تابع Box-Cox داده‌ها را به توزیع نرمال نزدیکتر می‌کند. علاوه بر نرمال‌سازی، ایستایی داده‌ها نیز باید مورد بررسی قرار گیرد. دو آزمون KPSS و PP برای ایستایی سری زمانی مورد بررسی قرار گرفت. مقدار P-Value بدست آمده از آزمون KPSS برابر با ۰/۲۱۳ و از آزمون PP کمتر از ۰/۰۰۰۱ بدست آمد که نشان دهنده ایستایی سری زمانی می‌باشد. با توجه به اینکه داده‌های سری زمانی نیاز به نرمال‌سازی دارند، بعد از انتقال از طریق توابع مختلف، مجدداً ایستایی سری زمانی مورد بررسی قرار گرفت. نتایج مجدد آزمون PP و KPSS نشان داد که سری انتقال داده شده غیرایستا بوده و در نتیجه غیرایستایی سری زمانی بایستی مورد بررسی قرار گیرد. با ترسیم نمودار ACF و PACF (شکل ۳)، ترم فصل با تکرار ۱۲ در سری زمانی مشاهده گردید. مقدار P-value بدست آمده از آزمون من-وایتی برابر با ۰/۰۰۹ بدست آمد که نشان دهنده وجود ترم پرش در داده‌ها می‌باشد. با انجام آزمون من-کندال (P-value=0.015<0.05) و من-کندال فصلی (P-value=0.0002<0.05) وجود ترم روند در سری زمانی تایید گردید. به طور کلی می‌توان گفت که داده‌های مورد بررسی دارای هر سه ترم قطعی در سری زمانی می‌باشند. بعد از شناسایی ترم‌های قطعی در سری زمانی بایستی این ترم‌ها از سری زمانی حذف و یا اثر آن‌ها کاهش داده شود.



شکل ۳. نمودار ACF و PACF مربوط به ایستگاه 02PL005.

پس از انجام روش‌های مختلف ایستاسازی، روش ایستاسازی مناسب مشخص شد و با انجام تفاضل‌گیری فصلی تمام ترم‌های قطعی از سری زمانی حذف گردیدند. سپس با تغییر پارامترهای مختلف اعم از فصلی و غیرفصلی، شبیه‌سازی‌هایی برای هر زیر سناریو انجام شد. در سناریو دوم که شامل عملیات پیش‌پردازش می‌باشد و چهار زیرسناریو مختلف تعریف گردیده است، قبل از انجام شبیه‌سازی، داده‌ها از طریق توابع نرمال‌ساز (شامل Log، Box-Cox، استاندارد و Logstd) انتقال داده شده و سپس وارد مرحله مدل‌سازی می‌گردند. پس از انجام مدل‌سازی برای هر زیر سناریو، مدلی که کمترین پیچیدگی را داشته باشد، انتخاب شده و با انجام آزمون لجنجنگ باکس، استقلال باقی‌مانده‌های مدل مورد بررسی قرار گرفت. در این آزمون که بر روی باقی‌مانده‌های مدل انجام می‌گیرد در صورتی که مقدار بدست آمده از P-value برای تمام تاخیرهای زمانی بیشتر از ۵ درصد باشد مدل از نظر استقلال باقی‌مانده‌ها تایید می‌گردد. به این ترتیب برای هر زیر سناریو یک مدل مناسب انتخاب گردید. نتایج مدل‌های برتر برای هر زیر سناریو بر اساس معیارهای مختلف ریاضی در جدول ۳ آورده شده است.

