



Simulation of downstream flow discharge at Maijaran dam using stochastic models

Elham Feizabadi¹ | Mohammad Mirzavand² | Seyyed Javad Sadatinejad³

1. School of Energy Engineering and Sustainable Resources, College of Interdisciplinary Science and Technology, University of Tehran, Tehran, Iran. E-mail: feizabadi.elham@ut.ac.ir
2. Corresponding Author, School of Energy Engineering and Sustainable Resources, College of Interdisciplinary Science and Technology, University of Tehran, Tehran, Iran. E-mail: mmirzavand@ut.ac.ir
3. School of Energy Engineering and Sustainable Resources, College of Interdisciplinary Science and Technology, University of Tehran, Tehran, Iran. E-mail: JSadatinejad@ut.ac.ir

| Article Info | ABSTRACT |
|--|---|
| <p>Article type: Research Article</p> <p>Article history: Received 10 October 2025 Received in revised form 8 November 2025 Accepted 26 November 2025 Published online 17 March 2026</p> <p>Keywords: ARMA Autocorrelation Discharge Stochastic Model</p> | <p>In the arid and semi-arid climatic conditions of Iran, optimal water resource management is of paramount importance. Accurate prediction of river flow discharge serves as an effective strategy in this regard, playing a key role in dam operation planning. This study aimed to simulate flow discharge downstream of the Maijaran Dam in Mazandaran Province, using monthly discharge data from the Maijaran Dam hydrometric station spanning the period 2007 to 2022. Following preliminary analyses—including normality and stationarity tests—and decomposition of the data into deterministic and stochastic components, the stochastic part of the time series was selected for modeling. Various time series model structures were evaluated using the Autocorrelation Function (ACF) and Partial Autocorrelation Function (PACF). Among the candidate models, the ARMA model was identified as the most suitable. Model orders were determined using ACF and PACF analyses, and model performance was assessed using the Akaike Information Criterion (AIC) and the coefficient of determination (R^2). Results indicated that the ARMA(3,2) model, with an AIC value of 144.06 and R^2 of 0.79, outperformed other models and provided acceptable accuracy in flow discharge simulation. The findings demonstrate the high efficacy of stochastic ARMA models in simulation of hydrological time series in data-scarce regions, offering a reliable tool for supporting water resource management decisions.</p> |

Cite this article: Feizabadi, E., Mirzavand, M., & Sadatinejad, S.J. (2026). Simulation of downstream flow discharge at Maijaran dam using stochastic models. *Journal of Water and Irrigation Management*, 15 (4), 713-727.
DOI: <https://doi.org/10.22059/jwim.2025.403909.1266>





شبیه‌سازی دبی جریان در پایین دست سد میجران با استفاده از مدل‌های غیرقطعی

الهام فیض‌آبادی^۱ | محمد میرزاوند^۲ | سید جواد ساداتی نژاد^۳

۱. گروه علوم و فناوری‌های محیطی، دانشکده مهندسی انرژی و منابع پایدار، دانشگاه تهران، تهران، ایران. رایانامه: feizabadi.elham@ut.ac.ir
۲. نویسنده مسئول، گروه علوم و فناوری‌های محیطی، دانشکده مهندسی انرژی و منابع پایدار، دانشگاه تهران، تهران، ایران. رایانامه: mmirzavand@ut.ac.ir
۳. گروه علوم و فناوری‌های محیطی، دانشکده مهندسی انرژی و منابع پایدار، دانشگاه تهران، تهران، ایران. رایانامه: JSadatinejad@ut.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله: مقاله پژوهشی

در شرایط اقلیمی خشک و نیمه‌خشک ایران، مدیریت بهینه منابع آب از اهمیت بالایی برخوردار است. یکی از راه‌کارهای مؤثر در این زمینه، پیش‌بینی دقیق دبی جریان رودخانه‌هاست که می‌تواند نقش کلیدی در برنامه‌ریزی بهره‌برداری از سدها ایفا کند. در این پژوهش، با هدف شبیه‌سازی دبی جریان پایین دست سد میجران واقع در استان مازندران، از داده‌های دبی ماهانه مربوط به ایستگاه هیدرومتری سد میجران در بازه زمانی ۱۳۸۶ تا ۱۴۰۱ استفاده شد. پس از انجام تحلیل‌های مقدماتی شامل آزمون نرمال بودن و ایستایی داده‌ها و تجزیه آن به مؤلفه‌های قطعی و غیرقطعی، بخش غیرقطعی سری زمانی جهت مدل‌سازی انتخاب شد. سپس با استفاده از تابع خودهمبستگی (ACF) و تابع خودهمبستگی جزئی (PACF) مدل‌های سری زمانی با ساختارهای گوناگون مورد ارزیابی قرار گرفتند. بنابراین، از بین مدل‌های مختلف، مدل ARMA مناسب تشخیص داده شد. برای تعیین مرتبه‌های مدل ARMA، از تابع خودهمبستگی AFC و PACF استفاده شد و جهت ارزیابی عملکرد مدل‌ها، از معیار اطلاعاتی آکائیک (AIC) و ضریب تعیین (R^2) بهره گرفته شد. نتایج نشان داد مدل ARMA(3,2) با مقدار AIC برابر با ۱۴۴/۰۶ و R^2 برابر با هفتاد و نه صدم، عملکرد بهتری نسبت به سایر مدل‌ها دارد و قادر است دبی جریان را با دقت قابل قبول شبیه‌سازی کند. یافته‌های این مطالعه نشان‌دهنده کارایی بالای مدل‌های غیرقطعی ARMA در شبیه‌سازی و پیش‌بینی سری‌های زمانی جریان آب در مناطق با اطلاعات محدود است و می‌تواند به‌عنوان ابزاری کارآمد در تصمیم‌گیری‌های مدیریت منابع آب مورد استفاده قرار گیرد.

تاریخ دریافت: ۱۴۰۴/۰۷/۱۸

تاریخ بازنگری: ۱۴۰۴/۰۸/۱۷

تاریخ پذیرش: ۱۴۰۴/۰۹/۰۵

تاریخ انتشار: ۱۴۰۴/۱۲/۲۶

کلیدواژه‌ها:

خودهمبستگی
خودهمبسته میانگین متحرک
دبی
مدل غیرقطعی

استناد: فیض‌آبادی، الهام؛ میرزاوند، محمد و ساداتی نژاد، سیدجواد (۱۴۰۴). شبیه‌سازی دبی جریان در پایین دست سد میجران با استفاده از مدل‌های غیرقطعی. نشریه مدیریت آب و آبیاری، ۱۵ (۴)، ۷۱۳-۷۲۷. DOI: <https://doi.org/10.22059/jwim.2025.403909.1266>



