

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

الهام فیض آبادی^۱، محمد میرزavand^{۲*}

۱- دانشجوی کارشناسی ارشد مهندسی طبیعت، گروه علوم و فناوری‌های محیطی، دانشکده مهندسی انرژی و منابع پایدار، دانشگاه تهران، تهران، ایران

۲- استادیار گروه علوم و فناوری‌های محیطی، دانشکده مهندسی انرژی و منابع پایدار، دانشگاه تهران، تهران، ایران

چکیده

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 پایین‌دست 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 $144/06$ 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 به عنوان ابزاری کارآمد در تصمیم‌گیری‌های مدیریت منابع آب مورد استفاده قرار گیرد.

کلمات کلیدی: خودهمبستگی، خودهمبسته میانگین متحرک، دبی، مدل غیرقطعی

Simulation of Downstream Flow Discharge at Maijaran Dam Using Stochastic Models

Elham Feizabadi¹| Mohammad Mirzavand^{2*}

1- Master Student of Nature Engineering, School of Energy Engineering and Sustainable Resources, College of Interdisciplinary Science and Technology, University of Tehran, Tehran, Iran

2- Assistant Professor, School of Energy Engineering and Sustainable Resources, College of Interdisciplinary Science and Technology, University of Tehran, Tehran, Iran

Abstract

* MMirzavand@ut.ac.ir

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 Maijara Dam in Mazandaran Province, using monthly discharge data from the Maijara 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.

Keywords: ARMA, Autocorrelation, Discharge, Stochastic Model

۱. مقدمه

کمبود منابع آبی یکی از چالش‌های جدی پیش‌روی بشر محسوب می‌شود که پیامدهای آن نه تنها 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 & 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 & 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 ۱۳۷۹ تا ۱۴۰۳، حدود ۲۲۷ میلی‌متر است رقمی که کمتر از یک‌سوم میانگین جهانی محسوب می‌شود. در نتیجه، مسئله کمبود آب به عنوان 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 قابل توجهی در بهینه‌سازی استفاده از ذخایر آبی و کاهش خسارات مربوط به حوادث طبیعی مرتبط با آب دارد (Yaseen *et al.*, 2015). مدل‌های غیرقطعی با توجه به قابلیت تطبیق پذیری 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 & 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 آنکه 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 & Ghazavi, 2015; Mirzavand & Ghazavi, 2015; Chan, 2011). سهولت اجراء همراه با نیاز حداقلی به داده‌ها، باعث شده این مدل‌ها به ویژه در مناطقی با اطلاعات ناکافی، کارایی قابل توجهی از خود نشان دهند (Box *et al.*, 1976). تحلیل سری‌های زمانی عمدتاً با دو هدف اصلی شامل شناخت

و مدل‌سازی فرآیندهای 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 محققان محسوب می‌شوند (Thomas & Fiering, 1962). پس از آنها مطالعات متعددی انجام گرفت که می‌توان به تحقیقات (Hipel & McLeod, 1994) و (Thompstone et al., 1985) و (wang et al., 2005) و (Yurekli et al., 2005) اشاره کرد. شاید بتوان اولین گام مؤثر در به‌کارگیری عملی روش‌های سری‌های زمانی در هیدرولوژی را به مک‌کرچار و دولر نسبت داد. این محققان با توجه به رفتار فصلی پارامترهای هیدرولوژیکی، از مدل‌های $SARIMA^1$ و $PARMA^2$ برای مدل‌سازی دبی رودخانه‌ها استفاده کردند (Laux et al., 2011). در مقایسه با نمونه‌های تصادفی مستقل، داده‌های سری‌های زمانی دارای خودهمبستگی بوده و این ویژگی وابستگی زمانی، هسته اصلی روش‌های پیش‌بینی در مطالعات سری‌های زمانی محسوب می‌شود (Abdollahnejad Kamel, 2015). مدل‌های سری‌های زمانی 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 سری‌های زمانی، مدل‌های خودهمبسته (AR^3)، میانگین متحرک (MA^4)، ترکیب خودهمبسته-میانگین متحرک ($ARMA^5$) و خودهمبسته-میانگین متحرک تجمعی ($ARIMA^6$) بیشترین استفاده را در پژوهش‌های هیدرولوژیکی دارند (Tsonis, 2001; Dastorani et al., 2016). در زمینه مدل‌های خطی سری‌های زمانی، مطالعات مختلفی انجام گرفته است (Fouladmand, 2010; Khalili et al., 2007; Sabaghian & Sharifi, 2009; Sabziparvar et al., 2014; Mousavi et al., 2011). Padilla et al. (1996) مدل‌های استوکاستیک $ARMA$ را برای 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 فرآیندهای 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 تامین آب مورد نیاز ۱۵۰۰ هکتار از اراضی کشاورزی و فعالیت‌های صنعتی پایین‌دست سد میجران، هدف از این مطالعه، شبیه‌سازی دبی جریان پایین‌دست این سد واقع در استان مازندران با استفاده از مدل‌های غیرقطعی در نرم‌افزار R می‌باشد. مهم‌ترین تمایز این پژوهش با مطالعات پیشین، در نظریه همزمان مولفه‌های طبیعی (دبی) و اثرات مدیریتی (خروجی سد) در مدل‌سازی سری‌های زمانی است که منجر به شبیه‌سازی واقعی‌تر و کاربردی‌تری از جریان پایین‌دست خواهد شد.