مدل برتر در سناریوی اول که شامل یک زیرسناریو می‌باشد، با  $MAE=13.28$ ،  $RMSE=17.23$ ،  $R=0.62$  و  $AIC=267.54$  با استفاده از پارامترهای فصلی به دست آمد. در سناریوی دوم، چهار زیر سناریو اجرا شد. زیرسناریوی ۴ با  $MAE=12.76$ ،  $RMSE=13.11$  و  $R=0.57$  و  $AIC=264.41$  نتایج بهتری را نسبت به سایر زیرسناریوها نشان می‌دهد. با این حال، زیرسناریوهای دیگر بهترین همبستگی خطی را ایجاد می‌کنند ( $R=0.64$ ). مقایسه زیرسناریوها مربوط به سناریو دوم نشان می‌دهد که اجرا از طریق زیرسناریوی ۴ کمترین مقدار  $RMSE$  و  $AIC$  را نسبت به سایر زیرسناریوها ایجاد می‌کند. بنابراین، بهترین پیش‌پردازش در سناریوی ۲، پیش‌پردازش از طریق تابع استاندارد می‌باشد که همزمان دقت بالاتر و پیچیدگی کمتری را دارد. مقایسه معیارهای ریاضی سناریوی اول (بدون پیش‌پردازش) و سناریوی دوم (با پیش‌پردازش) نشان می‌دهد که انجام پیش‌پردازش از طریق تابع استاندارد باعث کاهش مقدار پیچیدگی ( $AIC=264.41$ ) و خطای مدل‌سازی ( $MAE=12.76$  و  $RMSE=13.11$ ) می‌گردد. مقایسه نتایج اجرای مدل از طریق سناریو اول و دوم نشان می‌دهد که انجام پیش‌پردازش سبب افزایش دقت مدل‌سازی می‌گردد اما پیش‌پردازش از طریق استاندارد سازی دقت مدل را افزایش داده و سبب کاهش

پیچیدگی مدل می‌گردد در نتیجه اجرا از طریق این زیرسناریو سبب نتایج بهتری می‌گردد.

جدول ۳- نتایج معیارهای ریاضی مختلف برای تعیین بهترین مدل‌های خطی در ایستگاه 02PL005.

R	AIC	RMSE	MAE	مدل برتر	پیش‌پردازش	زیرسناریو	سناریو
۰.۶۲	۲۶۷,۵۴	۱۷,۲۳	۱۳,۲۸	(0,0,0)(1,1,2)12	-	۱	۱
۰.۶۴	۲۶۸,۶۴	۱۵,۳۴	۱۰,۹۴	(0,1,5)(2,1,0)12	Log	۲	
۰.۶۴	۲۶۸,۳۸	۱۵,۲۹	۱۰,۹۱	(0,1,5)(2,1,0)12	Box-cox	۳	
۰.۵۷	۲۶۴,۴۱	۱۳,۱۱	۱۲,۷۶	(0,0,1)(0,1,0)12	Standard	۴	۲
۰.۶۴	۲۶۸,۸۲	۱۳,۶۹	۱۰,۸۴	(0,0,5)(2,1,0)12	Logstd	۵	

### نتایج مدل غیرخطی MLP

در ابتدا ترکیبات ورودی به مدل غیرخطی برای مدل‌سازی رواناب به صورت ماهانه بایستی مشخص گردند. برای تعیین این ترکیبات ورودی، دیاگرام‌های ACF و PACF تمام ایستگاه‌های قرار گرفته در ناحیه مورد مطالعه ترسیم و مورد بررسی قرار گرفت. ترکیبات ورودی مختلف براساس تاخیرهای زمانی مختلف از این دیاگرام‌ها به عنوان ورودی به مدل غیر خطی در نظر گرفته شد. تاخیرهای زمانی ۱، ۲، ۳، ۴، ۶، ۱۲ و ۲۴ ماه، تاخیرهای مهم براساس دیاگرام‌های ACF و PACF می‌باشند. با توجه به ترکیبات مختلف این تاخیرها، ۱۶ ترکیب مختلف به عنوان ورودی به مدل غیرخطی در نظر گرفته شد. ۷۰ درصد داده‌های رواناب برای آموزش مدل غیرخطی و باقی‌مانده داده‌ها که شامل ۳۰ درصد داده‌ها می‌شود برای تست مدل در نظر گرفته شد. معیارهای آماری مختلف شامل MAE، RMSE، R و AIC برای بررسی عملکرد مدل و انتخاب مدل با بهترین عملکرد به کار برده شد. مقایسه نتایج بدست آمده از اجرای مدل از ترکیبات مختلف نشان داد که با افزایش تعداد نرون‌های ورودی مقدار پیچیدگی مدل افزایش یافته و به همین ترتیب مقدار دقت مدل‌سازی کاهش پیدا کرد. به نحوی که مدل با ۷ نرون ورودی متشکل از تاخیرهای ۱، ۲، ۳، ۴، ۶، ۱۲ و ۲۴ ماه سبب ایجاد مدل با پیچیدگی برابر با ۴۴۳/۰۳ گردید. به همین دلیل حداکثر سه نرون ورودی برای مدل‌سازی بخش غیرخطی در نظر گرفته شد و از میان ۱۶ ترکیب ورودی مختلف ۹ ترکیب که دارای تعداد نرون ورودی کمتر از ۳ باشند، را به عنوان ورودی به مدل غیرخطی انتخاب گردید و سایر ترکیبات حذف شدند. این ترکیبات در بخش غیرخطی معرفی شدند. مقایسه نتایج بدست آمده از اجرای مدل‌های مختلف نشان داد که مدل ۶ با  $RMSE=13.48$ ،  $MAE=10.25$  و  $R=0.7$  دارای کمترین مقدار خطا و بالاترین همبستگی نسبت به سایر مدل‌ها می‌باشد (شکل ۴). همچنین این مدل دارای کمترین مقدار پیچیدگی نسبت به سایر مدل‌ها می‌باشد.