۱. مقدمه

کمبود منابع آبی یکی از چالش‌های جدی پیش‌روی بشر محسوب می‌شود که پیامدهای آن نه‌تنها بر اکوسیستم‌های طبیعی، بلکه بر رفاه جامعه و ثبات اقتصادی، مسائل اجتماعی و امنیتی نیز سایه می‌افکند. با رشد روزافزون نیاز به آب، رقابت میان مصرف‌کنندگان مختلف تشدید شده و این تنش‌ها به‌ویژه در دوره‌های خشک‌سالی طولانی‌مدت و فراگیر، به‌وضوح قابل مشاهده است (Hisdal and Tallaksen, 2003; Malakoutian *et al.*, 2022). این چالش به‌ویژه در کشورهای واقع در مناطق خشک و نیمه‌خشک جهان که با پدیده‌های خشک‌سالی هواشناسی و کم‌آبی منابع زیرزمینی مواجه هستند، شدت بیش‌تری یافته است (Soleimani Motlagh *et al.*, 2017). از جمله این مناطق بحرانی می‌توان به شمال آفریقا و خاورمیانه اشاره کرد که ایران نیز بخشی از این جغرافیای پرتنش محسوب می‌شود (Mirzavand and Bagheri, 2020). کشور ایران در منطقه‌ای با اقلیم خشک و نیمه‌خشک واقع شده که این موقعیت، ویژگی‌های خاص هیدرولوژیکی آن را شکل داده است. این وضعیت زمانی آشکارتر می‌شود که بدانیم متوسط بارش درازمدت سالانه کشور از سال ۱۲۷۹ تا ۱۴۰۳، حدود ۲۲۷ میلی‌متر است رقمی که کم‌تر از یک‌سوم میانگین جهانی محسوب می‌شود. در نتیجه، مسئله کمبود آب به‌عنوان یک چالش بنیادین در این جغرافیا مطرح بوده که مدیریت کارآمد آن مستلزم اتخاذ راهبردهای یکپارچه، طراحی برنامه‌های جامع و پیاده‌سازی سیاست‌های پایدار است (Alizadeh, 2011). رودخانه‌ها به‌ویژه در شرایط اقلیمی کنونی، نقش مهمی در پایداری خدمات اکوسیستم دارند. بنابراین، پیش‌بینی دبی جریان در رودخانه‌های پایین‌دست سدها که از اجزای اساسی مدیریت منابع آب محسوب می‌شود، تأثیر قابل‌توجهی در بهینه‌سازی استفاده از ذخایر آبی و کاهش خسارت‌های مربوط به حوادث طبیعی مرتبط با آب دارد (Yaseen *et al.*, 2015). مدل‌های غیرقطعی با توجه به قابلیت تطبیق‌پذیری بالا در شرایط عدم قطعیت موجود در متغیرهای هیدرولوژیک و نیاز کم‌تر به اطلاعات دقیق از ویژگی‌های فیزیکی حوضه، به‌عنوان روشی مؤثر برای پیش‌بینی و تحلیل جریان رودخانه‌ها مورد توجه ویژه قرار گرفته‌اند (Adamowski and Chan, 2011). روش‌های غیرقطعی با در نظر گرفتن ویژگی‌های احتمالی و غیرقابل پیش‌بینی متغیرهای هیدرولوژیک، نقش مهمی در شبیه‌سازی و پیش‌بینی متغیرهای هیدرولوژیک مانند دبی جریان رودخانه‌ها ایفا می‌کنند (Yaseen *et al.*, 2015). این روش‌ها می‌توانند بدون آن که نیازمند اطلاعات جامعی از ویژگی‌های فیزیکی حوضه باشند، الگوهای پنهان و روابط زمانی موجود در داده‌های تاریخی را کشف کرده و پیش‌بینی‌های دقیقی ارائه دهند (Adamowski and Chan, 2011; Mirzavand and Ghazavi, 2015). سهولت اجرای همراه با نیاز حداقلی به داده‌ها، باعث شده این مدل‌ها به‌ویژه در مناطقی با اطلاعات ناکافی، کارایی قابل‌توجهی از خود نشان دهند (Box *et al.*, 1976). تحلیل سری‌های زمانی بیش‌تر با دو هدف اصلی شامل شناخت و مدل‌سازی فرایندهای احتمالی تشکیل‌دهنده الگوی داده‌ها و نیز پیش‌بینی مقادیر آینده بر مبنای رفتار گذشته همان سری انجام می‌شود (Cryer, 1992; Ckersik, 2001). تحلیل سری‌های زمانی در علوم هیدرولوژی از حدود ۶۰ سال قبل مورد توجه قرار گرفت و با معرفی روش‌های تحلیلی باکس-جنکینز به نقطه عطف خود رسید (Azizi, 2005). در میان پیشگامان به‌کارگیری مدل‌های خطی خودهمبسته در مطالعه رفتار رودخانه‌ها، توماس و فایرینگ از نخستین پژوهش‌گران محسوب می‌شوند (Thomas and Fiering, 1962). پس از آن‌ها مطالعات متعددی انجام گرفت که می‌توان به پژوهش‌های Hipel and McLeod (1994) و Thompson *et al.* (1985) و Wang *et al.* (2005) و Yurekli *et al.* (2005) اشاره کرد. شاید بتوان اولین گام مؤثر در به‌کارگیری عملی روش‌های سری‌زمانی در هیدرولوژی را به مک‌کرچار و دولر نسبت داد. این پژوهش‌گران با توجه به رفتار فصلی پارامترهای هیدرولوژیکی، از مدل‌های SARIMA^۱ و PARMA^۲ برای مدل‌سازی دبی رودخانه‌ها استفاده کردند (Laux *et al.*, 2011). در مقایسه با نمونه‌های تصادفی مستقل، داده‌های سری‌زمانی دارای خودهمبستگی بوده و این ویژگی وابستگی زمانی، هسته اصلی روش‌های پیش‌بینی در مطالعات سری‌زمانی محسوب می‌شود

(Abdollahnejad Kamel, 2015). مدل‌های سری‌زمانی متشکل از دو جزء اساسی هستند. یکی بخش سیستماتیک (قطعی) که از داده‌های مشاهده‌شده مشتق می‌شود و یک بخش احتمالاتی (تصادفی یا غیرقطعی) که با روش‌های آماری تخمین زده می‌شود. هنگامی که مدل به درستی انتخاب و پارامترهای آن به دقت محاسبه شوند، این ساختار دوگانه می‌تواند به خوبی ویژگی‌های سری‌های هیدرولوژیکی را بازتاب دهد (Salas, 1993). به همین دلیل است که این روش‌های پیش‌بینی، امروزه کاربرد گسترده‌ای در مطالعات منابع آب دارند. از میان انواع مدل‌های سری‌زمانی، مدل‌های خودهمبسته^۳ (AR)، میانگین متحرک (MA)^۴، ترکیب خودهمبسته-میانگین متحرک (ARMA)^۵ و خودهمبسته-میانگین متحرک تجمعی (ARIMA)^۶ بیش‌ترین استفاده را در پژوهش‌های هیدرولوژیکی دارند (Tsonis, 2001; Dastorani et al., 2016). در زمینه مدل‌های خطی سری‌زمانی، مطالعات مختلفی انجام گرفته است (Fouladmand, 2010; Khalili et al., 2007; Sabaghian and Sharifi, 2009; Sabziparvar et al., 2014; Mousavi et al., 2011). مدل‌های استوکاستیک ARMA (1996) Padilla et al. (2009; Sabziparvar et al., 2014; Mousavi et al., 2011) تحلیل سری‌های زمانی دبی سه چشمه کارستی در اسپانیا و فرانسه به کار گرفتند. نتایج مطالعه آن‌ها نشان داد که می‌توان از مدل‌های استوکاستیک به منظور پیش‌بینی دبی استفاده کرد. همچنین آن‌ها بهترین مدل ARMA را ارائه کردند. Burlando et al. (1996) بیان کردند که با توجه به اهمیت مدیریت پایدار منابع آب و نقش سری‌های زمانی در درک الگوهای هیدرولوژیکی، استفاده از مدل‌های استوکاستیک مانند ARMA می‌تواند به عنوان ابزاری کارآمد برای تحلیل دقیق دبی رودخانه‌ها و پیش‌بینی رفتار آن‌ها مطرح شود. ایشان بیان کردند که، این مدل‌ها نه تنها به درک بهتر فرایندهای تصادفی کمک می‌کنند، بلکه زمینه‌ساز تصمیم‌گیری‌های علمی و عملی در شرایط بحرانی منابع آب خواهند بود. لذا با توجه به کارایی این مدل‌ها و اهمیت پیش‌بینی درست دبی جریان در مدیریت پایداری تأمین آب موردنیاز ۱۵۰۰ هکتار از اراضی کشاورزی و فعالیت‌های صنعتی پایین دست سد میجران، هدف از این مطالعه، شبیه‌سازی دبی جریان پایین دست این سد واقع در استان مازندران با استفاده از مدل‌های غیرقطعی در نرم‌افزار R می‌باشد. مهم‌ترین تمایز این پژوهش با مطالعات پیشین، در نظرگیری هم‌زمان مؤلفه‌های طبیعی (دبی) و اثرات مدیریتی (خروجی سد) در مدل‌سازی سری‌زمانی است که منجر به شبیه‌سازی واقعی‌تر و کاربردی‌تری از جریان پایین دست خواهد شد.

