



UNIVERSITY OF TABRIZ

Journal of Hydraulics and Water Science

Online ISSN: [3092-6114](https://doi.org/10.22034/hws.2025.67753.1036)

Journal homepage: <https://hws.tabrizu.ac.ir/>



Original Article

Application of MIDAS Model in Flood Forecasting (Case Study: Bahramjoo Basin, Lorestan Province)

Mehdi Komasi* ¹, Afsaneh Abdoli Kolivand ²

1- Associate Prof., Department of Civil Engineering, Faculty of Engineering, Ayatollah Boroujerdi University, Boroujerd, Iran.

2- M.Sc., Department of Civil Engineering, Faculty of Engineering, Ayatollah Boroujerdi University, Boroujerd, Iran.

Received: 15/March/2025

Accepted: 21/Sep/2025

Revised: 27/May/2025

Published online: 22/Dec/2025

* Corresponding Author's Email: Komasi@abru.ac.ir

ARTICLE INFO

ABSTRACT

Keywords:

ARDL
Flood
GARCH
MIDAS
Regression
Time series

Introduction

In recent decades, the increasing frequency and intensity of flood events have become a major concern in water resources management and environmental planning. Floods are among the most destructive natural hazards, causing substantial economic damage, loss of life, and disruption to ecosystems. The challenge of accurately predicting runoff is particularly significant in mountainous watersheds, where complex terrain, heterogeneous precipitation patterns, and rapid hydrological responses increase uncertainty in modeling processes. Seasonal variability of rainfall further complicates the prediction of runoff, making it essential to adopt advanced modeling techniques capable of capturing these dynamics.

The Bahramjoo watershed in Lorestan Province represents a typical mountainous basin characterized by seasonal precipitation and considerable variability in hydrological behavior. Traditional time series models often face limitations when dealing with such variability, especially when input data are available at different temporal frequencies. In recent years, data-driven approaches have gained increasing attention due to their flexibility and ability to model complex relationships without requiring detailed physical assumptions. Among these, the Mixed Data Sampling (MIDAS) model has emerged as a promising approach for handling mixed-frequency data, although its application in hydrology remains relatively limited compared to fields such as economics.

Objectives

The primary objective of this study is to evaluate and compare the performance of three time series models-MIDAS, Autoregressive Distributed Lag (ARDL), and Generalized Autoregressive Conditional Heteroskedasticity (GARCH) in predicting seasonal runoff in the Bahramjoo watershed. Specifically, the study aims to assess the capability of these models in handling mixed-frequency data, improving prediction accuracy, and preserving the inherent structure of hydrological time series. Another key objective is to investigate whether the MIDAS

How to cite: Komasi, M. Abdoli Kolivand, A. *Application of MIDAS Model in Flood Forecasting (Case Study: Bahramjoo Basin, Lorestan Province)*. Journal of Hydraulics and Water Science, 35 (4):27-43.

<https://doi.org/10.22034/hws.2025.67753.1036>



This is an open-access article under the CC BY NC license
(<https://creativecommons.org/licenses/by-nc/4.0/>)



model can provide a methodological advantage over conventional models by directly incorporating high-frequency precipitation data into seasonal runoff forecasting.

Materials and Methods

The dataset used in this study consists of seasonal streamflow data and monthly precipitation records collected from hydrometric and meteorological stations within the study area over the period 2006 to 2023. A major challenge in the analysis arises from the mismatch in temporal frequency between the dependent variable (seasonal runoff) and the independent variable (monthly precipitation). To address this issue, three modeling approaches were implemented. In the ARDL and GARCH models, monthly precipitation data were aggregated into seasonal values to match the temporal scale of the runoff data. However, this aggregation process may result in the loss of valuable information embedded in high-frequency data. In contrast, the MIDAS model allows for the direct integration of mixed-frequency variables without the need for aggregation, thereby preserving the original temporal resolution of the data. Each model was calibrated using historical data and evaluated based on statistical performance metrics, including the coefficient of determination (R^2) and the root mean square error (RMSE). Additionally, cross-validation techniques were employed to ensure the robustness and reliability of the results. These evaluation criteria provide a comprehensive assessment of the models' ability to capture both the variability and magnitude of runoff.

Results and Discussion

The results indicate that all three models are capable of capturing the general trend of seasonal runoff variations in the study area. However, significant differences are observed in their predictive performance. Among the models, the MIDAS approach demonstrates the highest level of accuracy, with an R^2 value of 0.82 and an RMSE of 0.61 m³/s. In comparison, the ARDL model achieves an R^2 of 0.66 and an RMSE of 0.93 m³/s, while the GARCH model yields an R^2 of 0.52 and an RMSE of 0.71 m³/s. The superior performance of the MIDAS model can be attributed to its ability to incorporate high-frequency precipitation data directly into the modeling framework. By avoiding temporal aggregation, the model preserves important information that would otherwise be lost in conventional approaches. Furthermore, the flexible weighting structure of the MIDAS model allows it to assign different levels of importance to lagged values of precipitation, thereby capturing delayed hydrological responses more effectively. The analysis also reveals that the runoff dynamics in the Bahramjoo watershed exhibit relatively stable behavior with characteristics of long-term memory. Runoff tends to increase during wet seasons and decrease during dry periods, reflecting the strong influence of precipitation patterns. The MIDAS model is particularly effective in capturing these seasonal fluctuations due to its ability to model interactions between variables with different temporal frequencies.

Overall, the findings highlight the limitations of traditional models such as ARDL and GARCH when applied to mixed-frequency hydrological data. While these models remain useful in certain contexts, their reliance on aggregated data reduces their ability to capture fine-scale temporal variations. In contrast, the MIDAS model provides a more comprehensive representation of the underlying processes, leading to improved predictive performance.

Conclusion

This study demonstrates that the MIDAS model offers a significant improvement over conventional time series models in predicting seasonal runoff in mountainous watersheds. Its ability to integrate mixed-frequency data without aggregation allows for better preservation of temporal information and enhances model accuracy. The results suggest that MIDAS is a robust and efficient tool for hydrological forecasting, particularly in cases where input data are available at different temporal scales. From a practical perspective, the application of the MIDAS model can contribute to more accurate flood forecasting, improved water resources management, and more effective mitigation of flood-related risks. The findings of this research provide valuable insights for hydrologists, engineers, and decision-makers seeking to enhance predictive capabilities in complex hydrological systems. Future research may focus on extending the application of the MIDAS framework to other regions and temporal scales, as well as integrating it with advanced techniques such as machine learning models. Such efforts could further improve the accuracy and reliability of hydrological predictions and support sustainable water resources management in the face of increasing climate variability.



کاربرد مدل رگرسیونی MIDAS در پیش‌بینی سیلاب (مطالعه موردی: استان لرستان، حوضه بهرام‌جو)

مهدی کماسی^{۱*}، افسانه عبدلی کولیوند^۲

۱-دانشیار گروه عمران، مهندسی آب و سازه هیدرولیکی دانشگاه آیت الله العظمی بروجردی(ره)

۲- دانشجوی کارشناسی ارشد، مهندسی آب و سازه هیدرولیکی دانشگاه آیت الله العظمی بروجردی(ره)

تاریخ پذیرش: ۱۴۰۴/۰۶/۳۰

تاریخ دریافت: ۱۴۰۳/۱۲/۲۵

تاریخ انتشار آنلاین: ۱۴۰۴/۱۲/۰۱

تاریخ ویرایش: ۱۴۰۴/۰۳/۰۶

* نویسنده مسئول: Komasi@abru.ac.ir

چکیده

باتوجه به اهمیت سیلاب در مدیریت منابع آب، این مطالعه به پیش‌بینی رواناب فصلی حوضه بهرام‌جو طی سال‌های ۲۰۰۶ تا ۲۰۲۳ می‌پردازد. برای مدل‌سازی داده‌های رواناب فصلی به‌عنوان متغیر وابسته و بارش ماهانه به‌عنوان متغیر مستقل از ایستگاه‌های هواشناسی منطقه جمع‌آوری شد و با استفاده از سه مدل سری زمانی MIDAS، ARDL و GARCH تحلیل گردید. عملکرد مدل‌ها با آماره‌های ارزیابی ضریب تبیین (R^2) و جذر میانگین مربعات خطا (RMSE) ارزیابی شد. به‌طور کلی نتایج نشان داد که هرچند سه مدل روند تغییرات رواناب را به درستی پیش‌بینی نمودند، اما دقت مدل MIDAS بالاتر می‌باشد. در این راستا مدل MIDAS، بهترین عملکرد را با ضریب تبیین ۰/۸۲ و RMSE برابر با ۰/۶۱ مترمکعب بر ثانیه داراست. همچنین مدل‌های ARDL و GARCH به‌ترتیب با ضرایب تبیین ۰/۶۶ و ۰/۵۲ و RMSE برابر با ۰/۹۳ و ۰/۷۱ مترمکعب بر ثانیه عملکرد ضعیف‌تری را نسبت به مدل MIDAS داشتند. نتایج این پژوهش بیانگر آن است که متغیر رواناب حافظه بلندمدت خود را در فراز و فرود سری زمانی حفظ کرده و در فصول پر بارش روند افزایشی و در فصول کم‌بارش روند کاهش را داراست. نتیجه کلی به‌دست آمده پژوهش نشان داد که مدل MIDAS به دلیل توانایی ادغام داده‌های با فرکانس‌های زمانی متفاوت روزانه، ماهانه و فصلی، توانایی بهتری را در الگویابی و پیش‌بینی دقیق‌تر رواناب داشته و در نتیجه در مدیریت و کنترل سیلاب‌ها به‌عنوان راهکار مناسب می‌تواند مورد بهره‌برداری قرار گیرد.