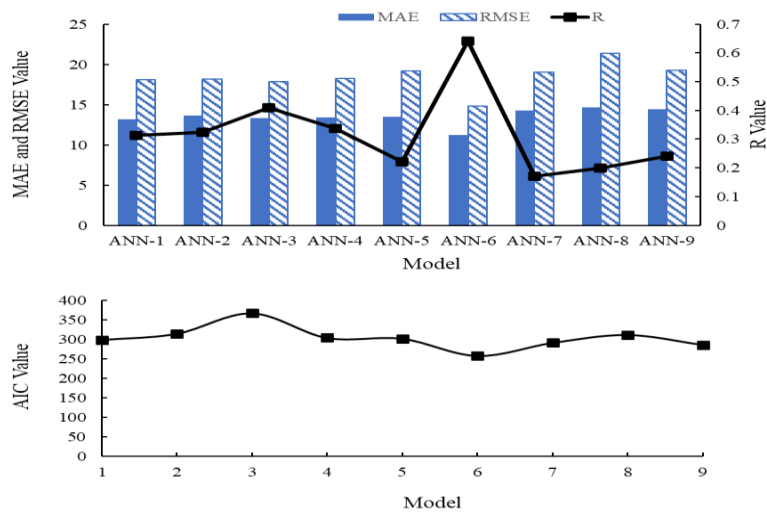
### نتایج مدل غیرخطی ORELM

در ابتدا ترکیبات ورودی به مدل غیرخطی برای مدل‌سازی رواناب به صورت ماهانه بایستی مشخص گردند. برای تعیین این ترکیبات ورودی، دیاگرام‌های ACF و PACF مورد بررسی قرار گرفت. ترکیبات ورودی مختلف براساس تاخیرهای زمانی مختلف از این دیاگرام‌ها به عنوان ورودی به مدل غیر خطی در نظر گرفته شد. تاخیرهای زمانی ۱، ۲، ۳، ۴، ۶، ۱۲ و ۲۴ ماه، تاخیرهای مهم براساس دیاگرام‌های ACF و PACF می‌باشند. با توجه به نتیجه بدست آمده از مدل MLP با افزایش تعداد نرون‌های ورودی میزان پیچیدگی مدل افزایش می‌یابد، به همین دلیل حداکثر سه نرون ورودی برای مدل‌سازی بخش غیرخطی در نظر گرفته شد و از میان ۱۶ ترکیب ورودی مختلف ۹ ترکیب که دارای تعداد نرون ورودی کمتر از سه بودن را به عنوان ورودی به مدل غیرخطی انتخاب گردید و سایر ترکیبات حذف شدند.


### نتایج مدل‌های هیبرید

در این مطالعه دو مدل هیبرید برای مدل‌سازی رواناب پیشنهاد شده است. در هر دو مدل بخش خطی توسط مدل خطی استوکاستیک فصلی براساس سناریوهای مختلف مدل‌سازی گردید. سپس با مقایسه نتایج بدست آمده از سناریوهای مختلف مدل برتر خطی مشخص گردید و باقی‌مانده‌های مدل خطی برتر محاسبه گردیدند. در مدل هیبرید اول باقی‌مانده‌های مدل خطی توسط مدل غیرخطی MLP با ترکیبات مختلف مدل‌سازی گردید. سپس خروجی مدل غیرخطی با نتایج بدست آمده از مدل خطی جمع و با استفاده از شاخص‌های آماری مختلف نتایج هر مدل محاسبه گردید. در مدل هیبرید دوم، باقی‌مانده‌های مدل خطی توسط مدل غیرخطی ORELM با ترکیبات مختلف مدل‌سازی و سپس خروجی مدل غیرخطی با مدل خطی جمع گردیده و شاخص‌های آماری مختلف برای آن مدل‌ها محاسبه گردیدند. نتایج بدست آمده براساس شاخص‌های آماری مختلف برای هر دو مدل هیبرید در شکل ۵ آورده شده است. مقایسه نتایج بدست آمده از مدل‌سازی به روش هیبرید SARIMA-MLP نشان داد که مدل ۴ که از ترکیب تاخیرهای ۱ و ۶ ماه برای مدل‌سازی بخش غیرخطی استفاده می‌کند