۲. روش‌شناسی پژوهش

۲.۱. منطقه مورد مطالعه

استان مازندران در شمال ایران دارای وسعتی معادل ۲۳۷۵۶/۴ کیلومترمربع است. شهرستان رامسر در استان مازندران، دارای ۷۲۹/۸ کیلومترمربع وسعت می‌باشد که ۳/۰۷ درصد کل مساحت استان را به خود اختصاص داده است. سد میجران در استان مازندران، در فاصله ۲۰ کیلومتری رامسر، روی رودخانه نسا رود قرار دارد. سد میجران در اسفندماه سال ۱۳۸۲ به منظور تأمین آب زراعی منطقه به میزان ۱۵۰۰ هکتار، توسعه و تقویت صنعت گردشگری و تأمین آب نوشیدنی شهرهای رامسر، کتالم و سادات شهر به میزان هفت میلیون مترمکعب ساخته شده است. موقعیت منطقه مورد مطالعه در این پژوهش در شکل (۱) ارائه شده است.

۲.۲. داده‌های مورد استفاده

داده‌های مورد استفاده در این پژوهش شامل مقدار دبی ماهانه برحسب مترمکعب می‌باشند. این داده‌ها مربوط به ایستگاه هیدرومتری سد میجران در شهرستان رامسر می‌باشند و بازه زمانی مورد مطالعه از سال ۱۳۸۶ تا ۱۴۰۱ (۱۵ سال طول دوره آماری) می‌باشد.

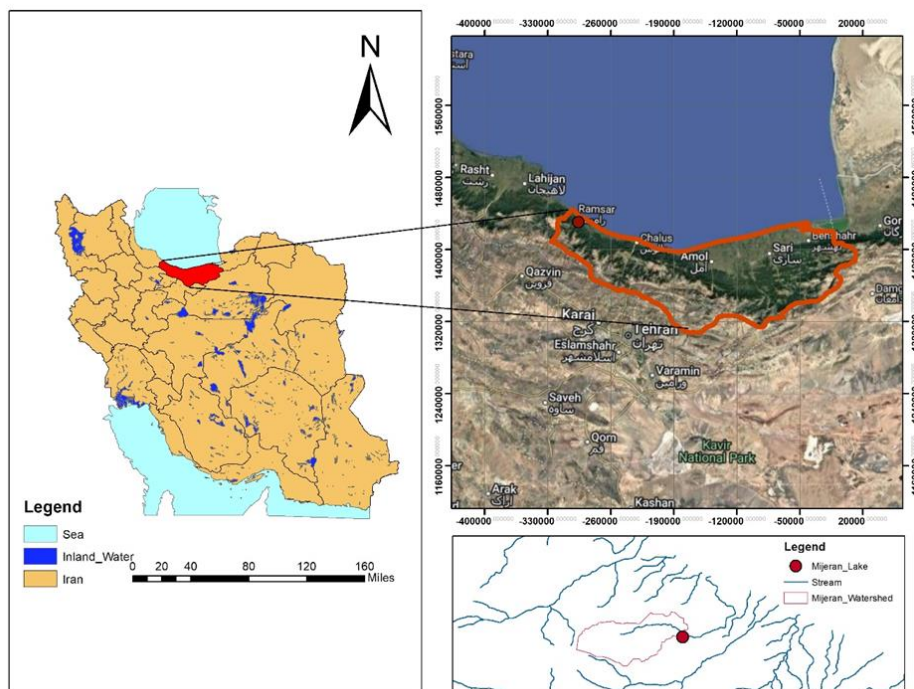


Figure 1. Geographical location of the study area in Iran and Mazandaran Province

۳.۲. مدل‌های غیرقطعی

سری‌های زمانی به مجموعه مشاهداتی اطلاق می‌گردد که در بازه‌های زمانی مشخص و منظم ثبت شده‌اند. ماهیت خاص این داده‌ها منجر به توسعه روش‌های تحلیلی ویژه‌ای شده که تحت عنوان "آنالیز سری‌های زمانی" شناخته می‌شوند. این مشاهدات که براساس توالی زمانی مرتب شده‌اند، عموماً با روابط ریاضی مانند رابطه (۱) قابل نمایش هستند.

$$X_{t_1}, X_{t_2}, \dots, X_{t_n} \quad \text{رابطه (۱)}$$

انواع مدل‌های سری‌های زمانی شامل مدل خودهمبسته (AR)، مدل میانگین متحرک (MA) و مدل‌های ترکیبی می‌باشند. برخی از فرایندها نه تنها دارای ویژگی خودهمبستگی هستند، بلکه ویژگی‌های میانگین متحرک را نیز دارا می‌باشند. در چنین مواردی، از مدل‌های ترکیبی مانند مدل خودهمبسته-میانگین متحرک (ARMA) و مدل خودهمبسته-میانگین متحرک تجمیعی (ARIMA) استفاده می‌شود. اولین گام در مدل‌سازی، شناسایی مدل براساس ویژگی‌های سری مشاهداتی است. در زیر، روابط مورد استفاده در مدل‌های مختلف غیرقطعی بررسی شده در این پژوهش ارائه شده است.

۳.۲.۱. مدل خودهمبسته

مدل خودهمبسته (AR) را می‌توان به صورت رابطه (۲) بیان کرد:

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t \quad \text{رابطه (۲)}$$

که در آن، φ_1 ، φ_2 و φ_p ضرایب و پارامترهای مدل هستند و a_t بخش تصادفی داده‌ها می‌باشد که دارای توزیع نرمال با میانگین صفر است (Hannan, 1971).

۲.۳.۲. مدل میانگین متحرک

مدل میانگین متحرک (MA) را می‌توان به صورت رابطه (۳) بیان کرد:

$$Z_t = \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} + a_t \quad \text{رابطه ۳}$$

که در آن، θ_1 ، θ_2 و θ_p ضرایب و پارامترهای مدل هستند و a_t بخش تصادفی داده‌ها می‌باشد که دارای توزیع نرمال با میانگین صفر است (Hannan, 1971).

۲.۳.۳. مدل خودهمبسته- میانگین متحرک

مدل خودهمبسته- میانگین متحرک (ARMA) به صورت ARMA(p, q) را می‌توان به صورت رابطه (۴) بیان کرد:

$$Y_t = \delta + \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + e_t \quad \text{رابطه ۴}$$

که در آن، δ مقدار ثابت مدل ARMA، ϕ_i ضریب i ام خودهمبستگی، θ_j ضریب j ام میانگین متحرک، e_t خطای مربوط به دوره زمانی t و Y_t مقدار مشاهده شده یا پیش‌بینی شده دبی جریان در دوره زمانی t می‌باشد (Erdem and Shi, 2011).

۲.۳.۴. مدل خودهمبسته- میانگین متحرک یکپارچه و میانگین متحرک خودهمبسته یکپارچه فصلی

مدل‌های خودهمبسته- میانگین متحرک یکپارچه (ARIMA) یکی از مهم‌ترین انواع مدل‌های خطی برای پیش‌بینی سری‌های زمانی هستند. مدل ARIMA از ترکیب مدل‌های خودرگرسیون (AR) و مدل‌های میانگین متحرک (MA) ناشی می‌شود. مدل ARIMA یک مدل Box-Jenkins را بر روی یک سری زمانی برازش می‌دهد (Shirmohammadi et al., 2013). در فرایند مدل‌سازی با استفاده از مدل ARIMA، از تکنیک‌های همبستگی استفاده می‌شود و می‌تواند برای مدل‌کردن الگوهایی به کار رود که در داده‌ها دید نمی‌شوند (Box et al., 1994). همچنین، یک مدل SARIMA را می‌توان به صورت $(P, D, Q)_s(P, D, Q)_s$ ARIMA(p, d, q) توضیح داد، که در آن p ، d و q ، بخش غیرفصلی مدل و $(P, D, Q)_s$ بخش فصلی مدل است، به طوری که p مرتبه خودرگرسیون غیرفصلی، d تعداد دفعات تفاضل‌گیری معمولی، q مرتبه میانگین متحرک غیرفصلی، P مرتبه خودرگرسیون فصلی، D تعداد دفعات تفاضل‌گیری فصلی، Q مرتبه میانگین متحرک فصلی و s طول دوره فصلی است (Faruk, 2010).