کلمات کلیدی: رگرسیون، سری زمانی، سیل، ARDL، MIDAS، GARCH

۱- مقدمه

سیلاب به‌عنوان یکی از مخرب‌ترین بلایای طبیعی در سطح جهانی شناخته می‌شود و اثرات زیان‌بار آن، به‌ویژه در مناطق توسعه‌یافته، هزینه‌های اقتصادی و اجتماعی فراوانی را به همراه دارد. پیش‌بینی جریان رودخانه‌ها، به معنای برآورد حجم آب عبوری یا متوسط دبی در یک بازه زمانی مشخص در آینده، از اهمیت بالایی برخوردار است. این پیش‌بینی‌ها به‌ویژه در مدیریت منابع آب، طراحی سازه‌های هیدرولیکی و برنامه‌ریزی برای مقابله با سیلاب‌ها و خشکسالی‌ها کاربرد دارند.

مدل‌های پیش‌بینی‌کننده جریان به‌طور کلی به سه دسته اصلی مدل‌های مبتنی بر فیزیک، مدل‌های مفهومی و مدل‌های داده‌محور تقسیم می‌شوند. در سال‌های اخیر، استفاده از روش‌های داده‌محور برای مدل‌سازی سری‌های زمانی هیدرولوژیکی به‌عنوان رویکردی نوین مطرح شده است. این مدل‌ها برخلاف مدل‌های مبتنی بر فرآیند، به کمک داده‌های موجود و بدون نیاز به درک عمیق از سیستم هیدرولوژیکی، روابط بین ورودی‌ها و خروجی‌ها را شبیه‌سازی می‌کنند (Badrzadeh, 2014). یکی از مدل‌های داده‌محور کارآمد، مدل رگرسیون داده‌های ترکیبی با تواتر متفاوت (MIDAS¹) است که امکان استفاده هم‌زمان از متغیرهایی با فرکانس‌های زمانی مختلف را فراهم می‌آورد. این مدل به‌ویژه در تحلیل و پیش‌بینی متغیرهای وابسته با تواتر پایین، نظیر دبی ماهانه یا فصلی، کاربرد دارد (Kazemzadeh, 2019). در مقایسه با مدل MIDAS، مدل‌های دیگر مانند ARDL و GARCH نیز در پیش‌بینی سری‌های زمانی مورد استفاده قرار گرفته‌اند. مدل ARDL به‌ویژه در تحلیل روابط بلندمدت و کوتاه‌مدت بین متغیرها کاربرد دارد. همچنین، مدل GARCH به‌عنوان ابزاری برای مدل‌سازی نوسانات در سری‌های زمانی با ویژگی‌های واریانس متغیر، در پیش‌بینی جریان رودخانه‌ها مورد استفاده قرار گرفته است.

در مطالعه (Khazaei & Mirzaei (2013) دبی ماهانه با استفاده از روش‌های شبکه عصبی و سری‌های زمانی پیش‌بینی شده و نتایج نشان‌دهنده دقت بالاتر شبکه عصبی مصنوعی نسبت به مدل‌های ARIMA بوده است. همچنین، (Maroufi et al. (2013 برای پیش‌بینی جریان رودخانه باران‌رزی‌چای در دو ایستگاه بی‌بکران و دیزج طی یک دوره آماری ۲۰ ساله از مدل عصبی - موجکی استفاده کردند و نتایج را با مدل شبکه عصبی مقایسه نمودند. عملکرد مدل‌ها با شاخص‌های آماری ضریب همبستگی، جذر میانگین مربعات خطا و میانگین قدرمطلق خطا سنجش گردید و نتایج حاکی از کارایی مناسب و دقت بالای مدل عصبی موجکی در مقایسه با شبکه عصبی مصنوعی در پیش‌بینی جریان رودخانه است.

در همین راستا، (Solín & Sládeková Madajová (2019) استفاده از مدل GARCH دبی روزانه رودخانه‌های هورن^۲ و موروا^۳ در اسلواکی را پیش‌بینی نمودند. این نتایج حاکی از توانایی مدل GARCH در شبیه‌سازی نوسانات واریانس و بهبود عملکرد مدل‌های پیش‌بینی است. همچنین، (Wang et al. (2023) مدل ترکیبی FARIMA-GARCH برای پیش‌بینی دبی روزانه ۲۱ ایستگاه هیدرولوژیکی در حوضه رودخانه زرد چین بررسی نمودند. نتایج این مطالعه نشان داد که مدل FARIMA-GARCH نسبت به مدل FARIMA ساده، عملکرد بهتری در پیش‌بینی دبی روزانه دارد. با این حال، مدل FARIMA-GARCH قادر به شبیه‌سازی دقیق مقادیر حداکثر دبی نبوده و در دوره‌های اوج جریان، اختلاف زیادی مشاهده شد.

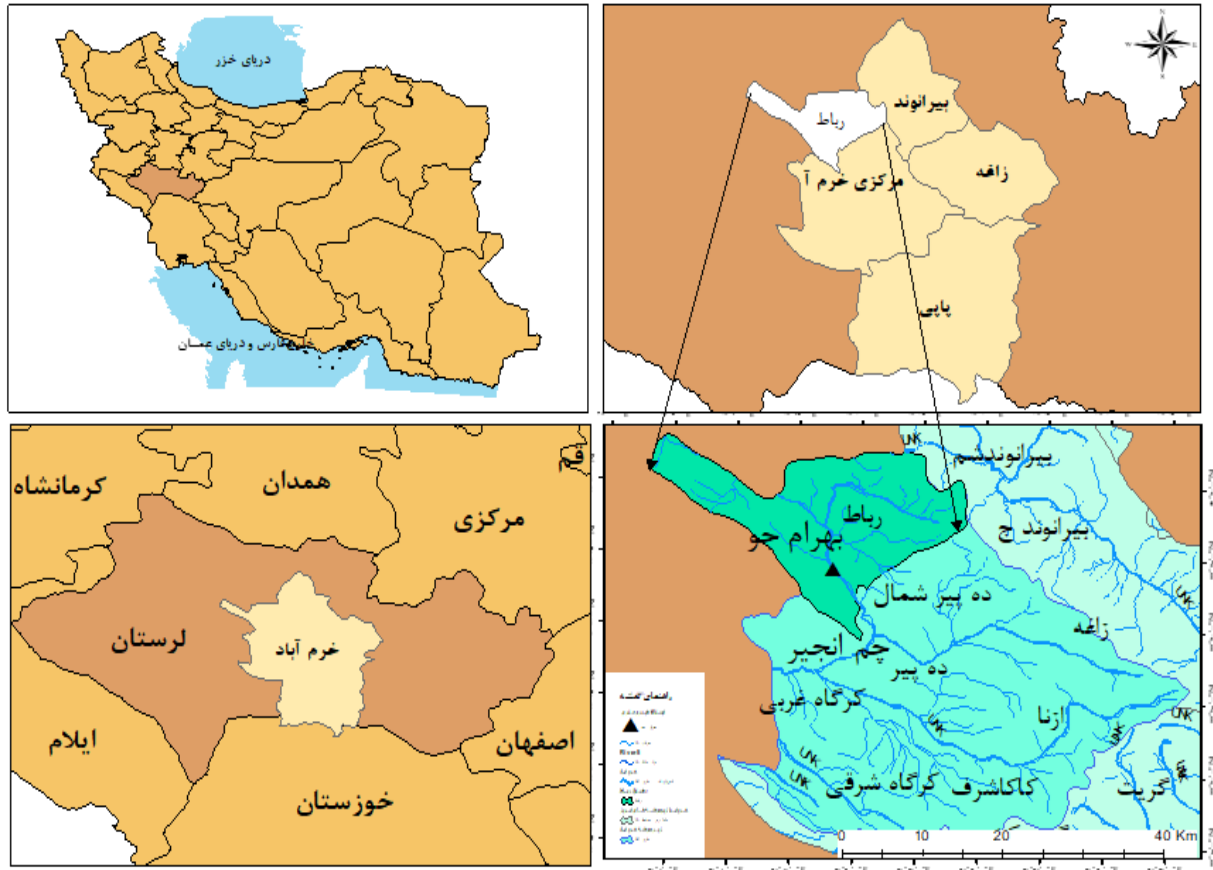
هدف از پژوهش حاضر، توسعه مدل ترکیبی پیش‌بینی سیلاب در حوضه بهرام‌جو با استفاده از سه مدل MIDAS، ARDL و GARCH است. این پژوهش با بهره‌گیری از توانمندی مدل MIDAS در پردازش داده‌های با فرکانس‌های زمانی متفاوت، مدل ARDL در تحلیل روابط کوتاه‌مدت و بلندمدت و مدل GARCH در مدل‌سازی نوسانات واریانس انجام شده است. تلفیق این مدل‌ها در قالب چارچوبی جامع، امکان پیش‌بینی دقیق‌تر دبی جریان رودخانه را فراهم می‌سازد. نتایج این پژوهش می‌تواند در بهبود مدیریت منابع آب، کاهش خسارات ناشی از سیلاب و برنامه‌ریزی مؤثر در شرایط بحران کاربرد داشته باشد. همچنین، نوآوری این پژوهش در استفاده ترکیبی از مدل‌های MIDAS، ARDL و GARCH برای پیش‌بینی رواناب فصلی در حوضه بهرام‌جو است. مقایسه هم‌زمان این مدل‌ها، ارزیابی جامعی از عملکرد آن‌ها فراهم کرده که در مطالعات پیشین کمتر دیده شده است.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

حوضه بهرام‌جو در شمال خرم‌آباد، در طول جغرافیایی ۴۷° ۴۸' - ۷° ۴۸' شرقی و عرض جغرافیایی ۷۰° ۳۳' - ۵۵° ۳۳' شمالی قرار دارد. ارتفاع حداقل این ناحیه ۱۲۶۰ متر از سطح دریا در جنوبی‌ترین نقطه حوضه و ارتفاع حداکثر ۲۸۵۶ متر از سطح دریا در اشرانکوه واقع می‌باشد. مساحت این حوضه ۴۲۸/۲۳ کیلومترمربع می‌باشد. موقعیت منطقه مورد مطالعه در شکل ۱ نشان داده شده است. حوضه مذکور شامل طاق‌دیس‌ها و ناودیس‌هایی است که دارای روند شمال غرب - جنوب شرق می‌باشد. بارندگی‌های این ناحیه فصلی بوده و بیشتر در پاییز و زمستان صورت می‌گیرد و بیشتر به شکل باران در مناطق جنوبی و در مناطق شمالی نیز گاهی به شکل برف صورت می‌گیرد.