با  $MAE=11.35$ ،  $RMSE=14.67$ ،  $AIC=254.41$  و  $R=0.65$  کمترین خطا و بالاترین همبستگی و همچنین کمترین پیچیدگی را نسبت به سایر ترکیبات ایجاد می‌کند. مدل ۱ با یک نرون ورودی که از تاخیر ۱ ماه بدست می‌آید دارای بالاترین مقدار پیچیدگی ( $AIC=270$ ) و کمترین مقدار همبستگی ( $R=0.55$ ) نسبت به سایر ترکیبات را دارد. بیشترین مقدار خطا در نتیجه مدل‌سازی از طریق مدل ۸ ( $MAE=14.69$ ) و مدل ۷ ( $RMSE=17.47$ ) بدست آمد. بنابراین مدل‌های ۱، ۷ و ۸ جزو مدل‌های با عملکرد ضعیف می‌باشند. مقایسه نتایج بدست آمده از مدل هیبرید SARIMA-ORELM نشان داد که مدل ۶ با  $AIC=249.29$ ،  $R=0.71$ ،  $MAE=11.2$  و  $RMSE=14.33$  دارای بهترین عملکرد از نظر دقت و پیچیدگی نسبت به سایر مدل‌ها می‌باشد. بالاترین مقدار پیچیدگی ( $AIC=259.64$ ) و بالاترین خطا ( $MAE=13.26$ ) در مدل ۱۲ مشاهده شد. کمترین مقدار همبستگی ( $R=0.62$ ) و بالاترین خطا ( $RMSE=16.01$ ) در مدل ۷ مشاهده شد. بنابراین مدل ۷ و ۱۲ جزو مدل‌ها با عملکرد ضعیف در مدل‌سازی می‌باشند.



شکل ۴. نتایج معیارهای ریاضی برای تعیین بهترین مدل‌های غیرخطی.



شکل ۵. نتایج معیارهای ریاضی برای تعیین بهترین مدل هیبرید.

#### مقایسه مدل‌ها

شکل ۶ مقایسه بین داده‌های اندازه‌گیری شده رواناب با نتایج مدل‌سازی از طریق اجرای مدل‌های برتر ساریما، ساریما با پیش‌پردازش، MLP، هیبرید SARIMA-MLP و هیبرید SARIMA-ORELM را نشان می‌دهد. در جدول ۴ نتایج معیارهای ریاضی مختلف برای مدل‌سازی رواناب ماهانه از طریق اجرای مدل‌های برتر خطی، غیرخطی MLP، غیرخطی ORELM، هیبرید SARIMA-MLP و هیبرید SARIMA-ORELM آورده شده است. مقایسه مدل‌سازی خطی در دو سناریو مختلف با انجام پیش‌پردازش و بدون انجام پیش‌پردازش




نشان می‌دهد که در تمام معیارهای ریاضی بجز در معیار همبستگی، پیش‌پردازش سبب بهبود نتایج مدل‌سازی خطی می‌گردد. مشابه با نتایج بدست آمده از این تحقیق، Wang et al., (2024) نیز نشان دادند که با انجام پنج روش پیش‌پردازش مختلف بر روی سری زمانی سبب بهبود دقت مدل‌سازی رواناب می‌گردد. بنابراین انتخاب پیش‌پردازش مناسب سبب افزایش دقت و کاهش پیچیدگی مدل می‌گردد. مقایسه مدل‌های غیر خطی نشان می‌دهد که مدل غیر خطی MLP با  $R=0.7$ ،  $MAE=10.25$  و  $RMSE=13.48$  از نظر معیارهای آماری خطا و همبستگی بهتر از روش ORELM عمل می‌کند. اما در مقابل روش ORELM در معیار پیچیدگی با  $AIC=256.50$  بهتر از روش MLP رواناب را انجام می‌دهد. با توجه به اینکه مدل ORELM دارای پیچیدگی کمتری می‌باشد، مدل غیرخطی بهتری برای مدل‌سازی رواناب می‌باشد. (Ebtehaj and Bonakdari (2022) با مدل‌سازی رواناب براساس روش‌های مبتنی بر ELM نیز نشان دادند که در مدل‌سازی رواناب روش IORELM بهتر از سایر روش‌ها مدل‌سازی رواناب را انجام می‌دهد. مقایسه مدل‌های هیبرید نشان می‌دهد که مدل هیبرید SARIMA-ORELM در تمام معیارهای ریاضی بهتر از مدل هیبرید SARIMA-MLP عمل می‌کند.