۲. مواد و روش‌ها

۱.۲. منطقه‌ی 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، درفاصله ۲۰

کیلومتری رامسر، روی رودخانه نسا رود قرار دارد. سد میجران در اسفند ماه سال ۱۳۸۲ به منظور تامین آب زراعی منطقه به میزان ۱۵۰۰ هکتار، توسعه و تقویت صنعت گردشگری و تامین 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.




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

۲.۲. داده‌های مورد استفاده

داده‌های مورد استفاده در این پژوهش شامل مقدار دبی ماهانه بر حسب 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.

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 بر اساس توالی زمانی مرتب شده‌اند، عموماً با روابط ریاضی مانند رابطه (۱) قابل نمایش هستند.

رابطه ۱)

$$X_{t_1}, X_{t_2}, \dots, X_{t_n}$$

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 بر اساس ویژگی‌های سری مشاهداتی است. در زیر، روابط مورد استفاده در مدل‌های مختلف غیرقطعی بررسی شده در این پژوهش ارائه شده است.

۱.۳.۲ 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 $\varphi_1, \varphi_2, \dots, \varphi_p$ 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 $\theta_1, \theta_2, \dots, \theta_p$ ضرایب و پارامترهای مدل هستند و a_t بخش تصادفی داده‌ها می‌باشد که دارای توزیع نرمال با میانگین صفر است (Hannan, 1971).

۳.۳.۲ مدل خودهمبسته-میانگین متحرک

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

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

که در آن δ مقدار ثابت مدل ARMA، φ_i ضریب i ام خودهمبستگی، φ_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 & Shi, 2011).

۴.۳.۲ مدل خودهمبسته-میانگین متحرک یکپارچه و میانگین متحرک خودهمبسته یکپارچه فصلی

مدل‌های خودرهمبسته-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 فرآیند 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 $(P, D, Q)s$ ARIMA(p, d, q) توضیح داد، که در آن (p, d, q) بخش غیرفصلی مدل و (P, D, Q)s بخش فصلی مدل است؛ به‌طوری 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).

۴.۲. آماده‌سازی داده‌ها و بررسی مدل‌های اولیه

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 ایستا بودن سری‌های زمانی داده‌های مورد استفاده است. لذا در این پژوهش، جهت بررسی نرمال بودن داده‌ها، با توجه به اینکه تعداد داده‌ها از ۵۰ عدد بیشتر بود (۱۹۲ داده)، از آزمون کلموگروف-اسمیرنوف در نرم‌افزار Minitab استفاده شد. در صورتی که مقدار p-value بدست 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 اینکه داده‌های مورد بررسی نرمال نبودند، قبل از اینکه 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 (KPSS⁷) در محیط برنامه R استفاده شد. در این آزمون نیز در صورتی که مقدار p-value بدست آمده از این آزمون بیشتر از پنج صدم باشد، داده‌ها ایستا می‌باشند، در غیر این صورت، داده‌ها ایستا نبوده و نیاز به ایستا کردن سری‌های زمانی (عمدتاً با تفاضل‌گیری) قبل از هرگونه مدل‌سازی می‌باشد. همچنین به منظور بررسی روند در سری‌های 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 مثبت یک و نود و شش صدم تا منفی یک و نود و شش صدم باشد، سری فاقد روند است.