Morava^۳Mixed Data Sampling^۱
Horn^۲



شکل ۱- موقعیت منطقه مورد مطالعه

Fig 1. Location of the study area

پرتواتر است. برای این که میان دو متغیر با تناوب t و τ ارتباط ایجاد شود، از ضریب S استفاده شده است. ضریب S کسری از فاصله زمانی پرتناوب t و $t-1$ است به طوری که $m = \frac{1}{S}$ مشخص می کند که متغیرهای سری زمانی پرتناوب X_t در این فاصله زمانی چند بار مورد مشاهده قرار گرفته است. بنابراین $t = \tau \cdot m$ بوده و در نتیجه، y_t به تعداد m بار کمتر از داده های سری زمانی x_t ظاهر می شود. متغیری که داده های ماهانه را دارا است، متغیر پرتواتر و متغیری که داده های فصلی را در بردارد، متغیر کم تواتر است (Nofaresti et al., 2018). یک رگرسیون ساده MIDAS با توجه به متغیر توضیح دهنده پرتواتر و وقفه هایش به صورت رابطه ۱ بیان شده است:

$$y_t = C_0 + \sum_{j=0}^m w(j; \theta) \cdot L^j t_x^{(m)} + u_t \quad (1)$$

که در آن، y_t متغیر وابسته با تواتر پایین، C_0 عرض از مبدا و m تعداد مشاهدات متغیر پرتواتر در یک دوره از متغیر کم تواتر است.

۲-۲- مبانی مدل رگرسیونی MIDAS

در ابتدا، مدل های رگرسیون داده های ترکیبی با تواتر متفاوت (MIDAS) توسط Klein & Sojo (1989) معرفی شدند. این مدل ها به منظور استفاده از داده های با فرکانس های زمانی مختلف در یک رگرسیون توسعه یافتند. در این راستا از این مدل ها توسط Ghysels et al. (2004) بهره گیری شد و سپس در ادامه توسط Ghysels et al. (2007) گسترش یافت. این روش این امکان را فراهم می آورد تا از متغیرهای با تواتر زمانی مختلف، مانند داده های فصلی، ماهانه و هفتگی و ... بتوانند در کنار هم در یک معادله رگرسیونی قرار گیرند. نکته مهم وجود متغیرهای توضیح دهنده با تواتر زیاد برای توضیح متغیر وابسته کم تواتر در این است که به محض انتشار داده های جدیدی برای متغیرهای پرتواتر می توان در مقدار پیش بینی متغیر کم تواتر تجدیدنظر کرد (Nofaresti & Bayat, 2016).

برای معرفی این الگو، ابتدا به نحوه نمادگذاری متغیرهایی پرداخته می شود که از تواترهای متفاوتی برخوردارند. فرض کنید $\{y\}$ و $\{X_t\}$ دو سری زمانی پایا با تواترهای مختلف باشند، به گونه ای که y_t متغیر وابسته و X_t متغیر توزیع دهنده است. در این چارچوب، t بیانگر واحد زمانی مربوط به متغیر کم تواتر و τ نشان دهنده واحد زمانی متغیر

$$w(j; \theta) = \frac{\varphi(j; \theta)}{\sum_{j=1}^{\max} \varphi(j; \theta)} \quad (2)$$

طبق حداکثر تعداد وقفه‌ها (jmax)، θ توابع وزن‌دهی از تواتری به تواتر دیگر و از متغیری به متغیری دیگر، می‌تواند متفاوت باشد. در توابع وزن‌دهی که به صورت رابطه ۲ می‌باشند، پارامترهای j و θ که به ترتیب شمارنده وقفه‌ها و برداری حاوی یک یا چند θ است، وزن‌هایی غیرمنفی ایجاد می‌کنند و برای مشخص کردن مقدار ضریب متغیر پرتواتر و وقفه‌هایش (β)، از فرض برابر واحد بودن مجموع وزن‌های ایجاد شده توسط این تابع استفاده می‌کنند که به صورت رابطه (۳) نمایش داده می‌شود (Noforesti & Bayat, 2016).

$$\sum_{j=0}^{\max} w(j; \theta) \cdot L_m^j(\alpha) = 1 \quad (3)$$

۲-۴- مدل خودرگرسیونی با وقفه‌های توزیعی ARDL^۶

روش ARDL توسط Pesaran & Shin (1995) به منظور بررسی رابطه هم‌جمعی و بلندمدت بین متغیرها ارائه شده است. این روش، مزیت‌های زیادی نسبت به سایر روش‌های مشابه دارد. مهم‌ترین مزیت روش ARDL، قابلیت استفاده از آن برای بررسی روابط بین متغیرها، صرف‌نظر از ایستا یا نا ایستا بودن آنهاست. همچنین در این روش، علاوه بر امکان محاسبه روابط بلندمدت بین متغیرها، امکان محاسبه روابط کوتاه‌مدت نیز وجود دارد. ضمن آنکه سرعت تعدیل عدم تعادل کوتاه‌مدت در هر دوره، برای رسیدن به تعادل بلندمدت نیز قابل محاسبه است.

یک مدل الگوی خودرگرسیونی با وقفه‌های توزیعی به‌طور کلی به صورت $ARDL(p_1, q_1, q_1, \dots, q_k)$ نشان داده می‌شود. به‌طور مشخص اگر Y_t ، متغیر وابسته و X_t ، متغیر توضیحی باشد K تعداد متغیر توضیحی به کار گرفته شده در مدل بوده و مدل ARDL به صورت رابطه ۴ خواهد بود:

$$a(L, P)Y_t = a_0 + \sum_{i=1}^k \beta_i(L, q_i)X_{i,t} + U_t \quad (4)$$

رابطه ۴ رابطه پویای بین متغیرها را نشان می‌دهد، به‌طوری که در آن:

$$a(L, q_i) = 1 - a_1 L^2 - a_2 L^2 - \dots - a_p L^p \quad (5)$$

$$(L, q_i) = \beta_{i0} - \beta_{i1} L + \dots + \beta_{iq} L^q \quad (6)$$

در رابطه ۱ تابع وزن‌دهی $w(j; \theta)$ ، بیانگر یک‌چند جمله‌ای برای اعمال وزن‌هایی خاص به وقفه‌های گسترده $x\tau$ و l/m عملگر وقفه‌ها است. β وقفه‌های متغیر پرتواتر می‌باشد. این تابع بر اساس پارامترهای j و θ که به ترتیب شمارنده وقفه‌ها و برداری حاوی یک تا چند پارامتر θ می‌باشد، شکل می‌گیرد (Noforesti et al., 2018).

عبارت L_m^j (عملگر وقفه)، وقفه‌های متغیر با تواتر بالا را با استفاده از m (تعداد دوره‌های زمانی در یک دوره با تواتر پایین) مدل‌سازی می‌کند. همچنین $t_x^{(m)}$ متغیر توضیحی با تواتر بالا و u_t جمله خطا یا اختلال است.

برای مدل‌سازی به روش MIDAS، از داده‌های فصلی دبی و داده‌های ماهانه بارش در بازه زمانی ۱۳۸۵ تا ۱۴۰۱ استفاده شد. جهت بررسی عملکرد مدل و اطمینان از قابلیت تعمیم آن، داده‌ها به دو بخش شامل ۷۰ درصد به عنوان مجموعه آموزش برای برآورد پارامترهای مدل و ۳۰ درصد به عنوان مجموعه اعتبارسنجی تقسیم شدند. برای ارزیابی عملکرد مدل بر روی داده‌هایی مستقل از فرایند آموزش، فرایند اعتبارسنجی، با آزمون مدل روی داده‌هایی مستقل از مجموعه آموزش، به شناسایی و کاهش بیش‌برازش^۲ استفاده شد. بیش‌برازش زمانی رخ می‌دهد که مدل به جای یادگیری الگوهای کلی، تنها به حفظ جزئیات خاص مجموعه آموزش می‌پردازد و در نتیجه در پیش‌بینی داده‌های جدید عملکرد ضعیفی دارد. با استفاده از اعتبارسنجی، می‌توان اطمینان حاصل کرد که مدل الگوهای تعمیم‌پذیر را یاد گرفته و دقت آن در پیش‌بینی مقادیر آتی بهبود یافته است. این مرحله نقش مهمی در ارزیابی واقعی دقت مدل و تضمین قابلیت اعتماد آن در کاربردهای عملی را دارد.

در این مطالعه، دقت مدل با استفاده از معیارهایی مانند میانگین مربعات خطا (RMSE)، میانگین قدرمطلق خطا (MAE) و ضریب تبیین (R^2) مورد ارزیابی قرار گرفت. استفاده از اعتبارسنجی به این روش موجب شد تا اطمینان حاصل شود که مدل طراحی شده از قابلیت تعمیم مناسبی برخوردار بوده و در پیش‌بینی‌های زمانی عملکرد قابل قبولی داراست.