Niu et al., (2019); Gelete (2023); Parsaie et al., (2024) نیز به طور مشابه تأثیر امیدوارکننده مدل‌های ترکیبی را برای مدل‌سازی رواناب در مطالعاتشان نشان دادند. نتایج مدل‌های خطی و غیرخطی نشان می‌دهد که مدل غیرخطی MLP از نظر دو معیار MAE و R بهتر از سایر مدل‌ها مدل‌سازی رواناب را انجام می‌دهد و مدل غیرخطی ORELM دارای پیچیدگی کمتری نسبت به سایر مدل‌ها می‌باشد. مدل خطی با انجام پیش‌پردازش نیز از نظر معیار RMSE بهتر از سایر مدل‌ها مدل‌سازی رواناب را انجام می‌دهد. به طور کلی می‌توان نتیجه گرفت که مدل غیرخطی در مدل‌سازی رواناب بهتر از مدل خطی عمل می‌کند. مقایسه تمامی مدل‌ها با یکدیگر نشان می‌دهد که مدل هیبرید SARIMA-ORELM از نظر تمامی معیارها بجز در معیار RMSE بهتر از سایر مدل‌ها مدل‌سازی را انجام می‌دهد و دارای خطای کمتر و پیچیدگی کمتر نسبت به سایر مدل‌ها می‌باشد.

جدول ۴- نتایج معیارهای ریاضی مختلف برای تعیین بهترین مدل

مدل	AIC	R	RMSE	MAE
ساریمما	۲۶۷/۵۴	۰/۶۲	۱۷/۲۳	۱۳/۲۸
ساریمما+پیش پردازش	۲۶۴/۴۱	۰/۵۷	۱۳/۱۱	۱۲/۷۶
MLP	۲۵۸/۳۶	۰/۷۰	۱۴/۷۷	۱۱/۲۱
ORELM	۲۵۶/۵۰	۰/۶۴	۱۵/۱۶	۱۲/۱۵
SARIMA-ORELM	۲۴۹/۲۹	۰/۷۱	۱۴/۳۳	۱۱/۲۰
SARIMA_MLP	۲۵۴/۴۱	۰/۶۵	۱۴/۶۸	۱۱/۳۶



شکل ۶. نتایج خروجی مدل‌های مختلف برای تعیین بهترین مدل.

## نتیجه‌گیری

در این مطالعه به پیشنهاد ترکیب مدل ماشین یادگیری افراطی مناسب داده پرت (ORELM) با مدل خطی میانگین متحرک اتورگرسیو فصلی (SARIMA) برای بهبود دقت مدل‌سازی رواناب پرداخته شد. روش پیشنهادی ما شامل جمع‌آوری داده‌های رواناب از ایستگاه 02PL005، تعریف سناریوهای مختلف برای بخش مدل‌سازی خطی، تعریف ترکیب ورودی‌های مختلف برای بخش مدل‌سازی غیرخطی و



استفاده از تکنیک‌های پیش پردازش مختلف برای مدل‌سازی رواناب می‌باشد. سپس مدل‌ها از طریق ارزیابی عملکرد کیفی مورد ارزیابی قرار گرفتند. خلاصه‌ای از مهم‌ترین نتایج به شرح زیر است:

انجام پیش‌پردازش سبب بهبود نتایج مدل‌سازی خطی گردید.

با وجود اینکه پیش‌پردازش از طریق تابع BOX-COX داده‌ها را به توزیع نرمال نزدیکتر می‌کند اما با انجام پیش‌پردازش از طریق تابع استاندارد و استانداردسازی داده‌ها قبل از مدل‌سازی نتایج بهتری بدست آمد.

