

**Web site:**

<https://wsrcj.srbiau.ac.ir>

Email:

iauwsrj@srbiau.ac.ir
iauwsrj@gmail.com

Vol. 14
No. 4 (56)

Received:
2024-04-13

Accepted:
2025-01-26

Pages: 31-44

Evaluation of Stochastic Models in Predicting the Underground Water Level of Hamadan-Bahar Plain

Hamed Nozari^{1*}, Nadia Sedghnejad² and Sajjad Pouyanfar³

- 1) Associate Professor, Department of Water Science and Engineering, Faculty of Agriculture, Bu-Ali-Sina University, Hamedan.
2) PhD student, Department of Water Science and Engineering, Faculty of Agriculture, Bu-Ali-Sina University, Hamedan.
3) Master's degree, Department of Water Science and Engineering, Faculty of Agriculture, Bu-Ali-Sina University, Hamedan.
Corresponding author email: hanozari@yahoo.com

Abstract:

Background and Aim: Groundwater sources are considered to be one of the most important available sources of fresh water in the world. Today, due to the changes in weather, climate change, population increase and excessive withdrawals of underground water, these resources have faced a significant decrease. Considering that Iran is located in a dry and semi-arid region, the underground water level has undergone many changes in many areas. The level of underground water in Hamadan-Bahar plain area has also faced a significant decrease. Therefore, the prediction of underground water levels in Hamadan-Bahar plain and the management of effective factors in its reduction are the main goals of this research.

Method: In the first step, in this research, it was tried to predict the underground water level with the help of support vector machine integrated model with Simulated annealing algorithm (SVM-SA) using the rainfall values of 4 synoptic stations of Aghkahriz, Ekbatan Dam, Kooshkabad and Marianaj. The uncertainties of this model are also analyzed. In the next step, the precipitation values of the mentioned 4 synoptic stations were predicted for 5 years monthly and annually with the help of seasonal autocorrelated moving average (SARIMA) and autocorrelated moving average (ARIMA) models, and finally, using the predicted rainfall values, the underground water level was predicted monthly and annually using the SVM-SA model for 5 years.

Result: The estimated values of underground water level were analyzed with the help of SVM-SA model using the indices of explanation coefficient (R^2), root mean square error (RMSE) and Nash Sutcliffe coefficient (NSE). The results indicate that there is no significant difference between the performance of the model in predicting the underground water level in annual and monthly periods. But the SVM-SA model with Nash Sutcliffe coefficient of 0.993, root mean standard error of 0.417 and explanatory coefficient of 0.993 in the calibration period has been more accurate in monthly estimation of underground water level. In the next step, in order to achieve the best SARIMA and ARIMA models for predicting monthly and annual rainfall values, statistical indicators of coefficient of explanation (R^2), root mean square error (RMSE), mean standard error (SE) and goodness of fit (AIC) are used. Finally, by using the ranks of the selected models according to the evaluation indices for monthly and annual periods for Aghkahriz station, respectively SARIMA(3,0,1)*(1,0,1) and ARIMA(3,0,2), for Ekbatan dam station according to SARIMA(1,0,1)*(1,1,2) and ARIMA(3,1,3), for Kooshkabad station according to SARIMA(1,1,3)*(1,1,1) and ARIMA(2,0,3) and for Marianaj station by SARIMA(1,0,1)*(1,1,2) and ARIMA(3,0,2) respectively, rainfall values for 5 years in monthly and annually forecast it placed. Finally, using the forecasted rainfall values with the help of SARIMA and ARIMA models, the groundwater level was forecasted monthly and annually for the next 5 years using the SVM-SA model.

Conclusion: One of the important results of this study is the absence of a significant relationship between the decrease in rainfall and the sharp drop in groundwater in the Hamedan-Bahar plain. In fact, the results of this research indicate that the sharp drop in the underground water level is caused by the excessive extraction of these valuable resources.

Keywords: Artificial Intelligence, Support Vector Machine Model (SVM), Simulated annealing (SA), ARIMA, SARIMA



شاپا چاپی: ۲۲۵۱-۷۴۸۰
شاپا الکترونیکی: ۲۲۵۰-۷۴۰۰

نشریه حفاظت منابع آب و خاک

آدرس تارنما:

<https://wsrj.srbiau.ac.ir>

پست الکترونیک:

iawsrcj@srbiau.ac.ir
iawsrcj@gmail.com

سال چهاردهم

شماره ۴ (۵۶)

تاریخ دریافت:

۱۴۰۳/۰۱/۲۵

تاریخ پذیرش:

۱۴۰۳/۱۱/۰۷

صفحات: ۴۴-۳۱

ارزیابی مدل‌های استوکستیک در پیش‌بینی سطح آب زیرزمینی دشت همدان - بهار

حامد نوذری^{۱*}، نادیا صدق نژاد^۲ و سجاد پویان فر^۳

(۱) دانشیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان.
(۲) دانشجوی دکتری، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان.
(۳) کارشناسی ارشد، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان.
* ایمیل نویسنده مسئول: hanozari@yahoo.com

چکیده:

زمینه و هدف: ذخایر آب زیرزمینی از مهم‌ترین منابع قابل دسترس آب شیرین در جهان محسوب می‌شوند. امروزه با توجه به تغییرات آب و هوا، تغییر اقلیم، افزایش جمعیت و برداشت‌های بی‌رویه از آب‌های زیرزمینی، این منابع با کاهش قابل توجهی مواجه شده است. با توجه به اینکه ایران در منطقه خشک و نیمه‌خشک واقع شده است، در بسیاری از مناطق سطح آب زیرزمینی دستخوش تغییرات بسیاری قرار گرفته است. سطح آب زیرزمینی نیز در منطقه دشت همدان-بهار با کاهش قابل توجهی مواجه شده است. از این رو پیش‌بینی مقادیر سطح آب زیرزمینی در دشت همدان-بهار و مدیریت عوامل موثر در کاهش آن از اهداف اساسی این پژوهش می‌باشد.