۲-۳- تابع وزن‌دهی

تابع وزن‌دهی $w(j; \theta)$ که هسته مرکزی MIDAS است، بیان‌کننده یک چندجمله‌ای برای اعمال وزن‌های خاص به وقفه گسترده $x\tau$ است. (Ghysels and Ozkan (2015) توابع وزن‌دهی MIDAS را همچون تابع وزن‌دهی آلمون^۳، آلمون نمایی^۴ و بتا^۵ معرفی کرده که فرم کلی آن‌ها به صورت رابطه ۲ می‌باشد:

^۴ Normalized exponential Almon lag polynomial
^۵ Normalized beta probability density function
^۶ Autoregressive Distributed Lag

^۱ Weighting Function
^۲ Overfitting
^۳ Almon lag polynomial specification

پیش‌بینی‌شده به مقادیر واقعی متغیر موردنظر را اندازه‌گیری می‌کنند که از جمله این شاخص‌ها شاخص ضریب تبیین (R^2) ، جذر میانگین مربعات خطا $(RMSE)^3$ ، میانگین قدرمطلق درصد خطا $(MAPE)^4$ می‌توان اشاره کرد که به صورت رابطه ۱۰ تا ۱۳ قابل تعریف هستند.

۲-۶-۱- ضریب تبیین

ضریب تبیین (R^2) میزان تناسب مدل را با داده‌ها نشان می‌دهد و بیانگر درصد واریانس متغیر وابسته است که توسط متغیرهای مستقل مدل قابل توضیح است. مقدار R^2 بین صفر و یک قرار دارد و هرچه این مقدار به یک نزدیک‌تر باشد، مدل تولنایی بیشتری در تبیین تغییرات داده‌ها دارد و به صورت رابطه ۱۰ بیان می‌گردد:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_t - \hat{y}_t)^2}{\sum_{i=1}^n (y_t - \bar{y}_t)^2} \quad (10)$$

۲-۶-۲- ضریب تبیین تعدیل شده

ضریب تبیین تعدیل شده $R^2_{adjusted}$ تأثیر واقعی متغیرهای مستقل مدل بر متغیرهای وابسته می‌باشد این ضریب نسخه اصلاح شده R^2 است که برای تعداد متغیرهای وارد شده در مدل تعدیل شده و برای مقایسه مدل‌هایی با تعداد متغیرهای مختلف مناسب‌تر است. ورود متغیرهای غیرمرتبط معمولاً باعث کاهش مقدار $R^2_{adjusted}$ می‌شود، بنابراین این شاخص معیار بهتری برای ارزیابی واقعی کارایی مدل محسوب می‌شود. این مدل به صورت رابطه ۱۱ ارائه می‌گردد:

$$R^2_{adjusted} = 1 - \frac{(1 - R^2)(N - 1)}{N - P - 1} \quad (11)$$

که در رابطه بالا، N تعداد کل مشاهدات، P تعداد متغیرهای پیش‌بینی، R^2 ضریب تبیین و $R^2_{adjusted}$ ضریب تبیین تعدیل شده است. تفاوت ضریب تبیین و ضریب تبیین تعدیل شده این است که شاخص ضریب تبیین با فرض تأثیر همه متغیرهای مستقل بر متغیر وابسته است در حالی که در ضریب تبیین تعدیل شده این درصد نشان‌دهنده تأثیر واقعی متغیرهای مستقل بر متغیر وابسته (نه همه متغیرهای مستقل) می‌باشد. تفاوت دیگر این دو شاخص این است که مناسب بودن متغیرها برای مدل، توسط ضریب تبیین حتی با وجود مقدار بالای این شاخص قابل تشخیص نیست در صورتی که می‌توان به مقدار برآورد شده ضریب تبیین تعدیل شده اعتماد کرد (Gujarati & Porter, 2009).

که در آن، a_0 مقدار ثابت، L عملگر وقفه، P تعداد وقفه‌های به کار رفته برای متغیر وابسته (Y_t) و q تعداد وقفه‌های مورد استفاده برای متغیرهای مستقل $(X_{i,t})$ است.

۲-۵- مدل GARCH

یکی از محدودیت‌های مدل ARCH این است که در سری‌های زمانی که در آن‌ها واریانس خطا به صورت پویا تغییر می‌کند، مربع جملات خطا (باقی‌مانده‌ها) به تنهایی قادر به تبیین کامل واریانس شرطی نیستند. به همین دلیل، ایده جدیدی مطرح شد مبنی بر اینکه اجزای واریانس شرطی جملات خطا نیز در فرایند توضیح و پیش‌بینی واریانس خطا مورد استفاده قرار گیرند (Engle and Kroner, 1995). این ایده سال ۱۹۸۶ در پژوهشی با عنوان " واریانس ناهمسانی شرطی خودرگرسیون تعمیم‌یافته " منتشر شد که نقطه شروعی برای نسل جدیدی از مدل‌های GARCH بود (Bollerslev, 1986). مدل عمومی $GARCH(p,q)$ به صورت رابطه ۷ است:

$$y_t = a + \beta X_t + u_t \quad (7)$$

$$u_t | \Omega_t \sim iid N(0, h_t)$$

$$\sigma_t^2 = \omega + \sum_{j=1}^q a_j \varepsilon_{t-j}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2 \quad (8)$$

رابطه ۸ بیان می‌کند که مقدار پارامتر مقیاس واریانس (σ_t^2) به مقادیر گذشته نوسانات که با مجذور باقیمانده وقفه‌دار نشان داده شده و همچنین مقادیر گذشته به خود آن متغیر که به وسیله عناصر با وقفه σ_t^2 نشان داده شده است، بستگی دارد.

برای $p=0$ مدل GARCH به یک مدل ARCH(1) تقلیل می‌یابد. ساده‌ترین مدل $GARCH(q,p)$ ، مدل $GARCH(1,1)$ است که در آن معادله واریانس به صورت رابطه ۹ می‌باشد این روند تصریح مدل، غالباً عملکرد مناسبی داشته و برآورد آن ساده است.

$$\sigma_t^2 = \omega + \beta_1 \sigma_{t-1}^2 + a_1 \varepsilon_{t-1}^2 \quad (9)$$

۲-۶- آماره ارزیابی

قبل از به کارگیری هر مدل، لازم است اعتبار و دقت آن به صورت کمی و قابل سنجش ارزیابی شود تا مشخص گردد مدل موردنظر تا چه میزان قادر است با استفاده از داده‌های متغیرهای توضیح‌دهنده، پیش‌بینی دقیقی برای متغیر وابسته ارائه دهد. برای این منظور از شاخص‌های مختلفی استفاده می‌شود که نزدیکی مقادیر

³ Root Mean Square Error.
⁴ Mean Absolute Percentage Error

¹ Generalized Autoregressive Conditional Heteroskedasticity
² Coefficient Of Determination.

استاندارد پایین‌تر بیانگر برآورد دقیق‌تر ضریب است. آماره t ، به‌عنوان نسبت ضریب به خطای استاندارد آن تعریف می‌شود و برای آزمون معناداری ضریب به کار می‌رود. مقدار مطلق بالای این آماره نشان‌دهنده احتمال بالاتر معنی‌داری آماری ضریب است که فرض صفر مبنی بر عدم وجود رابطه بین متغیر مستقل و وابسته را به چالش می‌کشد. مقدار احتمال بیانگر میزان احتمال وقوع نتایج مشاهده شده تحت فرض صفر است. در صورتی که این مقدار کمتر از سطح معناداری تعریف شده (معمولاً ۰/۰۵) باشد، فرض صفر رد و ضریب مربوطه به‌صورت معنادار شناخته می‌شود. به بیان ساده، p-value نشان می‌دهد که ضریب موردنظر به‌طور تصادفی به دست نیامده و اثر آن واقعی است. آزمون دوربین - واتسون^۴ برای شناسایی خودهمبستگی در باقیمانده‌های مدل رگرسیون به کار می‌رود. این آزمون مقدار عددی بین صفر تا چهار دارد که مقدار نزدیک به دو نشان‌دهنده فقدان خودهمبستگی است، در حالی که مقادیر نزدیک به صفر یا چهار به ترتیب نمایانگر وجود خودهمبستگی مثبت یا منفی هستند. وجود خودهمبستگی می‌تواند منجر به برآوردهای نادرست و کاهش اعتبار نتایج مدل شود از این‌رو شناسایی و اصلاح آن از اهمیت بالایی برخوردار است.

در این پژوهش، برای تحلیل داده‌ها و انجام آزمون‌های مربوط به آن‌ها از نرم‌افزار EViews 10 استفاده شد. این نرم‌افزار یکی از ابزارهای پرکاربرد در تحلیل آماری است که امکان برآورد مدل‌ها، انجام آزمون‌های مختلف و تحلیل داده‌های سری زمانی را فراهم می‌کند.

۳- نتایج و بحث

در این پژوهش، از سری زمانی رواناب در مقیاس فصلی و سری زمانی بارش در مقیاس ماهانه برای مدل MIDAS و همچنین سری زمانی رواناب و بارش در مقیاس فصلی برای مدل‌های ARDL و GARCH استفاده شده است که این متغیرها به‌عنوان ورودی به نرم‌افزار EViews 10 معرفی شده‌اند. داده‌های مورد استفاده مربوط به دوره آماری ۱۷ ساله منطقه بهرام‌جو می‌باشند. شکل‌های ۲ و ۳ به ترتیب نمودار داده‌های مشاهداتی بارش ماهانه و رواناب فصلی این منطقه را نمایش می‌دهند. شکل ۲ تغییرات بارش را در طول زمان به‌صورت ماهانه و الگوهای ماهانه بارش مربوط به منطقه حوضه بهرام‌جو را نمایش می‌دهد. نمودار بارش الگوهای دقیق‌تری از تغییرات بارش در طول سال ارائه می‌دهد که به تشخیص فصل‌های پر باران و فصول خشک کمک می‌کند.