مدل هیبرید SARIMA-ORELM در تمام معیارهای ریاضی بهتر از مدل هیبرید SARIMA-MLP عمل می‌کند.

مدل‌های هیبرید SARIMA-MLP و SARIMA-ORELM به ترتیب سبب کاهش ۴/۹ درصد و ۶/۸ درصد پیچیدگی مدل نسبت به حالت مدل‌سازی خطی بدون انجام پیش‌پردازش شدند.

ضعیف‌ترین عملکرد از نظر معیارهای خطا و پیچیدگی در بین شش مدل مختلف انتخاب شده برای مدل‌سازی رواناب، انجام مدل‌سازی از طریق مدل کلاسیک SARIMA بدون انجام پیش‌پردازش بدست می‌آید.

با توجه به اینکه در مطالعه حاضر از روش مبتنی بر یادگیری ماشین برای محاسبه رواناب استفاده شده است، پیشنهاد می‌شود که در کارهای آینده با استفاده از مدل‌های مفهومی مانند مدل GR4J برای مدل‌سازی رواناب استفاده و نتایج آنها با مطالعه حاضر مقایسه گردد.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

## REFERENCES

- Azari, A., Zeynoddin, M., Ebtehaj, I., Sattar, A. M. A., Gharabaghi, B. and Bonakdari, H. 2021. Integrated preprocessing techniques with linear stochastic approaches in groundwater level forecasting. *Acta Geophysica*, 69, 1395–1411. <https://doi.org/10.1007/s11600-021-00617-2>.
- Bayesteh, M., & Azari, A. (2019). Comparison of the performance of stochastic models in the generation of synthetic monthly flows data: A case study on Marun river. *Journal of Applied Research in Water and Wastewater*. 12, 117-125. <https://doi.org/10.22126/arww.2019.1405>.
- Box, G. E. P., & Jenkins, G. (1970). *Time series analysis: Forecasting and control* (2nd ed.). San Francisco, CA: Holden-Day.
- Dwivedi, D. K., & Shrivastava, P.K. (2019). Rainfall and runoff estimation of micro watersheds of coastal Navsari. *Journal of Soil and Water Conservation* 18(1): 43-51, January-March 2019. ISSN: 022-457X (Print); 2455-7145 (Online); <https://doi.org/10.5958/2455-7145.2019.00005.5>.
- Ebtehaj, I., & Bonakdari, H. (2022). A reliable hybrid outlier robust non-tuned rapid machine learning model for multi-step ahead flood forecasting in Quebec, Canada, *Journal of Hydrology*, Volume 614, Part B, 2022, 128592, ISSN 0022-1694, <https://doi.org/10.1016/j.jhydrol.2022.128592>.
- Ebtehaj, I., Bonakdari, H., & Gharabaghi, B. (2019). A reliable linear method for modeling lake level fluctuations. *Journal of Hydrology*. 570 (2019), 236-250. <https://doi.org/10.1016/j.jhydrol.2019.01.010>.
- Ebtehaj, I., Bonakdari, H., Zeynoddin, M., Gharabaghi, B., & Azari, A. (2020). Evaluation of preprocessing techniques for improving the accuracy of stochastic rainfall forecast models. *Int. Journal of Environment Science Technology*. 17, 505–524. <https://doi.org/10.1007/S13762-019-02361-Z>.
- Gelete, G. (2023). Application of hybrid machine learning-based ensemble techniques for rainfall-runoff modeling. *Earth Sci Inform* 16, 2475–2495. <https://doi.org/10.1007/S12145-023-01041-4>.
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: theory and applications. *Neurocomputing* 70(1–3):489–501.
- Jarque, C. M., & Bera, A. K. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Econ Lett*. 6(3):255–259. [https://doi.org/10.1016/0165-1765\(80\)90024-5](https://doi.org/10.1016/0165-1765(80)90024-5).
- Kwiatkowski, D., Phillips, P. C. B., Schmidt, P. & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root? *J Econo*. 54(1–3), 159–178. [https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y).
- Kim, T., Shin, J. Y., Kim, H., Kim, S., & Heo, J. H. (2019). The Use of Large-Scale Climate Indices in Monthly Reservoir Inflow Forecasting and Its Application on Time Series and Artificial Intelligence Models. *Water*. 2019, 11, 374. <https://doi.org/10.3390/w11020374>.
- Lima, L. M. M., Popova, E., & Damien, P. (2014). Modeling and forecasting of Brazilian reservoir inflows via dynamic linear models. *International Journal of Forecasting*. 30 (2014) 464–476. <https://doi.org/10.1016/j.ijforecast.2013.12.009>.