۲.۴.۲. آماده‌سازی داده‌ها و بررسی مدل‌های اولیه

۲.۴.۲.۱. بررسی نرمال بودن، ایستایی داده‌ها و روند در سری زمانی

یکی از مهم‌ترین فرض‌ها در مدل‌سازی سری‌های زمانی با استفاده از مدل‌های غیرقطعی، نرمال بودن داده‌ها و همچنین ایستایی بودن سری‌های زمانی داده‌های مورد استفاده است. لذا در این پژوهش، جهت بررسی نرمال بودن داده‌ها، با توجه به این که تعداد داده‌ها از ۵۰ عدد بیشتر بود (۱۹۲ داده)، از آزمون کلموگروف-اسمیرنوف در نرم‌افزار Minitab استفاده شد. در صورتی که مقدار p -value به دست آمده از این آزمون بیشتر از پنج صدم باشد، داده‌ها نرمال می‌باشند، در غیر این صورت، داده‌ها نرمال نبوده و نیاز به نرمال‌سازی قبل از هرگونه مدل‌سازی است. با توجه به این که داده‌های مورد بررسی نرمال نبودند، قبل از این که اقدام به نرمال‌سازی داده‌ها شود، ابتدا مشخص شد که داده‌ها از چه توزیع آماری تبعیت می‌کنند، برای این منظور، از نرم‌افزار Minitab استفاده شد. سپس با توجه به نوع توزیع آماری، داده‌ها نرمال شدند. همچنین، جهت بررسی ایستایی سری‌های زمانی داده‌های مورد استفاده، از آزمون کویاتکوفسکی-فیلیپس-اشمیت-شین (KPSS)^۷ در محیط برنامه R استفاده شد. در این آزمون نیز در صورتی که مقدار p -value به دست آمده از این آزمون

بیش‌تر از ۰/۰۵ باشد، داده‌ها ایستا می‌باشند، در غیر این صورت، داده‌ها ایستا نبوده و نیاز به ایستا کردن سری زمانی (به‌طور عمده با تفاضل‌گیری) قبل از هرگونه مدل‌سازی می‌باشد. هم‌چنین به‌منظور بررسی روند در سری زمانی مورد بررسی، از آزمون من-کندال استفاده شد. در صورت وجود روند در داده‌ها، لازم است بخش روند حذف شود. در صورتی که مقدار آماره من-کندال (z) بین $+۱/۹۶$ تا $-۱/۹۶$ باشد، سری فاقد روند است.

۲.۴.۲. انتخاب مدل اولیه

قبل از شروع مدل‌سازی سری زمانی، نیاز است تا مدل‌ساز مدل‌هایی را که احتمال بیش‌تری دارد جواب بهتری در مدل‌سازی بدهند، شناسایی کند. برای این منظور، از تابع خودهمبستگی (ACF)^۱ و تابع خودهمبستگی جزئی (PACF)^۲ استفاده شد. در صورتی که تابع ACF به‌صورت نمایی کاهش یابد و PACF بعد از n تأخیر، معنی‌دار باشد (از حدود معنی‌دار بیش‌تر باشد)، مدل AR مدل مناسبی خواهد بود. اما اگر تابع PACF به‌صورت نمایی کاهش یابد و تابع ACF بعد از n تأخیر معنی‌دار باشد، مدل MA مدل بهتری خواهد بود. لازم به ذکر است که تعداد قله‌های معنی‌دار در ACF مرتبه مدل MA یا q را و تعداد قله‌های معنی‌دار در تابع PACF مرتبه مدل AR یا p را نشان می‌دهند. اما اگر هر دو تابع ACF و PACF به‌صورت تدریجی کاهش یابند (بدون قطع شدن واضح)، نیاز به مدل‌های ترکیبی مانند ARMA می‌باشد و معمولاً از معیارهای اطلاعاتی (مثل AIC/BIC)^۱ برای انتخاب p و q استفاده می‌شود. هم‌چنین، اگر سری زمانی غیرایستا باشد، ابتدا تفاضل‌گیری (d) انجام می‌شود تا سری زمانی ایستا شود و از مدل ARIMA استفاده خواهد شد. درنهایت اگر الگوهای فصلی در ACF/PACF با تأخیرهای مضرب s (مثلاً ۱۲ برای داده‌های ماهانه) ظاهر شوند، از مدل SARIMA استفاده می‌شود.

۲.۴.۳. تفکیک بخش‌های قطعی و غیرقطعی سری زمانی

همان‌طور که بیان شد، مهم‌ترین فرایند در مدل‌سازی سری‌های زمانی، جداسازی بخش‌های قطعی و غیرقطعی سری زمانی و مدل‌سازی بخش غیرقطعی سری زمانی می‌باشد (Mirzavand and Ghazavi, 2015). بنابراین، در این پژوهش، در برنامه R، سری زمانی تجزیه و بخش غیرقطعی سری زمانی از بخش‌های قطعی (پرش، فصلی، روند) جدا و مدل‌سازی با استفاده از مدل انتخابی بر روی این بخش از سری زمانی داده‌های دبی انجام شد.

۲.۴.۴. انتخاب مرتبه‌های مدل انتخابی

در این مرحله الگوهای شناسایی شده در مرحله قبل مورد آزمون قرار می‌گیرند. در واقع توابع خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) تعداد گام‌های معنی‌دار در هر یک از نمودارهای ذکر شده محدودۀ تغییرات مرتبه مدل را نشان داده و درنهایت با ترکیب آن‌ها و در سطح اطمینان ۹۵ درصد می‌توان به مدل مناسبی دست پیدا کرد که کم‌ترین خطا و بیش‌ترین همبستگی با داده‌ها را نشان دهد (Ghahreman and Gharekhani, 2011). در این راستا از معیارهای گوناگونی برای ارزیابی و مقایسه عملکرد مدل‌ها استفاده می‌شود (Dodangeh et al., 2012). با توجه به این‌که در تابع ACF و PACF در چه تأخیرهایی حدود معنی‌داری را قطع می‌کند، به‌ترتیب مرتبه‌های q و p مدل انتخاب می‌شود.

۲.۴.۵. انتخاب مدل نهایی

برای ارزیابی عملکرد مدل‌های منتخب اولیه و انتخاب بهترین شبیه‌سازی، از ضریب تعیین (R^2) و معیار اطلاعاتی

آکائیک (AIC) استفاده شد. مدل‌هایی که AIC کم‌تر، R^2 بیش‌تر و قدرمطلق پارامترهای مدل از یک تجاوز نکنند به‌عنوان مدل برتر انتخاب می‌شوند. معیار AIC را می‌توان به‌صورت رابطه (۵) بیان کرد:

$$AIC(k) = n \ln(MSE) + 2K \quad (\text{رابطه ۵})$$

در این رابطه، n تعداد داده‌های مورد استفاده (برای واسنجی مدل) و k تعداد پارامترهای آزاد به‌کاررفته در مدل را نشان می‌دهد. MSE نیز برابر با میانگین مربعات خطا است. به‌طور کلی، در بین مدل‌های مختلف، مدلی مناسب‌تر است که دارای مقدار R^2 بالاتر و کم‌ترین مقدار AIC باشد و قدرمطلق پارامترهای مدل از یک تجاوز نکند.

۳. نتایج و بحث

اولین مرحله در آنالیز سری‌های زمانی مشاهده گرافیکی داده‌ها می‌باشد. بنابر این ضرورت، روند تغییرات دبی ماهانه در شکل (۲) ارائه شده است.