نمودار رواناب فصلی شکل ۳ امکان بررسی تغییرات دبی آب در هر فصل سال طی ۱۷ سال گذشته را فراهم می‌آورد و می‌تواند الگوهای موسمی، روندهای تدریجی و نوسانات سالانه را نمایان سازد این

۳-۶-۲- جذر میانگین مربعات خطا

جذر میانگین مربع خطا به‌منظور سنجش میزان خطای مدل مورد استفاده قرار می‌گیرد و میزان اختلاف داده واقعی و داده‌های برآورد شده را محاسبه می‌کند. هر چه این میزان به صفر نزدیک‌تر باشد، نشان‌دهنده خطای کمتر و قابل قبول بودن مدل است این معیار به‌صورت رابطه ۱۲ است:

$$RMSE = \sqrt{\frac{1}{n} \sum (y_t - \hat{y}_t)^2} \quad (12)$$

در این رابطه، n بیانگر تعداد داده‌های مورد نظر مورد نظر سری است.

۳-۶-۴- میانگین قدرمطلق درصد خطا

نشان‌دهنده میانگین درصد خطای مطلق (MAPE) است و به‌صورت درصد بیان می‌شود. این شاخص میزان خطای مطلق مدل را نسبت به مقادیر واقعی به‌صورت درصدی نشان می‌دهد و به‌صورت رابطه ۱۳ نمایش داده می‌شود:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_t - y_t}{y_t} \right| \times 100 \quad (13)$$

در تمام روابط فوق y_t مقدار واقعی متغیر مورد نظر و \hat{y}_t مقدار پیش‌بینی شده توسط الگوی تصریح شده می‌باشد و n نشانگر تعداد کل نمونه‌های سری می‌باشد. MAPE یکی از معیارهای ارزیابی خطا در پیش‌بینی یا مدل‌سازی است. این شاخص برای سنجش درصد خطای پیش‌بینی نسبت به مقادیر واقعی استفاده می‌شود. جهت اختصار سایر پارامترهای مورد نیاز در ارزیابی مدل‌ها در جدول (۱) آورده شده است.

جدول ۱- پارامترهای مورد نیاز برای ارزیابی مدل رگرسیونی

Table 1. Parameters required to evaluate the regression model

نام پارامتر The name of the parameter	فرمول محاسباتی Calculation formula
ضریب رگرسیون ^۱ Regression coefficient	$\beta_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2}$
خطای استاندارد ^۲ Standard error	$SE(\beta_1) = \sqrt{\frac{\hat{\sigma}^2}{\sum (x_i - \bar{x})^2}}$
آماره t	$T = \frac{\beta_1}{SE(\beta_1)}$
مقدار احتمال ^۳ Probability value	$P = 2 \times [1 - F_t(t_{stat} ; d_f)]$

که در آن، β_1 بیانگر میزان تأثیر متغیرهای مستقل بر متغیر وابسته است. $SE(\beta_1)$ مربوط به هر ضریب، نشان‌دهنده میزان عدم قطعیت یا پراکندگی تخمین آن است. همچنین y_i و x_i مقادیر مشاهده شده، \bar{y} و \bar{x} میانگین‌ها و $\hat{\sigma}^2$ واریانس باقی مانده‌های مدل می‌باشد خطای

^۳ prob


^۴ Durbin.watson

^۱ Coefficient

^۲ Std.Error


به‌طور کلی، تحلیل دقیق این داده‌ها و استفاده از مدل‌های مناسب، پایه و اساس انتخاب و توسعه مدل‌های پیش‌بینی مانند ARDL، MIDAS و GARCH بوده و می‌تواند در مدیریت منابع آبی، برنامه‌ریزی کشاورزی و اتخاذ تصمیمات عملیاتی مرتبط بسیار مفید باشد.

اطلاعات پایه و اساس تحلیل دقیق تر رفتار هیدرولوژیکی حوضه هستند و به شناسایی رابطه بین بارش و رواناب و اثرات تغییرات اقلیمی کمک می‌کنند. همچنین، این نمودارها امکان کشف نوسانات غیرمعمول و رخدادهای اقلیمی خاص را فراهم می‌آورند که در مدل‌سازی و پیش‌بینی‌های آینده تأثیرگذار خواهند بود.



شکل ۲- نمودار داده‌های بارش ماهانه حوضه بهرام جو در طول دوره آماری ۱۴۰۱-۱۳۸۵

Fig 2. Monthly precipitation data chart for the Bahramjoo basin during the statistical period 2006-2023



شکل ۳- نمودار داده‌های رواناب فصلی حوضه بهرام جو در طول دوره آماری ۱۴۰۱-۱۳۸۵

Fig 3. Seasonal runoff data chart for the Bahramjoo basin during the statistical period 2006-2023

می‌کند که تأثیر تغییرات متغیرهای مستقل بر متغیر وابسته به ویژه در داده‌های با تواتر مختلف مورد بررسی قرار گیرد جدول ۲ نتایج

۳-۱- مدل MIDAS

مدل‌سازی به روش MIDAS یک روش کارآمد در تحلیل رواناب بین متغیرها است. زیرا استفاده از مدل MIDAS این امکان را فراهم

برآورد مدل MIDAS را با استفاده از توابع وزن‌دهی مختلف نمایش می‌دهد.

جدول ۲- نتایج حاصل از برآورد مدل MIDAS با توابع وزن‌دهی گوناگون

Table 2. Results from estimating the MIDAS model with different weighting functions

Durbin.watson	R ² _{adjusted}	R ²	Prob	t.statistic	Std.Error	Coefficient	تابع وزن‌دهی
۲/۲۵	۰/۷۰	۰/۷۰	۰/۰۰	۴/۱۷	۰/۰۶	۰/۲۶	Step
۲/۲۶	۰/۷۶	۰/۷۶	۰/۰۰	۳/۷۸	۰/۰۵	۰/۲۱	PDL Almon
۲/۲۱	۰/۷۷	۰/۷۷	۰/۰۰	۳/۸۵	۰/۰۵	۰/۲۱	EXP Almon
۲/۳۳	۰/۷۵	۰/۷۵	۰/۰۰	۳/۹۹	۰/۰۶	۰/۲۲	Beta
۱/۹۹	۰/۷۹	۰/۷۹	۰/۰۰	۴/۲۶	۰/۰۵	۰/۲۳	U-MIDAS

بهتری نسبت به سایر توابع وزن‌دهی ارائه می‌دهد. مقدار آماره دوربین واتسون برای این تابع نزدیک به عدد ۲ است که نشان‌دهنده عدم وجود خودهمبستگی در باقی‌مانده‌های مدل می‌باشد. به‌طور کلی، می‌توان گفت تابع وزن‌دهی U-MIDAS در این مرحله از دقت و عملکرد بالاتری نسبت به سایر توابع برخوردار است. در مرحله بعدی مدل‌سازی، به بررسی پارامترهای سنجش دقت مدل در مرحله پیش‌بینی پرداخته شده است. جدول ۳ شامل معیارهای مختلف دقت پیش‌بینی برای هر یک از توابع وزن‌دهی می‌باشد.

در این برآورد، روش‌ها و تعاریف مربوط به توابع وزن‌دهی گوناگون به کار گرفته شده است. نتایج نشان می‌دهد که تمامی توابع وزن‌دهی در سطح معناداری بسیار بالایی قرار دارند. همچنین، با بررسی معیارهایی نظیر ضریب تبیین R² و آماره دوربین - واتسون که به تشخیص هم‌خطی و خودهمبستگی باقی‌مانده‌ها کمک می‌کند، مشخص می‌شود که تابع وزن‌دهی U-MIDAS با داشتن آماره t برابر ۴/۲۶، بالاترین سطح معنی‌داری را داراست. این تابع همچنین با ضریب تبیین و ضریب تبیین تعدیل‌شده‌ای برابر با ۰/۷۹، عملکرد

جدول ۳- نتایج دقت پیش‌بینی مدل MIDAS


Table 3. Results of prediction accuracy of the MIDAS model

SMAPE	MAPE	MAE (m ³ /s)	RMSE (m ³ /s)	تابع وزن‌دهی
۳۵/۸۲	۳۱/۹۵	۰/۵۴	۰/۷۰	Step
۳۸/۳۴	۴۰/۱۵	۰/۵۵	۰/۶۹	PDL Almon
۳۷/۶۸	۴۰/۴۶	۰/۵۳	۰/۶۸	EXP Almon
۳۷/۶۴	۳۸/۳۰	۰/۵۴	۰/۶۹	Beta
۳۲/۹۸	۳۲/۶۲	۰/۴۷	۰/۶۲	U-Midas

مدل نسبت به سایر مدل‌ها می‌باشد. در نهایت با توجه به نتایج ارائه شده در جداول ۲ و ۳ می‌توان نتیجه‌گیری کرد که تابع وزن‌دهی U-Midas از مدل MIDAS نسبت به سایر مدل‌ها عملکرد بهتری دارد. این مدل در مرحله تخمین با داشتن بالاترین ضریب تبیین و ضریب تبیین تعدیل شده و نیز در مرحله پیش‌بینی با داشتن کمترین مقادیر خطا دقت بیشتری را نشان می‌دهد؛ بنابراین، تابع وزن‌دهی U-

جدول ۳ نشان می‌دهد که مدل U-MIDAS در تمامی معیارهای دقت پیش‌بینی بهترین عملکرد را دارد. مقدار RMSE برای مدل U-MIDAS برابر با ۰/۶۲ است که نشان‌دهنده کمترین خطای ریشه میانگین مربع در پیش‌بینی‌هاست. همچنین، MAE این مدل برابر با ۰/۴۷ است که نشان‌دهنده کمترین میانگین خطای مطلق در پیش‌بینی‌ها می‌باشد. معیارهای MAPE و SMAPE نیز به ترتیب برابر با ۳۲/۹۸ و ۳۲/۶۲ هستند که نشان‌دهنده خطای نسبی کمتر این

MIDAS از مدل MIDAS به عنوان مدل بهینه برای استفاده در پیش‌بینی‌های آبی پیشنهاد می‌شود.