- Moeeni, H., Bonakdari, H., & Ebtehaj, I. (2017). Integrated SARIMA with Neuro-Fuzzy Systems and Neural Networks for Monthly Inflow Prediction. *Water Resource Management*. 31, 2141–2156 (2017). <https://doi.org/10.1007/s11269-017-1632-7>.
- Nath, A., Mthethwa, F., & Saha, G. (2020). Runoff estimation using modified adaptive neuro-fuzzy inference system. *Environment Engineering Res.* 25(4), 545-553. <https://doi.org/10.4491/eer.2019.166>.
- Niu, W. J., Feng, Z. K., Zeng, M., Feng, B., Min, Y. W., Cheng, C. T., & Zhou, J. Z. (2019). Forecasting reservoir monthly runoff via ensemble empirical mode decomposition and extreme learning machine optimized by an improved gravitational search algorithm. *Applied Soft Computing*. 82, 105589. <https://doi.org/10.1016/j.asoc.2019.105589>.
- Nourani, V., Najafi, H., Amini, A., & Tanaka, H. (2021). Using hybrid wavelet-exponential smoothing approach for streamflow modeling. *Complexity*. 1-17. <https://doi.org/10.1155/2021/6611848>.
- Nourmohammadi Dehbalaei, F., Azari, A. & Akhtari, A. A. (2023). Development of a linear–nonlinear hybrid special model to predict monthly runoff in a catchment area and evaluate its performance with novel machine learning methods. *Appl Water Sci* 13, 118 (2023). <https://doi.org/10.1007/s13201-023-01917-2>.
- Parsaie, A., Ghasemlounia, R., Gharehbaghi, A., Haghiabi, A., Chadee, A. A., Rashki Ghale Nou, M. (2024). Novel hybrid intelligence predictive model based on successive variational mode decomposition algorithm for monthly runoff series, *Journal of Hydrology*, Volume 634, 2024, 131041, ISSN 0022-1694, <https://doi.org/10.1016/j.jhydrol.2024.131041>.
- Phillips, P. C. B., & Perron, P. (1988). Testing for a unit root in time series regression, *Biometrika*, 75(2), 335-46.
- Salih, S. Q., Sharafati, A., Ebtehaj, I., Sanikhani, H., Siddique, R., Deo, R. C., Bonakdari, H., ShahidS., & Yaseen, Z. M. (2020). Integrative stochastic model standardization with genetic algorithm for rainfall pattern forecasting in tropical and semi-arid environments. *Hydrological Sciences Journal*. 65(2020), 7. <https://doi.org/10.1080/02626667.2020.1734813>.
- Soltani, K., Azari, A., Zeynoddin, M., Amiri, A., Ebtehaj, I., Ouarda, T. B. M. J., Gharabaghi, B., & Bonakdari, H. (2021). Lake surface area forecasting using integrated satellite-sarima-long-short-term memory model. 04 August 2021, PREPRINT (Version 1). <https://doi.org/10.21203/rs.3.rs-631247/v1>.
- Wang, W.C., Du, Y. J., Chau, K. W., Cheng, C. T., Xu, D. M. & Zhuang, WT. (2024). Evaluating the Performance of Several Data Preprocessing Methods Based on GRU in Forecasting Monthly Runoff Time Series. *Water Resour Manage* 38, 3135–3152. <https://doi.org/10.1007/s11269-024-03806-y>.
- Zhang, K., & Luo, M., (2015). Outlier-robust extreme learning machine for regression problems, *Neurocomputing* 151 (2015) 1519-1527. <https://doi.org/10.1016/j.neucom.2014.09.022>.
- Zhang, X., Wu, X., Zhu, G., Lu, X., & Wang, K. (2022). A seasonal ARIMA model based on the gravitational search algorithm (GSA) for runoff prediction. *Water Supply* 22 (8): 6959–6977. <https://doi.org/10.2166/ws.2022.263>.
- Zhihua, L.V., Zuo, J., & Rodriguez, D. (2020). Predicting of Runoff Using an Optimized SWAT-ANN: A Case Study. *Hydrology*.29. <https://doi.org/10.1016/j.ejrh.2020.100688>.