۴.۲.۲. انتخاب مدل اولیه

قبل از شروع مدل‌سازی سری‌زمانی، نیاز است تا مدل‌ساز مدل‌هایی که احتمال بیشتری دارد جواب بهتری در مدل‌سازی بدهند را شناسایی کند. برای این منظور، از تابع خودهمبستگی⁽⁸⁾ (ACF) و تابع خودهمبستگی جزئی⁽⁹⁾ (PACF) استفاده شد. در صورتی که تابع ACF به صورت 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 به صورت 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 به صورت تدریجی کاهش یابند (بدون قطع شدن واضح)، نیاز به مدل‌های ترکیبی مانند ARMA می‌باشد و معمولاً از معیارهای اطلاعاتی (مثل AIC/BIC^{10}) 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. و نهایتاً اگر الگوهای فصلی در ACF/PACF با تأخیرهای مضرب s (مثلاً ۱۲ برای داده‌های ماهانه) ظاهر شوند، از مدل SARIMA استفاده می‌شود.

۲.۴.۲. تفکیک بخش‌های قطعی و غیرقطعی سری زمانی

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

۳.۴.۲. 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 معنادار در هریک از نمودارهای ذکرشده محدوده تغییرات مرتبه مدل را نشان داده و در نهایت 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 & Gharehkhani (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، به ترتیب مرتبه‌های q و p مدل انتخاب می‌شود.

۴.۴.۲. 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 به عنوان مدل برتر انتخاب می‌شوند. معیار AIC را می‌توان به صورت رابطه (۵) بیان کرد:

$$AIC(k) = \ln(MSE) + 2K$$

رابطه (۵)

در این رابطه، n تعداد داده‌های مورد استفاده (برای واسنجی مدل) و k تعداد پارامترهای آزاد به کار رفته در مدل را نشان می‌دهد. MSE نیز برابر با میانگین مربعات خطا است. به طور 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 به دست‌آمده از تجزیه سری‌زمانی برای بهبود دقت پیش‌بینی استفاده شده است. این مؤلفه که نشان‌دهنده نویزها و عدم قطعیت در داده‌ها است، به عنوان بخشی از مدل‌سازی در نظر گرفته شد تا الگوهای پنهان و تأثیرات غیرقابل پیش‌بینی را در فرآیند 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 (پنج صدم $p\text{-value}$). با توجه به بررسی‌های صورت گرفته در نرم‌افزار Minitab، مشخص شد که داده‌ها از تابع انتقال جانسون پیروی می‌کنند، لذا با استفاده از تابع بدست آمده، داده‌ها نرمال شدند (پنج صدم $p\text{-value}$). همچنین با توجه به نتایج حاصل از بررسی ایستایی داده‌ها در برنامه R، مقدار $p\text{-value}$ بدست آمده برای

آزمون KPSS بیشتر از پنج صدم بدست 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 بدست آمده و توضیحات ارائه شده در بخش روش کار، 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 یک، دو، چهار، پنج و شش به عنوان 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 یک و سه به عنوان مرتبه‌های اولیه مناسب برای بخش p مدل ARMA در نظر گرفته شدند. بنابراین با توجه به شرایط حاکم بر سری زمانی داده‌ها و نتایج بدست آمده از تابع ACF و PACF، در این تحقیق برای مدل‌سازی داده‌های دبی روزانه از روش ARMA غیرفصلی در قالب بررسی ۱۱ مدل با ترکیب $ARMA(1, 2)$ ، $ARMA(1, 1)$ ، $ARMA(1, 4)$ ، $ARMA(1, 5)$ ، $ARMA(1, 6)$ ، $ARMA(3, 1)$ ، $ARMA(3, 2)$ ، $ARMA(3, 4)$ ، $ARMA(3, 5)$ 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 کمتر باشد مدل بهینه خواهد بود. با توجه به نتایج بدست آمده (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 & Ghazavi, 2015).