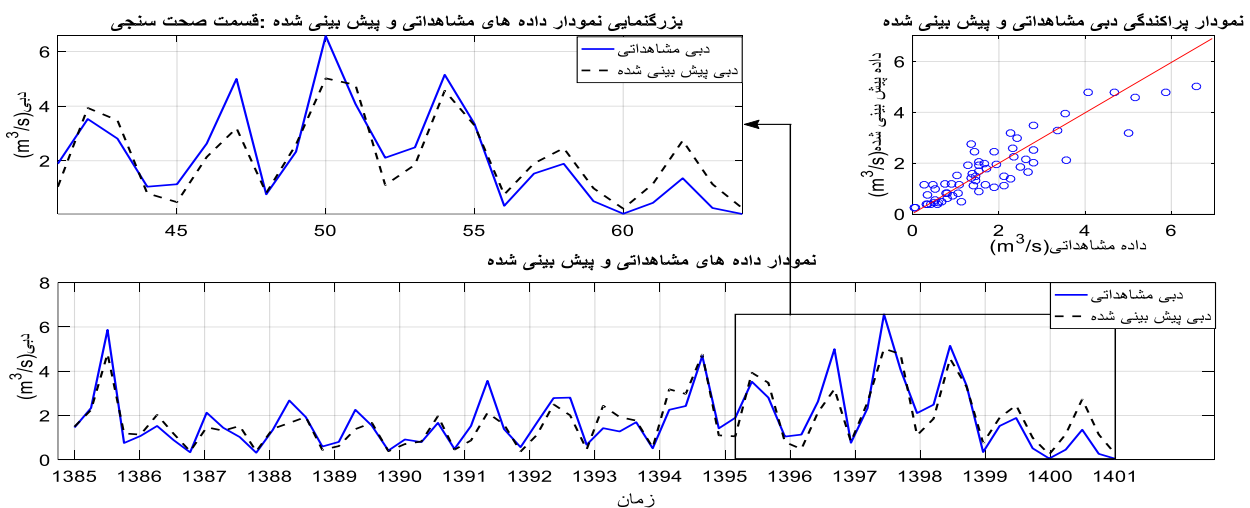


شکل ۴- نمودار داده‌های مشاهداتی و پیش‌بینی شده رواناب فصلی با مدل MIDAS با تابع وزن‌دهی U-MIDAS

Fig 4. Graph of observed and predicted seasonal runoff data with the MIDAS model with the U-MIDAS weighting function

نمودار داده‌های مشاهداتی و پیش‌بینی شده در مرحله صحت‌سنجی و همچنین نمودار پراکنش آن‌ها را برای تابع وزن‌دهی U-MIDAS نشان می‌دهد. نزدیکی مقادیر دو نمودار مشاهداتی و پیش‌بینی شده در بسیاری از قسمت‌ها در شکل ۵ نشان‌دهنده دقت این مدل می‌باشد.

شکل ۴ نشان‌دهنده تغییرات رواناب فصلی برای داده‌های مشاهداتی و پیش‌بینی شده توسط مدل MIDAS با استفاده از توابع وزن‌دهی U-MIDAS است. با توجه به نتایج حاصل از برآورد ضرایب الگوی MIDAS که در جدول ۲ آمده است، توابع وزن‌دهی U-MIDAS عملکرد بهتری نسبت به سایر توابع داشته است. شکل ۵



شکل ۵- نمودار داده‌های مشاهداتی و پیش‌بینی شده مدل MIDAS در مرحله صحت‌سنجی و واسنجی

Fig 5. Graph of observational and predicted data of the MIDAS model in the validation and calibration stage

فراهم می‌کند که تأثیر تغییرات متغیرهای مستقل بر متغیر وابسته به طور جامع و گسترده مورد بررسی قرار گیرد و با توجه به تأخیرهای زمانی، تأثیرات کوتاه‌مدت و بلندمدت را می‌توان ارزیابی نمود. در این مدل پس از وارد کردن اطلاعات بارش و دبی به صورت فصلی به

۲-۳- نتایج مدل ARDL

مدل‌سازی به روش ARDL یک روش انعطاف‌پذیر و پرکاربرد در تحلیل روابط بین متغیرها است. استفاده از مدل ARDL این امکان را

مختلف بر متغیر وابسته فراهم می‌کنند. ارزیابی دقیق‌تر این نتایج می‌تواند به درک بهتری از رابطه بین متغیرها و پیش‌بینی‌های دقیق‌تر برای آینده کمک کند. همچنین نتایج برآورد مدل ARDL شامل ضریب تبیین برابر با ۰/۶۶ و ضریب تبیین تعدیل شده برابر با ۰/۶۵ نشان می‌دهند که مدل ARDL قادر است ۶۶٪ از تغییرات متغیر وابسته را توضیح دهد. همچنین آماره دوربین واتسون برابر با ۲/۳۸ است که نشان‌دهنده عدم خودهمبستگی در باقی‌مانده‌های مدل می‌باشد و به اعتبار مدل افزوده است.


نرم‌افزار و انتخاب مدل ARDL در مرحله برآورد ضرایب الگوی مدل خروجی‌های نرم‌افزار به صورت جدول ۴ است که شامل ضرایب تخمینی، خطاهای استاندارد، آماره‌های t و احتمال‌های مربوط به هر ضریب می‌باشد.

نتایج جدول ۴ نشان می‌دهند که متغیرهای مستقل r (بارش) و متغیر وابسته q (دبی) از معناداری بالایی برخوردار هستند. این نتایج کاربردی بوده چرا که اطلاعات مهمی را درباره تأثیر متغیرهای

جدول ۴- نتایج برآورد مدل ARDL

Table 4. ARDL model estimation Results

Prob	t.statistic	Std.Error	Coefficient	Variable
۰/۰۰	۵/۱۵	۰/۰۶	۰/۳۱	Q
۰/۰۰	۱۱/۹۷	۰/۰۰	۰/۰۳	R



شکل ۶- نمودار سری داده‌های مشاهده‌ای و پیش‌بینی شده رواناب توسط مدل ARDL

Figure 6-Graph of observed and predicted runoff data series by the ARDL model

دقت این مدل در پیش‌بینی است. جدول ۵ پارامترهای سنجش دقت مدل ARDL را در مرحله برآورد نشان می‌دهد.

در شکل ۶ نمودار داده‌های مشاهده‌ای و پیش‌بینی شده رواناب توسط مدل ARDL به تصویر کشیده شده است. تطابق نمودار در حالت مشاهده‌ای و پیش‌بینی شده در بسیاری از نقاط نشان‌دهنده

جدول ۵- نتایج دقت پیش‌بینی مدل ARDL

Table 5. Results of prediction accuracy of the ARDL model

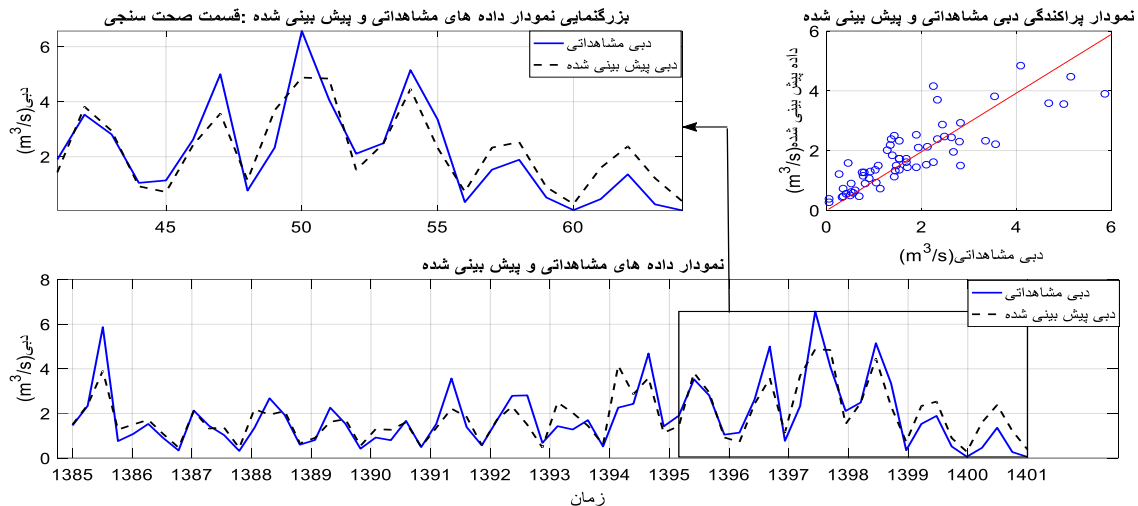
SMape	MAPE	MAE(m ³ /s)	RMSE(m ³ /s)	مدل
۳۳/۵۴	۲۹/۶۹	۰/۵۳	۰/۷۱	ARDL

همچنین، مقادیر سنجه‌های خطا نشان‌دهنده درصد خطای نسبتاً پایین مدل در پیش‌بینی مقادیر واقعی هستند. به‌طور کلی، این

بر اساس جدول ۵ این مدل دارای دقت مناسبی در پیش‌بینی است. مقدار کم RMSE و MAE بیانگر خطای پایین پیش‌بینی‌هاست.

برای مدل ARDL را نشان می‌دهد. تطابق دو نمودار در بسیاری از قسمت‌ها نشان‌دهنده دقت این مدل و توانایی آن در پیش‌بینی می‌باشد.

پارامترها حاکی از توانایی مدل ARDL در ارائه پیش‌بینی‌های دقیق و قابل‌اعتماد هستند. شکل ۷ نمودار داده‌های مشاهداتی و پیش‌بینی شده در مراحل واسنجی و صحت‌سنجی و همچنین نمودار پراکنش



شکل ۷- نمودار داده‌های مشاهداتی و پیش‌بینی شده مدل ARDL در مرحله صحت‌سنجی و واسنجی

Fig 7. Graph of observational and predicted data of the ARDL model in the validation and calibration stage

جدول ۶ نتایج برآورد مدل GARCH برای متغیر مستقل R و عرض از مبدأ C که شامل خطاهای استاندارد، آماره‌های t و مقادیر احتمال برای هر متغیر را نشان می‌دهد.