Figure 2. Decomposed Data Visualization

همان‌طور که در نمودار شکل (۲) مشاهده می‌شود، داده‌ها شامل یک روند کلی همراه با نوسانات فصلی، با نوسانات تناوبی منظم و یک مؤلفه تصادفی با نویزهای غیرقابل پیش‌بینی هستند. این مؤلفه‌ها بیانگر تغییرات بلندمدت، الگوهای تکرارشونده و عدم قطعیت در داده‌ها هستند. در این پژوهش، از مؤلفه تصادفی به‌دست‌آمده از تجزیه سری‌زمانی برای بهبود دقت پیش‌بینی استفاده شده است. این مؤلفه که نشان‌دهنده نویزها و عدم قطعیت در داده‌هاست، به‌عنوان بخشی از مدل‌سازی در نظر گرفته شد تا الگوهای پنهان و تأثیرات غیرقابل پیش‌بینی را در

فرایند پیش‌بینی لحاظ کند. به منظور آماده‌سازی داده‌های سری زمانی ابتدا نرمال بودن داده‌ها تعیین شد، نتایج نشان داد که در ایستگاه هیدرومتری مورد مطالعه داده‌ها نرمال نبوده ($P\text{-value} < 0.05$). با توجه به بررسی‌های صورت گرفته در نرم‌افزار Minitab، مشخص شد که داده‌ها از تابع انتقال جانسون پیروی می‌کنند، لذا با استفاده از تابع به‌دست‌آمده، داده‌ها نرمال شدند ($P\text{-value} > 0.05$). همچنین با توجه به نتایج حاصل از بررسی ایستایی داده‌ها در برنامه R، مقدار p-value به‌دست‌آمده برای آزمون KPSS بیش‌تر از 0.05 به‌دست آمد، لذا داده‌ها ایستا بودند و بنابراین نیاز به تفاضل‌گیری نشد. به منظور انتخاب مدل غیرقطعی اولیه، از تابع ACF و PACF استفاده شد. برای این منظور، ابتدا تابع خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) در برنامه R (شکل ۳) ترسیم شد. با توجه به نتایج به‌دست‌آمده و توضیحات ارائه‌شده در بخش روش پژوهش، مشخص شد که مدل ARMA می‌تواند مدل مناسبی برای شبیه‌سازی و پیش‌بینی این سری زمانی باشد. به همین دلیل، از این مدل استفاده شد. جهت تعیین مرتبه‌های مدل، از تابع ACF و PACF استفاده شد. مرتبه (q) مدل از بخش تابع خودهمبستگی (ACF) و مرتبه (p) از طریق نمودار خودهمبستگی جزئی PACF تعیین می‌شود. برای تعیین پارامتر q، با توجه به عبور از سطح معنی‌داری (خط چین بر روی شکل ۳)، تأخیرهای شماره ۱، ۲، ۳، ۴، ۵، ۶ و ۷ به‌عنوان مرتبه‌های اولیه مناسب برای بخش q مدل ARMA در نظر گرفته شدند. همچنین، برای تعیین پارامتر p، با توجه به عبور از سطح معنی‌داری (خط چین بر روی شکل ۳)، تأخیرهای شماره ۱ و ۲ به‌عنوان مرتبه‌های اولیه مناسب برای بخش p مدل ARMA در نظر گرفته شدند. بنابراین با توجه به شرایط حاکم بر سری زمانی داده‌ها و نتایج به‌دست‌آمده از تابع ACF و PACF، در این پژوهش برای مدل‌سازی داده‌های دبی روزانه از روش ARMA غیرفصلی در قالب بررسی ۱۱ مدل با ترکیب $ARMA(1, 1)$ ، $ARMA(1, 2)$ ، $ARMA(1, 4)$ ، $ARMA(1, 5)$ ، $ARMA(1, 6)$ ، $ARMA(3, 1)$ ، $ARMA(3, 2)$ ، $ARMA(3, 4)$ ، $ARMA(3, 5)$ و $ARMA(3, 6)$ انجام شد.

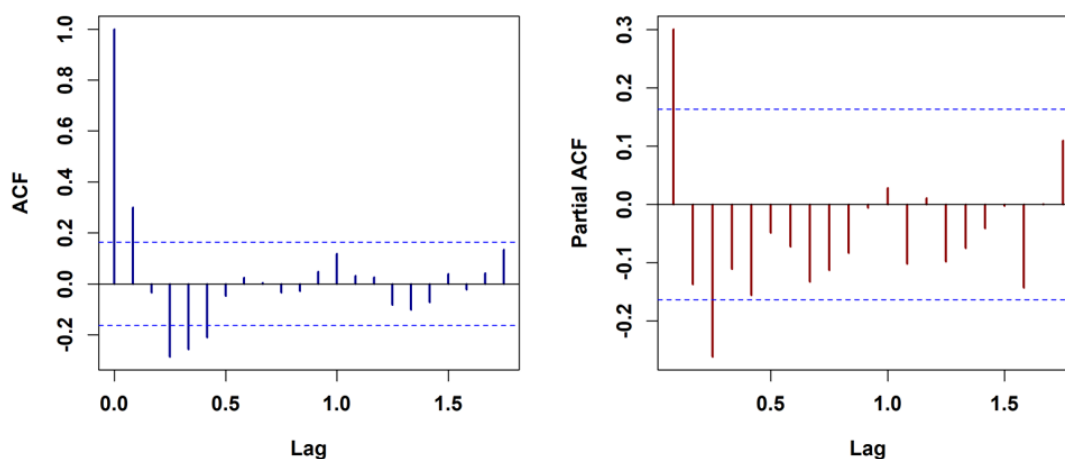


Figure 3. ACF and PACF Plot of the Data

همان‌طور که ملاحظه می‌شود، نتایج مدل‌سازی با ۱۱ مدل غیرقطعی ارائه شده است. از بین این مدل‌ها، مدل‌هایی که دارای ضرایب تبیین بیش‌تر، مقدار آکائیک کم‌تر و مقدار قدرمطلق پارامترهای مدل از ۱ کم‌تر باشد، مدل بهینه خواهد بود. با توجه به نتایج به‌دست‌آمده (جدول ۱)، مشاهده می‌شود که پارامترهای مدل $ARMA(3, 1)$ و مدل $ARMA(3, 5)$ بیش‌تر از یک بودند که نشان‌دهنده عدم ثبات مدل است و از نظر آماری معتبر نیستند، بنابراین این دو مدل حذف شدند (Mirzavand and Ghazavi, 2015).

Table 1. Estimated Parameters and Goodness-of-Fit Criteria for Various ARMA Models

| Model | Parameter | Model parameter values | AIC | R ² |
|------------|------------|------------------------|--------|----------------|
| ARMA(1,1) | ϕ_1 | 0.15 | 169.33 | 0.78 |
| | θ_1 | 0.19 | | |
| ARMA(1,2) | ϕ_1 | -0.57 | 167.99 | 0.79 |
| | θ_1 | 0.94 | | |
| | θ_2 | 0.33 | | |
| ARMA(1,4) | ϕ_1 | 0.46 | 146.24 | 0.79 |
| | θ_1 | -0.31 | | |
| | θ_2 | -0.26 | | |
| | θ_3 | -0.32 | | |
| | θ_4 | -0.09 | | |
| ARMA(1,5) | ϕ_1 | 0.11 | 145.51 | 0.79 |
| | θ_1 | 0.04 | | |
| | θ_2 | -0.17 | | |
| | θ_3 | -0.39 | | |
| | θ_4 | -0.22 | | |
| | θ_5 | -0.23 | | |
| ARMA(1,6) | ϕ_1 | -0.49 | 147.22 | 0.79 |
| | θ_1 | 0.65 | | |
| | θ_2 | -0.08 | | |
| | θ_3 | -0.49 | | |
| | θ_4 | -0.48 | | |
| | θ_5 | -0.41 | | |
| | θ_6 | -0.18 | | |
| ARMA(3,1) | ϕ_1 | 1.13 | 143.62 | 0.79 |
| | ϕ_2 | -0.37 | | |
| | ϕ_3 | -0.06 | | |
| | θ_1 | -1.00 | | |
| ARMA(3,2) | ϕ_1 | 0.34 | 144.06 | 0.79 |
| | ϕ_2 | 0.55 | | |
| | ϕ_3 | -0.43 | | |
| | θ_1 | -0.19 | | |
| | θ_2 | -0.80 | | |
| ARMA(3,4) | ϕ_1 | 0.11 | 147.41 | 0.79 |
| | ϕ_2 | 0.64 | | |
| | ϕ_3 | -0.42 | | |
| | θ_1 | 0.03 | | |
| | θ_2 | -0.84 | | |
| | θ_3 | -0.07 | | |
| | θ_4 | -0.10 | | |
| ARMA(3,5) | ϕ_1 | 0.88 | 143.31 | 0.80 |
| | ϕ_2 | -1.00 | | |
| | ϕ_3 | 0.34 | | |
| | θ_1 | -0.75 | | |
| | θ_2 | 0.76 | | |
| | θ_3 | -0.45 | | |
| | θ_4 | -0.17 | | |
| | θ_5 | -0.37 | | |
| ARMA(3,6) | ϕ_1 | 0.03 | 150.01 | 0.79 |
| | ϕ_2 | -0.11 | | |
| | ϕ_3 | -0.32 | | |
| | θ_1 | 0.10 | | |
| | θ_2 | -0.07 | | |
| | θ_3 | -0.08 | | |
| | θ_4 | -0.28 | | |
| | θ_5 | -0.43 | | |
| θ_6 | -0.22 | | | |