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

مدل	مقادیر		AIC	R^2
	پارامتر	پارامترهای مدل		
$ARMA(1,1)$	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		
	φ_1	0.34		
ARMA(3,2)	φ_2	0.55	144.06	0.79
	φ_3	-0.43		
	θ_1	-0.19		
	θ_2	-0.80		
	φ_1	0.11		
	φ_2	0.64		
ARMA(3,4)	φ_3	-0.42	147.41	0.79
	θ_1	0.03		
	θ_2	-0.84		
	θ_3	-0.07		
	θ_4	-0.10		
	φ_1	0.88		
	φ_2	-1.00		
ARMA(3,5)	φ_3	0.34	143.31	0.80
	θ_1	-0.75		
	θ_2	0.76		
	θ_3	-0.45		
	θ_4	-0.17		
	θ_5	-0.37		
	φ_1	0.03		
	φ_2	-0.11		
ARMA(3,6)	φ_3	-0.32	150.01	0.79
	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 هفتاد و نه صدم و همچنین کمترین مقدار معیار آکائیک (AIC) برابر با $144/06$ بود. نتایج حاصل از شبیه‌سازی سری زمانی دبی ایستگاه هیدرومتری سد میجران بر اساس 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. 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 فرآیند نویز سفید می‌باشد. به عبارت دیگر، تابع خودهمبستگی (ACF) و تابع خودهمبستگی جزئی (PACF) باقیمانده‌های این مدل، فاقد هرگونه الگوی معنادار بود و نتایج آزمون لیونگ-باکس (Ljung-Box test) نیز عدم وجود خودهمبستگی در باقیمانده‌ها را تایید کرد (پنج صدم $p\text{-value} >$). این موضوع نشان‌دهنده آن است که مدل انتخاب شده 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 به طور 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 $ARMA(3,2)$ به عنوان 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 سری‌زمانی داده‌های دبی ماهانه ایستگاه سد میجران، مدل $ARMA(3,2)$ انتخاب شد.






Figure 4. Simulated and observed discharge output of Maijarian Dam

بر اساس نتایج ارائه شده در شکل (۴)، مدل $ARMA(3,2)$ با ضریب تبیین هفتاد و نه صدم و معادله رگرسیون $y=1.0199x-0.4788$ همسویی قابل توجهی با مقادیر مشاهداتی از خود نشان می دهد. تمرکز نقاط حول خط $y=x$ در نمودار پراکنش و توانایی مدل در بازتولید الگوهای پیچیده ای چون نوسانات فصلی و تغییرات ناگهانی، گویای دقت عملیاتی بالای این مدل است. در مقابل، مدل های ساده تری نظیر $ARMA(1,1)$ و $ARMA(1,2)$ از کاستی های آشکاری در شبیه سازی رفتار داده ها رنج می برند. این یافته ها با نتایج پژوهش های پیشین همسو است. به عنوان مثال، *Malakoutian et al.* (۲۰۲۲) در مطالعه رودخانه های فصلی قبرس از مدل های خودرگرسیوی (AR) با مرتبه های مختلف استفاده کردند و نشان دادند که انتخاب مدل بر اساس معیار AIC و تحلیل باقیمانده ها منجر به پیش بینی قابل اطمینان جریان در شرایط عدم قطعیت می شود. همچنین *Soleimani Motlagh et al.* (۲۰۱۷) در مطالعه خشکسالی هیدروژئولوژیکی در دشت الشتر، از مدل های مختلف ARMA در خوشه های مختلف استفاده کردند و نشان دادند که مدل بهینه در هر خوشه بسته به ویژگی های آماری داده ها متفاوت است. به طوری که، در خوشه چهار مدل $ARMA(2,2)$ و در خوشه پنجم مدل $AR(2)$ به عنوان مدل بهینه انتخاب شدند. این موضوع تأیید می کند که انتخاب مدل می بایست بر اساس

ویژگی‌های محلی داده‌ها و با استفاده از معیارهای علمی مانند AIC و تحلیل باقیمانده‌ها صورت پذیرد. علاوه بر این، Mirzavand (2015) و Padilla *et al.* (۱۹۹۶) 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، به عنوان 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 رودخانه‌ها است. این مطالعه با کاربرد مدل‌سازی سری‌زمانی غیرقطعی، نشان داد که مدل ARMA(3,2) می‌تواند به عنوان 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 به عنوان 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 به دلیل تغییرات اقلیمی یا تغییر کاربری اراضی تغییر کنند، استفاده از مدل‌های به روز که پارامترهای آنها به طور پیوسته با داده‌های جدید به روز می‌شوند، می‌تواند راهکار مناسبی برای حفظ دقت مدل در بلندمدت باشد. در مجموع، این پژوهش نقش مؤثر مدل‌های غیرقطعی ساده را به عنوان پایه‌ای مستحکم برای تصمیم‌گیری‌های مدیریت آب تأیید می‌کند و این مدل نه تنها به بهبود مدیریت منابع آب در حوضه سد میجران منجر خواهد شد، بلکه می‌تواند به عنوان 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 منافی 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., & et al. (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>
- Thompstone, 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.
-