۳-۳- نتایج مدل GARCH

این مدل نیز شامل دو مرحله برآورد مدل (واسنجی) و انجام پیش‌بینی بر اساس مدل آموزش یافته (صحت‌سنجی) می‌باشد.

جدول ۶- نتایج برآورد مدل GARCH

Table 6. GARCH model estimation results

Prob	t.statistic	Std.Error	Coefficient	Variable
۰/۰۰	۸/۰۶	۰/۰۰	۰/۰۲	R
۰/۰۰	۲/۹۰	۰/۲۵	۰/۷۳	C


تطابق داده‌های پیش‌بینی شده با داده‌های مشاهداتی در برخی نقاط خطاهای جزئی این مدل در پیش‌بینی را نشان می‌دهد. جدول ۷ نتایج دقت پیش‌بینی مدل را نمایش می‌دهد. به‌طور کلی، مقادیر پارامترهای ارائه شده در جدول ۷ نشان می‌دهد که مدل GARCH در مرحله پیش‌بینی دارای دقت متوسطی است. مقادیر نسبتاً پایین RMSE و MAE بیانگر دقت قابل‌قبول مدل در پیش‌بینی مقادیر واقعی می‌باشد. باین‌حال، مقادیر نسبتاً بالای MAPE و SMAPE نشان‌دهنده وجود خطاهای نسبی قابل‌توجه در برخی پیش‌بینی‌ها است. این نتایج حاکی از آن است که گرچه مدل توانایی پیش‌بینی دارد، اما اعمال بهبودهایی در ساختار مدل می‌تواند به کاهش خطاهای نسبی و افزایش دقت پیش‌بینی منجر شود. برای نمونه، می‌توان با به‌کارگیری مدل‌های ترکیبی، بهبود در تخمین پارامترها، یا اعمال تکنیک‌های بهینه‌سازی پارامترهای مدل، دقت پیش‌بینی را

نتایج جدول ۶ نشان می‌دهند که متغیر مورد بررسی تأثیر معنی‌داری در مدل دارد و تخمین‌ها به‌طور مناسبی از دقت بالای برخوردارند. از نتایج برآورد مدل ضریب تبیین برابر با ۰/۵۲ و ضریب تبیین تعدیل شده برابر با ۰/۵۱ است. این مقادیر نشان می‌دهند که مدل GARCH می‌تواند ۵۲٪ از تغییرات متغیر وابسته را توضیح دهد. آماره دوربین واتسون برابر با ۱/۶۶ است که نشان‌دهنده وجود احتمال خودهمبستگی در باقی‌مانده‌های مدل است و می‌تواند دقت مدل را تحت‌تأثیر قرار دهد.

شکل ۸ نمودار داده‌های مشاهداتی و پیش‌بینی شده توسط مدل GARCH را نشان می‌دهد. این نمودار تغییرات رواناب فصلی را برای داده‌های مشاهداتی و پیش‌بینی شده توسط مدل GARCH نمایش می‌دهد. با دقت در شکل ۸، می‌توان دریافت اگرچه مدل GARCH توانایی کافی در پیش‌بینی سری‌های زمانی را دارد، با این حال عدم

مشاهداتی و پیش‌بینی شده برای مدل GARCH را نشان می‌دهد. عدم تطابق دو نمودار در بعضی از قسمت‌ها نشان‌دهنده عدم دقت کافی این مدل در پیش‌بینی می‌باشد.

افزایش داد. همچنین، استفاده از مدل‌های پیچیده‌تر مانند GARCH چندمتغیره، یا ترکیب با روش‌های یادگیری ماشینی ممکن است کارایی مدل را در پیش‌بینی ارتقا دهد. شکل ۹ نمودار داده‌های



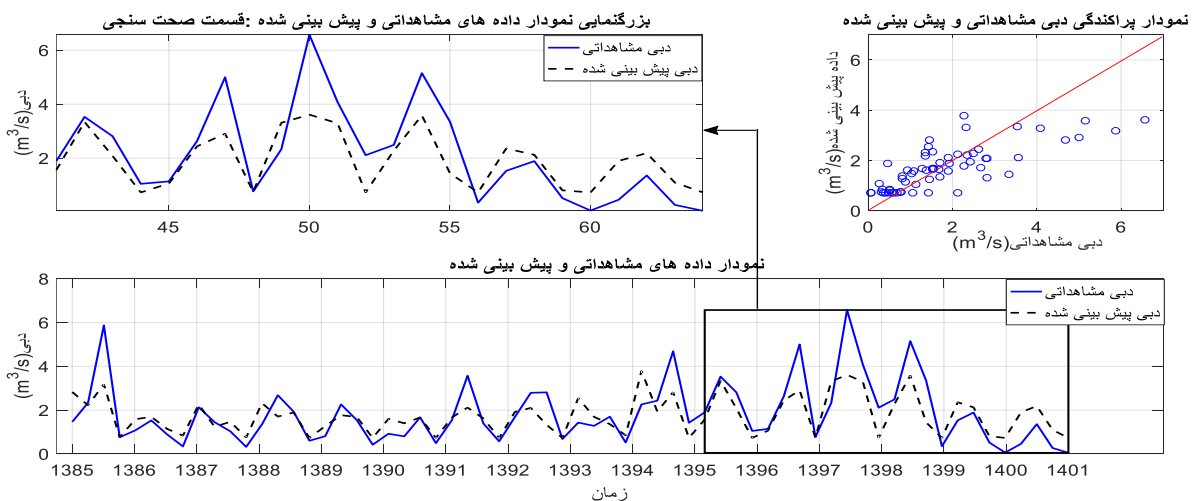
شکل ۸- نمودار سری داده‌های مشاهداتی و پیش‌بینی شده توسط مدل GARCH در مرحله پیش‌بینی

Fig 6. Graph of observed and predicted runoff data series by the GARCH model

جدول ۷- نتایج دقت پیش‌بینی مدل GARCH

Table 7. Results of prediction accuracy of the GARCH model

مدل	RMSE (m ³ /s)	MAE (m ³ /s)	MAPE	SMAPE
GARCH	۰/۹۳	۰/۶۷	۴۰/۲۰	۴۱/۸۸



شکل ۹- نمودار داده‌های مشاهداتی و پیش‌بینی شده مدل GARCH در مرحله صحت‌سنجی و واسنجی

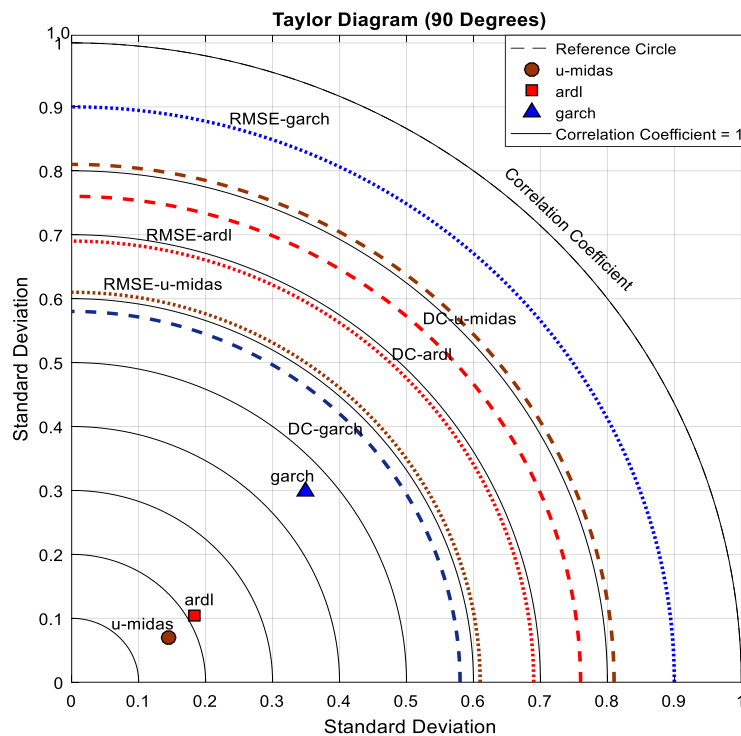
Fig 9. Graph of observational and predicted data of the GARCH model in the validation and calibration stage

معیار و ضریب همبستگی کار می‌کند. در این نمودار، مدل‌هایی که به نقطه مرجع نزدیک‌تر باشند، عملکرد بهتری دارند. در نمودار تیلور شکل ۱۰، هر مدل با استفاده از پارامترهای مختلف مورد ارزیابی قرار گرفته است. نقاط داده‌ها نشان‌دهنده انحراف معیار و ضریب همبستگی

۳-۴- تحلیل دقت مدل‌ها با استفاده از نمودار تیلور

مدل‌های ARDL، GARCH و MIDAS از جمله مدل‌های پرکاربرد در زمینه پیش‌بینی سری‌های زمانی هستند. نمودار تیلور ابزاری مفید برای مقایسه عملکرد این مدل‌ها است که با توجه به پارامترهای انحراف

مدل‌ها است، درحالی که خطوط نقطه‌چین نشان‌دهنده مقادیر RMSE و DC مربوط به هر مدل هستند.