با توجه به نتایج ارائه شده در جدول (۱)، مدل ARMA(3,2)، دارای بیشترین ضریب همبستگی برابر با ۰/۷۹ و همچنین کمترین مقدار معیار آکائیک (AIC) برابر با ۱۴۴/۰۶ بود. نتایج حاصل از شبیه‌سازی سری زمانی دبی ایستگاه هیدرومتری سد میجران براساس مدل‌های ARMA(1,1)، ARMA(1,2)، ARMA(1,4)، ARMA(1,5)، ARMA(1,6)، ARMA(3,2)، ARMA(3,4) و ARMA(3,6) در شکل (۴) ارائه شده است.

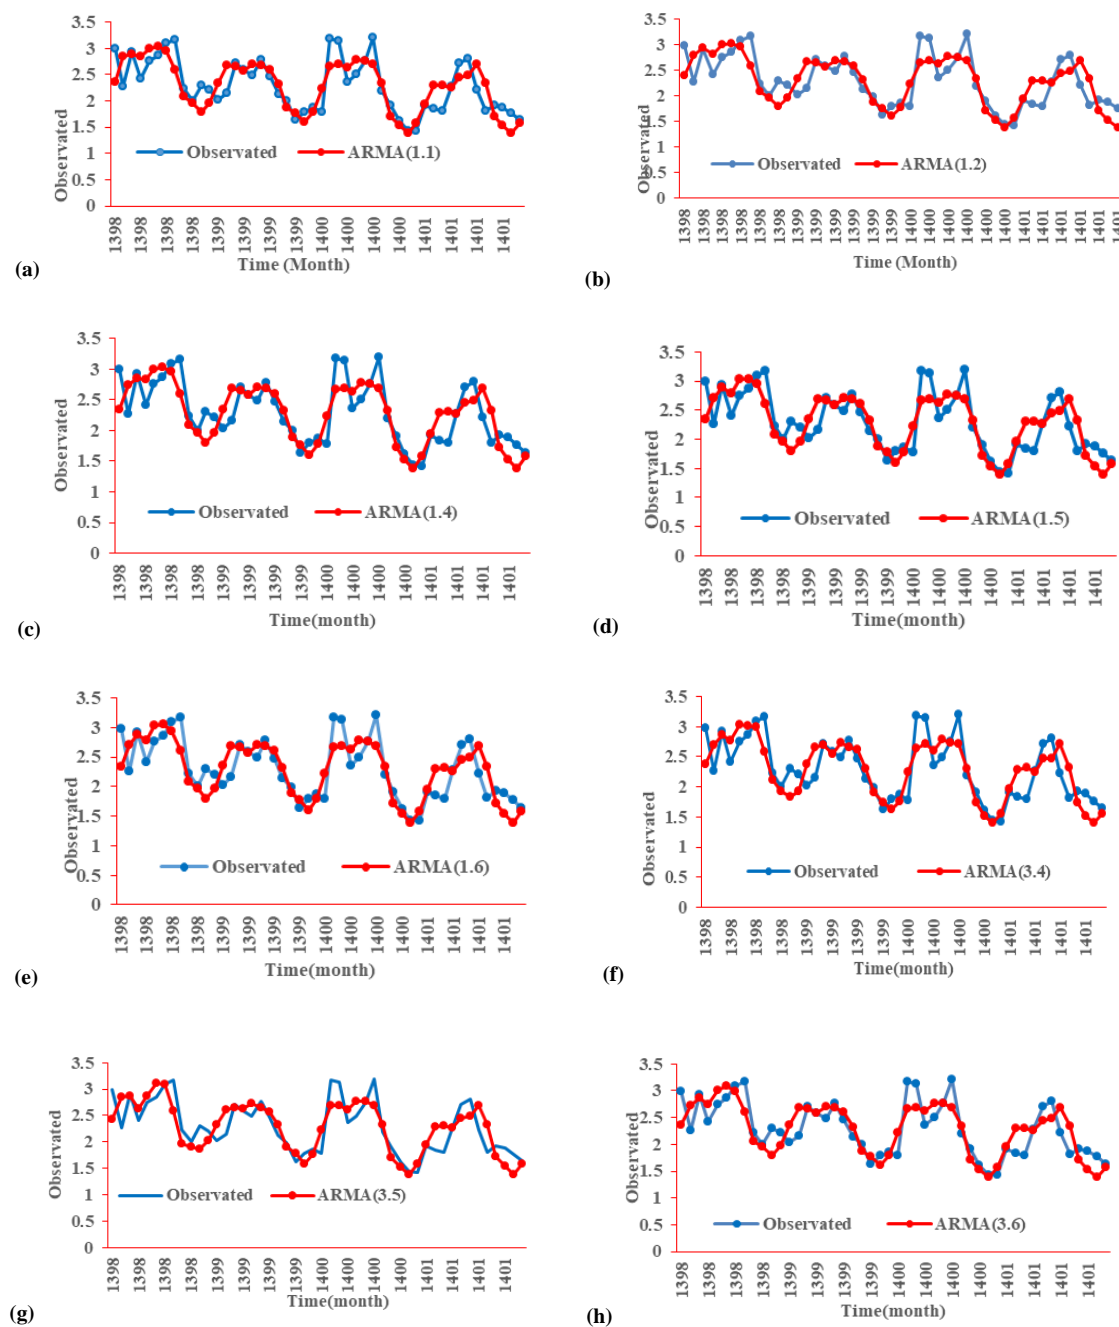


Figure 4. Simulated and observed discharge output of Majjaran Dam

همان‌طور که مشاهده می‌شود هر کدام از این مدل‌ها، تلاش می‌کنند تا الگوهای فصلی، روندی و تصادفی موجود در داده‌ها را بازسازی نمایند. با این حال، ارزیابی دقیق‌تر باقیمانده‌های هر مدل نشان داد که تنها در مدل برتر $ARMA(3,2)$ است که رفتار باقیمانده‌ها مطابق با یک فرایند نویز سفید می‌باشد. به عبارت دیگر، تابع خودهمبستگی (ACF) و تابع خودهمبستگی جزئی (PACF) باقیمانده‌های این مدل، فاقد هرگونه الگوی معنی‌دار بود و نتایج آزمون لیونگ-باکس

(Ljung-Box test) نیز عدم وجود خودهمبستگی در باقیمانده‌ها را تأیید کرد ($P\text{-value} > 0.05$). این موضوع نشان‌دهنده آن است که مدل انتخاب‌شده به خوبی توانسته تمامی ساختار و وابستگی‌های زمانی موجود در داده‌ها را استخراج کند و هیچ اطلاعات دیگری در باقیمانده‌ها برای مدل‌سازی باقی نمانده است. از سوی دیگر، مدل‌هایی با مرتبه‌های پایین‌تر (مانند $ARMA(1,1)$) نتوانستند وابستگی‌های بلندمدت در داده‌ها را به‌طور کامل حذف کنند (که در مقادیر بالاتر AIC و همبستگی پایین‌تر مشهود است). در مقابل، مدل‌هایی با مرتبه‌های بسیار بالا (مانند $ARMA(3,6)$) اگرچه ممکن بود بر روی داده‌های آموزشی انطباق ظاهری بهتری نشان دهند، اما با توجه به افزایش معیار AIC و خطر بیش‌برازش، برای پیش‌بینی‌های آینده قابل اطمینان نبودند. بنابراین، مدل $ARMA(3,2)$ به‌عنوان نقطه تعادلی بهینه بین سادگی مدل (اصل پارسیمونی) و دقت برازش شناسایی گردید. لذا، با استناد به ارزیابی هم‌زمان معیارهای اطلاعاتی (AIC)، تحلیل دقیق مشخصه‌های آماری باقیمانده‌ها و رعایت اصل پارسیمونی، مدل نهایی جهت شبیه‌سازی و پیش‌بینی سری زمانی داده‌های دبی ماهانه ایستگاه سد میجران، مدل $ARMA(3,2)$ انتخاب شد.