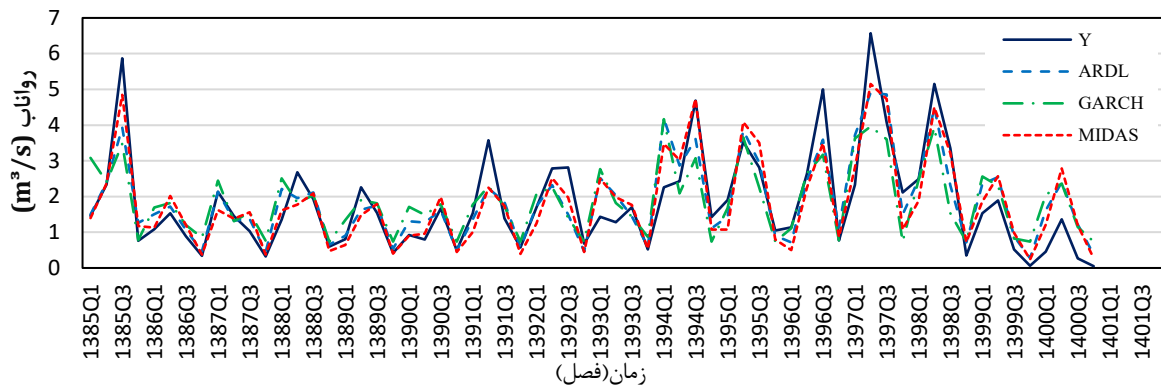


شکل ۱۰- نمودار تیلور مدل‌های ARDL، GARCH و U-Midas

Fig10. Taylor diagram of ARDL, GARCH and GARCH

انحراف معیار، عملکرد قلیل‌قبولی ارلته می‌دهد؛ اما هنوز از دقت مدل U-MIDAS پایین‌تر است. مدل GARCH نیز با بیشترین مقدار RMSE و انحراف معیار، ضعیف‌ترین عملکرد را در پیش‌بینی سری‌های زمانی داشته و ضریب همبستگی آن نیز از دو مدل دیگر کمتر است؛ بنابراین، نتایج نمودار تیلور به‌وضوح بیان می‌کند که استفاده از تابع وزن‌دهی U-MIDAS در مدل MIDAS باعث بهبود قابل‌توجهی در دقت پیش‌بینی‌ها می‌شود و این مدل به‌عنوان گزینه‌ای برتر برای تحلیل و پیش‌بینی سری‌های زمانی پیشنهاد می‌گردد. در نهایت، این پیش‌بینی‌ها را با داده‌های واقعی مقایسه گردید تا دقت و عملکرد هر مدل در پیش‌بینی سیلاب مورد ارزیابی قرار گیرد. نتایج به‌دست‌آمده از مدل‌سازی‌ها در شکل ۱۱ آورده شده است.

در نمودار تیلور شکل ۱۰، عملکرد تابع وزن‌دهی U-MIDAS از مدل MIDAS در پیش‌بینی سری‌های زمانی به‌وضوح بهتر از مدل‌های ARDL و GARCH نشان‌دهنده شده است. این نمودار که معیارهای مختلفی از جمله ضریب همبستگی، ریشه میانگین مربعات خطا و انحراف معیار را به‌صورت هم‌زمان نمایش می‌دهد، نشان می‌دهد که مدل U-MIDAS با کمترین مقدار RMSE و انحراف معیار، نزدیک‌ترین مدل به نقطه مرجع است. این نزدیکی به نقطه مرجع در نمودار تیلور به معنای دقت بالاتر و خطای کمتر در پیش‌بینی‌ها است. ضریب همبستگی در مدل U-MIDAS بالاترین مقدار را دارد که بیانگر تطابق بهتر این مدل با داده‌های مشاهداتی و دقت بیشتر آن در شناسایی نوسانات و نقاط تغییر سری زمانی می‌باشد. در مقابل، مدل ARDL با داشتن مقادیر متوسط RMSE و



شکل ۱۱- نمودار داده‌های مشاهداتی و پیش‌بینی شده توسط مدل MIDAS, ARDL و GARCH در مرحله پیش‌بینی

Fig 11. Graph of observed and predicted data by the MIDAS, ARDL and GARCH model in the prediction phase

بر داده‌های فصلی و هم‌فرکانس شده مبتنی هستند، بخشی از اطلاعات زمانی مهم را از دست دادند. این یافته با نتایج پژوهش Barkachian and Rezaei (2016) مطابقت دارد. مدل MIDAS با ضریب تبیین ۰/۸۲ و RMSE برابر ۰/۶۱ مترمکعب بر ثانیه، نسبت به مدل‌های ARDL و GARCH با ضریب تبیین ۰/۶۶ و ۰/۵۲ و RMSE به ترتیب ۰/۹۳ و ۰/۷۱ عملکرد بهتری داشت. محدودیت‌هایی مانند عدم دسترسی به داده‌های با فرکانس بالاتر و عدم لحاظ برخی عوامل مؤثر هیدرومتئورولوژیکی نظیر دما و رطوبت ممکن است دقت پیش‌بینی را تحت تأثیر قرار داده باشد؛ بنابراین، پیشنهاد می‌شود در مطالعات آتی، استفاده از داده‌های ماهانه دقیق‌تر، داده‌های ماهواره‌ای و گنجلدن متغیرهای آب‌وهوایی مدنظر قرار گیرد. نتایج این تحقیق، مدل MIDAS را به‌عنوان گزینه‌ای دقیق، عملیاتی و کارآمد برای پیش‌بینی رواناب و بهبود سیستم‌های هشدار سیل و مدیریت بحران در حوضه‌های مشابه معرفی می‌کند.

شکل ۱۱ نشان می‌دهد که نمودار داده‌های مشاهداتی به نمودار مدل MIDAS بسیار نزدیک است که این نزدیکی تأییدکننده برتری و دقت بالای این مدل در پیش‌بینی سری‌های زمانی می‌باشد. این تطابق نشان می‌دهد که مدل MIDAS توانسته است به‌خوبی رفتار واقعی داده‌ها را شبیه‌سازی کند و بنابراین به‌عنوان بهترین مدل در این مطالعه معرفی می‌شود.

۴- نتیجه‌گیری و جمع‌بندی

در این پژوهش، مدل MIDAS برای پیش‌بینی رواناب فصلی حوضه آبریز بهرام‌جو به کار گرفته شد. مدل MIDAS با استفاده از داده‌های بارش ماهانه که تغییرات زمانی دقیق‌تر و جزئیات بیشتری نسبت به داده‌های فصلی ارائه می‌دهد، توانست دقت پیش‌بینی را به‌طور قابل توجهی افزایش دهد. در مقابل، مدل‌های ARDL و GARCH که

منابع

- Badrzadeh H, 2014. River flow forecasting using an integrated approach of wavelet multi-resolution analysis and computational intelligence techniques. Doctoral dissertation, Curtin University (In Persian).
- Barkachian R, and Rezaei M, 2016. Examining the performance of mixed-data sampling regression in predicting Iran's seasonal inflation. *Economics and Modeling*, 7(25), 25–46 (In Persian).
- Bollerslev T, 1986. Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327, doi.org/10.1016/0304-4076(86)90063-1.
- Engle RF, and Kroner KF, 1995. Multivariate simultaneous generalized ARCH. *Econometric Theory*, 11(1), 122–150, doi.org/10.1017/S0266466600009063.
- Ghysels E, and Ozkan N, 2015. Real-time forecasting of the US federal government budget: A simple mixed frequency data regression approach. *International Journal of Forecasting*, 31(4), 1009–1020, doi.org/10.1016/j.ijforecast.2014.12.008.
- Ghysels E, Santa-Clara P, and Valkanov R, 2004. The MIDAS touch: Mixed data sampling regression models. *Econometric Reviews*, 23(2), 147-186., doi.org/10.1081/ETC-120028872.
- Ghysels, E., Sinko, A., and Valkanov, R., 2007. MIDAS regressions: Further results and new directions. *Econometric Reviews*, 26(1), 53–90, doi.org/10.1080/07474930600972467.
- Gujarati DN, and Porter DC, 2009. *Basic econometrics*. McGraw-Hill.
- Kazemzadeh E, Ebrahimi-Salari T, and Behnama M, 2019. Forecasting the growth rate of gold coin prices in Iran using the MIDAS regression model. *Applied Economics*, 9(28), 43–53 (In Persian).
- Khazaei M, and Mirzaei MR, 2013. Comparison of

- the efficiency of monthly discharge prediction using artificial neural networks and time series methods. *Journal of Watershed Engineering and Management*, 5(2), 74–84 (In Persian).
- Klein LR, and Sojo E, 1989. Combinations of high and low-frequency data in macroeconomic models. In *Economics in Theory and Practice: An Eclectic Approach: Essays in Honor of F. G. Adams*, pp. 3–16. Springer, doi.org/10.1007/978-94-009-2474-9_1.
 - Maroufi S, Moradi K, and Parsafar N, 2013. Daily flow forecasting using artificial neural networks and wavelet neural networks (Case study: Barandoozchay River). *Journal of Soil and Plant Knowledge*, 23(3), 93–103 (In Persian).
 - Noferesti M, and Bayat M, 2016. Forecasting monthly inflation rate: Application of the mixed-frequency error correction model (EC-MIDAS). *Economics and Modeling*, 7(27), 55–70 (In Persian).
 - Noferesti M, Varahrami V, and Dashtban-Faraji S, 2018. Investigating the effect of changes in population age structure on government consumption expenditures and forecasting its developments using the MIDAS model. *Journal of Growth and Sustainable Development Research*, 18(3), 103–123 (In Persian).
 - Pesaran MH, and Shin Y, 1995. An autoregressive distributed lag modelling approach to cointegration analysis (Vol. 9514). Cambridge, UK, University of Cambridge.
 - Solín E, and Sládeková Madajová M, 2019. Flood risk of municipalities in upper basins of Slovakia. In *Water Resources in Slovakia: Part II: Climate Change, Drought and Floods*, pp. 173–193, doi.org/10.1007/698_2017_173.
 - Wang H, Song S, Zhang G, Ayantobo OO, and Guo T, 2023. Stochastic volatility modeling of daily streamflow time series. *Water Resources Research*, 59(1), e2021WR031662, doi.org/10.1029/2021WR031662.