براساس نتایج ارائه‌شده در شکل (۴)، مدل $ARMA(3,2)$ با ضریب تبیین 0.79 و معادله رگرسیون $y = 1.0199x - 0.4788$ همسویی قابل‌توجهی با مقادیر مشاهداتی از خود نشان می‌دهد. تمرکز نقاط حول خط $y = x$ در نمودار پراکنش و توانایی مدل در بازتولید الگوهای پیچیده‌ای چون نوسانات فصلی و تغییرات ناگهانی، گویای دقت عملیاتی بالای این مدل است. در مقابل، مدل‌های ساده‌تری نظیر $ARMA(1,1)$ و $ARMA(1,2)$ از کاستی‌های آشکاری در شبیه‌سازی رفتار داده‌ها رنج می‌برند. این یافته‌ها با نتایج پژوهش‌های پیشین همسو است. به‌عنوان مثال، Malakoutian et al. (2022) در مطالعه رودخانه‌های فصلی قبرس از مدل‌های خودرگرسیوی (AR) با مرتبه‌های مختلف استفاده کردند و نشان دادند که انتخاب مدل براساس معیار AIC و تحلیل باقیمانده‌ها منجر به پیش‌بینی قابل اطمینان جریان در شرایط عدم قطعیت می‌شود. همچنین Soleimani Motlagh et al. (2017) در مطالعه خشک‌سالی هیدروژئولوژیکی در دشت الشتر، از مدل‌های مختلف $ARMA$ در خوشه‌های مختلف استفاده کردند و نشان دادند که مدل بهینه در هر خوشه بسته به ویژگی‌های آماری داده‌ها متفاوت است. به‌طوری‌که، در خوشه چهارم مدل $ARMA(2,2)$ و در خوشه پنجم مدل $AR(2)$ به‌عنوان مدل بهینه انتخاب شدند. این موضوع تأیید می‌کند که انتخاب مدل می‌باید براساس ویژگی‌های محلی داده‌ها و با استفاده از معیارهای علمی مانند AIC و تحلیل باقیمانده‌ها صورت پذیرد. علاوه بر این، Mirzavand and Ghazavi (2015) و Padilla et al. (1996) نیز بر کارایی مدل‌های $ARMA$ در محیط‌های با داده‌های محدود و شرایط هیدرولوژیکی پیچیده تأکید کرده‌اند. در پژوهش حاضر نیز مدل $ARMA(3,2)$ با دارا بودن پایین‌ترین مقدار AIC و بالاترین ضریب تبیین، به‌عنوان نقطه تعادلی بهینه بین سادگی مدل و دقت برازش شناخته شد که این امر با اصول «پارسیمونی» در مدل‌سازی سازگار است. در نهایت، می‌توان نتیجه گرفت که انتخاب مدل $ARMA(3,2)$ در این پژوهش نه تنها از پشتوانه آماری قوی برخوردار است، بلکه با یافته‌های پژوهش‌های معتبر در حوزه هیدرولوژی و مدل‌سازی سری‌زمانی همخوانی کامل دارد.

۴. نتیجه‌گیری

مدیریت بهینه منابع آب در حوزه‌های آبریز، مستلزم درک دقیق و قابل اطمینان از رفتار جریان رودخانه‌هاست. این مطالعه با کاربرد مدل‌سازی سری‌زمانی غیرقطعی، نشان داد که مدل $ARMA(3,2)$ می‌تواند به‌عنوان ابزاری قدرتمند و در عین حال مقرون‌به‌صرفه برای شبیه‌سازی دبی جریان در پایین‌دست سد میجران عمل کند. دقت قابل قبول این مدل، پتانسیل بالایی برای تبدیل شدن به یک سامانه پشتیبان تصمیم‌گیری در عملیات بهره‌برداری از سد ایجاد می‌کند. این پیش‌بینی‌ها پیامدهای مستقیم و ملموسی در مدیریت منابع آب منطقه خواهد داشت. از جمله می‌توان به برنامه‌ریزی

دقیق‌تر برای تخصیص آب کشاورزی ۱۵۰۰ هکتار از اراضی پایین‌دست اشاره کرد که می‌تواند از بروز تنش‌های آبی در فصل زراعی جلوگیری کند. همچنین این مدل امکان بهینه‌سازی عملیات بهره‌برداری از سد را فراهم می‌آورد، به طوری که می‌توان برای ذخیره‌سازی یا رهاسازی آب با توجه به پیش‌بینی‌های جریان، برنامه‌ریزی نمود. علاوه بر این، مدل ارائه شده می‌تواند در پایش خشک‌سالی و مدیریت بحران نیز نقش ایفا کند، چرا که شناسایی روندهای کاهشی بلندمدت در جریان می‌تواند به‌عنوان هشدار اولیه‌ای برای مواجهه با دوره‌های خشک‌سالی مورد استفاده قرار گیرد. با وجود موفقیت مدل حاضر، پیچیدگی سامانه‌های هیدرولوژیکی ایجاب می‌کند که گام‌های بعدی برای افزایش دقت و قابلیت اطمینان پیش‌بینی‌ها برداشته شود. در این راستا، توسعه مدل‌های هیبریدی که توانایی مدل‌های غیرقطعی را با قدرت مدل‌های هوش مصنوعی مانند شبکه‌های عصبی مصنوعی یا ماشین بردار پشتیبان ترکیب می‌کنند، می‌تواند راه‌کار مناسبی باشد. همچنین ادغام متغیرهای اقلیمی مانند بارش، دما و تبخیر-تعرق در چارچوب مدل‌های ARMAX یا مدل‌های مبتنی بر یادگیری ماشین، می‌تواند به پیش‌بینی‌های بااهمیت‌تر و با دید بلندمدت‌تر منجر شود. با توجه به این‌که پارامترهای هیدرولوژیکی ممکن است در طول زمان به‌دلیل تغییرات اقلیمی یا تغییر کاربری اراضی تغییر کنند، استفاده از مدل‌های به‌روز که پارامترهای آن‌ها به‌طور پیوسته با داده‌های جدید به‌روز می‌شوند، می‌تواند راه‌کار مناسبی برای حفظ دقت مدل در بلندمدت باشد. در مجموع، این پژوهش نقش مؤثر مدل‌های غیرقطعی ساده را به‌عنوان پایه‌ای مستحکم برای تصمیم‌گیری‌های مدیریت آب تأیید می‌کند و این مدل نه‌تنها به بهبود مدیریت منابع آب در حوضه سد میجران منجر خواهد شد، بلکه می‌تواند به‌عنوان الگویی برای سایر حوضه‌های آبریز کشور با شرایط مشابه نیز مورد استفاده قرار گیرد.

۵. پی‌نوشت‌ها

1. Seasonal Autoregressive Integrated Moving Average
2. Periodic Auto-regressive Moving Average
3. Auto-regressive
4. Moving Average
5. Auto-regressive Moving Average
6. Auto-regressive Integrated Moving Average
7. Kwiatkowski-Phillips-Schmidt-Shin
8. Auto-Correlation Function
9. Partial Auto-Correlation Function
10. Akaike Information Criterion

۶. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷. منابع

- Abdollahnejad Kamel, A. (2015). Time series models in forecasting monthly rainfall (Case study: Hashemabad station, Gorgan). *Geographical Space Planning*, 5(17), 15-25. (In Persian).
- Adamowski, J., & Chan, H. F. (2011). A comparison of artificial neural network and time series models for forecasting daily water levels at hydrological monitoring stations. *Water Quality Research Journal of Canada*, 46(2), 175-185.
- Alizadeh, A. A. (2011). *Principles of applied hydrology* (32nd ed.). Imam Reza University Press. (In Persian).
- Azizi, G. (2005). Investigation of droughts, wet periods, and the possibility of their prediction using time series model in Hormozgan Province. *Geographical Research Quarterly*, 79, 48-61. (In Persian).

- Box, G. E. P., & Jenkins, G. M. (1976). *Time series analysis: Forecasting and control* (2nd ed.). Holden-Day.
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (1994). *Time series analysis: forecasting and control* (3rd ed.). Prentice Hall.
- Burlando, P., Montana, A., & Raze, R. (1996). Forecasting of storm rainfall by combined use of radar, rain gages and linear models. *Atmospheric Research*, 42, 199-211.
- Cryer, J. D. (1992). *Time series analysis* (H. A. Niroomand, Trans.). Mashhad University Publication. (In Persian).
- Dastorani, M., Mirzavand, M., Dastorani, M. T., & Sadatnejad, S.J. (2016). Comparative study among different time series models applied to monthly rainfall forecasting in semi-arid climate condition. *Natural Hazards*, 81, 1811-1827. <https://doi.org/10.1007/s11069-016-2163-x>
- Dodangeh, A., Abedi Koupai, J., & Gohari, S. A. (2012). Application of time series modeling to investigate future climatic parameters trend for water resources management purposes. *Journal of Water and Soil Science*, 16(59), 59-74. (In Persian). <http://jstnar.iut.ac.ir/article-1-2198-fa.html>
- Erdem, E., & Shi, J. (2011). ARMA-based approaches for forecasting the tuple of wind speed and direction. *Applied Energy*, 88(4), 1405-1414. <https://doi.org/10.1016/j.apenergy.2010.10.031>
- Faruk, D. (2010). A hybrid neural network and ARIMA model for water quality time series prediction. *Engineering Applications of Artificial Intelligence*, 23(4), 586-594. <https://doi.org/10.1016/j.engappai.2009.09.015>
- Fouladmand, H. (2010). Monthly evaporation–transpiration prediction using artificial neural network in Fars agricultural stations. *Journal of Water and Soil Science*, 20(1), 157-169. (In Persian).
- Ghahreman, N., & Gharekhani, A. (2011). Evaluation of random time series models in estimating pan evaporation (case study: Shiraz station). *Journal of Water Research in Agriculture*, 25(1), 75-81. (In Persian). <https://sid.ir/paper/196848/fa>
- Hannan, E. J. (1971). *Multiple time series*. Wiley.
- Hejabi, S., & Bazrafshan, J. (2013). Evaluation of six types of stochastic models skill in modeling and forecasting the standardized precipitation index time series. *Journal of Water Research in Agriculture*, 27(3), 429-454. (In Persian). <https://doi.org/10.22092/jwra.2013.128847>
- Hipel, K. W., & McLeod, A. I. (1994). *Time series modeling of water resources and environmental systems*. Elsevier.
- Hisdal, H., & Tallaksen, L. M. (2003). Estimation of regional meteorological and hydrological drought characteristics: a case study for Denmark. *Journal of Hydrology*, 281(3), 230-247.
- Kersik, N. (2001). *Hydrogeology and groundwater modeling to solve problems* (M. Chitchian & H. A. Kashkooli, Trans.). Shahid Chamran University Press. (In Persian).
- Khalili, K., Fakhri-Fard, A., & Hessari, B. (2007). Analysis of intensity-duration-frequency curves, drought frequency and reservoir design for agriculture and drinking water. In *Proceedings of the 3rd National Congress on Civil Engineering University of Tabriz*, Tabriz, Iran. (In Persian).
- Laux, P., Vogl, S., Qiu, W., Knoche, H. R., & Kunstmann, H. (2011). Copula-based statistical refinement of precipitation in RCM simulations over complex terrain. *Hydrology and Earth System Sciences*, 15, 2401-2419.
- Malakoutian, M. M. A., Samaei, S. Y., Khaksar, M., & Malakoutian, Y. (2022). A prediction of future flows of ephemeral rivers by using stochastic modeling (AR autoregressive modeling). *Sustainable Operations and Computers*, 3, 330–335. <https://doi.org/10.1016/j.susoc.2022.05.003>
- Mirzavand, M., & Bagheri, R. (2020). The water crisis in Iran: Development or destruction? *World Water Policy*, 00, 1–9. <https://doi.org/10.1002/wwp2.12023>
- Mirzavand, M., & Ghazavi, R. (2015). A stochastic modelling technique for groundwater level forecasting in an arid environment using time series methods. *Water Resources Management*, 29, 1315–1328. <https://doi.org/10.1007/s11269-014-0875-9>
- Mousavi, S., Banihabib, M., & Bandari, R. (2011). Prediction of daily inflow to dam reservoir using time series models. In *Proceedings of the 15th National Seminar on Irrigation and Evaporation Reduction*. Kerman, Iran. (In Persian).
- Padilla, A., Pulido-Bosch, A., Cavache, M., & Vallejos, A. (1996). The ARMA model applied to the flow of Karst Spring. *Water Resources Bulletin*, 32, 917-928.
- Rezanejad Keshteli, M., Babanezhad, M., & Amini, A. (2016). Fitting the seasonal time series model to the rivers discharge in time domain (Case study: Atrak River). *Journal of Water and Soil Conservation*, 22(6), 307-315. (In Persian). <https://doi.org/20.1001.1.23222069.1394.22.6.20.2>

- Sabaghian, R., & Sharifi, M. B. (2009). The use of stochastic models in river flow simulation and prediction of annual average river discharge using time series analysis. In *Proceedings of the First International Conference on Water Resources Management*. Shahroud University of Technology, Shahroud, Iran. (In Persian).
- Sabzevary, Y., & Abedi Koupaei, J. (2022). Trend and time series analysis of reference evapotranspiration (Case study: Khorram Abad Plain). *Extension and Development of Watershed Management*, 10(37), 35-46. (In Persian).
- Sabziparvar, A. A., Mokhtari, B., Sadeghifar, M., Saghai, S., Ershad-Fath, F., & Norouz-Valashedi, R. (2014). Estimation of daily pan evaporation using time series models. *Watershed Engineering and Management Journal*, 6(1), 42-51. (In Persian).
- Salas, J. D. (1993). Analysis and modeling of hydrological time series. In D. R. Maidment (Ed.), *Handbook of hydrology*. McGraw-Hill.
- Shirmohammadi, B., Vafakhah, M., Moosavi, V., & Moghaddamnia, A. (2013). Application of several data-driven techniques for predicting groundwater level. *Water Resources Management*, 27, 419-432. <https://doi.org/10.1007/s11269-012-0194-y>.
- Thomas, H. A., & Fiering, M. B. (1962). *Mathematical synthesis of stream flow sequences for the analysis of river basin by simulation*. Harvard University Press.
- Soleimani Motlagh, M., Ghasemieh, H., Talebi, A., & Abdollahi, K. (2017). Identification and Analysis of Drought Propagation of Groundwater During Past and Future Periods. *Water Resources Management*, 31, 109-125. <https://doi.org/https://doi.org/10.1007/s11269-016-1513-5>
- Thompson, R. M., Hipel, K. W., & McLeod, A. I. (1985). Forecasting quarter-monthly river flow. *Water Resources Bulletin*, 21, 731-741.
- Tsonis, A. A. (2001). Probing the linearity and nonlinearity in the transitions of the atmospheric circulation. *Nonlinear Processes in Geophysics*, 8, 341-345.
- Wang, W., Van Gelder, P. H., Vrijling, J. K., & Ma, J. (2005). Testing and modeling autoregressive conditional heteroskedasticity of streamflow processes. *Nonlinear Processes in Geophysics*, 12, 55-66.
- Yaseen, Z. M., El-Shafie, A., Jaafar, O., Afan, H. A., & Sayl, K. N. (2015). Artificial intelligence-based evapotranspiration models: A review. *Water Resources Management*, 29(7), 2587-2611.
- Yurekli, K., Kurung, A., & Ozturk, F. (2005). Testing the residuals of an ARIMA model on the Cekerek stream watershed in Turkey. *Turkish Journal of Environmental Science*, 29, 61-74.