روش پژوهش: در گام نخست، در این پژوهش سعی شد به کمک مدل تلفیقی ماشین بردار پشتیبان با الگوریتم تبرید شبیه‌سازی (SVM-SA) سطح آب زیرزمینی با استفاده از مقادیر بارش ۴ ایستگاه سینوپتیک آق‌کهریز، سد اکباتان، کوشک آباد و مریانج برآورد گردید و عدم قطعیت مدل SVM-SA نیز مورد تجزیه و تحلیل قرار گرفت. در گام بعد، مقادیر بارش ۴ ایستگاه سینوپتیک مذکور به مدت ۵ سال بصورت ماهانه و سالانه به کمک مدل‌های میانگین متحرک یکپارچه خودهمبسته فصلی (SARIMA) و میانگین متحرک یکپارچه خودهمبسته (ARIMA) مورد پیش‌بینی قرار گرفت و در نهایت با استفاده از مقادیر بارش پیش‌بینی شده، سطح آب زیرزمینی با استفاده از مدل SVM-SA به مدت ۵ سال به‌صورت ماهانه و سالانه مورد پیش‌بینی قرار گرفت.

یافته‌ها: مقادیر برآورد سطح آب زیرزمینی به کمک مدل SVM-SA با استفاده از شاخص‌های ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE) و ضریب نش ساتکلیف (NSE) مورد بررسی قرار گرفت. نتایج نشان داد که عملکرد مدل در پیش‌بینی سطح آب زیرزمینی در دوره‌های سالانه و ماهانه مناسب بوده و اختلاف معنی داری در نتایج پیش‌بینی ماهانه و سالانه وجود ندارد. اما مدل SVM-SA با ضریب نش ساتکلیف ۰،۹۹۳، جذر میانگین خطای استاندارد ۰،۴۱۷ و ضریب تبیین ۰،۹۹۳ در دوره واسنجی در برآورد ماهانه سطح آب زیرزمینی کمی دقت بالاتری داشته است. در گام بعد جهت دستیابی به بهترین مرتبه مدل SARIMA و ARIMA جهت پیش‌بینی مقادیر بارش ماهانه و سالانه از شاخص‌های آماری ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE)، میانگین خطای استاندارد (SE) و سنجش نیکویی برازش (AIC) استفاده شد. در نهایت با استفاده از مرتبه‌های مدل‌های منتخب با توجه به شاخص‌های ارزیابی برای دوره‌های ماهانه و سالانه برای ایستگاه‌های آق‌کهریز به ترتیب $(1,0,1) * SARIMA(3,0,1)$ و $ARIMA(3,0,2)$ ، ایستگاه سد اکباتان به ترتیب $(1,1,2) * SARIMA(1,0,1)$ و $ARIMA(3,1,3)$ ، برای ایستگاه کوشک آباد به ترتیب $(1,1,1) * SARIMA(1,1,3)$ و $ARIMA(2,0,3)$ و برای ایستگاه مریانج به ترتیب $(1,1,2) * SARIMA(1,0,1)$ و $ARIMA(3,0,2)$ ، مقادیر بارش برای ۵ سال بصورت ماهانه و سالانه مورد پیش‌بینی قرار گرفت. در نهایت با استفاده از مقادیر بارش پیش‌بینی شده به کمک مدل‌های SARIMA و ARIMA، سطح آب زیرزمینی با استفاده از مدل SVM-SA بصورت ماهانه و سالانه برای ۵ سال آینده مورد پیش‌بینی قرار گرفت.

نتیجه‌گیری: از نتایج مهم این مطالعه می‌توان به این نکته اشاره کرد که رابطه معنی‌داری بین کاهش بارش و افت شدید آب‌های زیرزمینی در دشت همدان-بهار وجود ندارد. در واقع نتایج این پژوهش حاکی از آن است که افت شدید سطح آب زیرزمینی در سال‌های اخیر ناشی از برداشت بی‌رویه از این منابع ارزشمند می‌باشد.

کلیدواژه‌ها: هوش مصنوعی، مدل ماشین بردار پشتیبان (SVM)، الگوریتم تبرید شبیه‌سازی (SA)، SARIMA، ARIMA

پیش‌بینی نیاز به اطلاعات دقیق آبخوان مشابه مدل‌های عددی ندارند. این مدل‌ها به اطلاعات وابسته به زمان که تغییرات سطح آبهای زیرزمینی را تحت تاثیر قرار می‌دهند شامل بارش، دما، برداشت از آبخوان نیاز دارند (Mirarabi et al., 2019). با این حال، از جمله معایب این مدل‌ها می‌توان به عملکرد ضعیف در موقعیت‌های پیچیده و مواجه با تعداد متغیرهای مستقل بسیار اشاره کرد (Nadiri et al., 2019). از سوی دیگر مدل‌های یادگیری ماشین (ML)، هوش مصنوعی (AI) و مدل‌های سری زمانی از جمله روش‌های رگرسیون پیچیده‌ای هستند که جهت جبران کاستی‌های مدل‌های رگرسیون ساده حضور یافتند. این مدل‌ها در رشته‌های مختلف مورد استفاده و ارزیابی قرار گرفتند که در مقایسه با مدل‌های رگرسیون ساده عملکرد خوبی را گزارش کردند (Arya Azar et al., 2023). از رایج‌ترین این مدل‌ها که مورد استفاده بسیاری از محققین می‌باشد می‌توان به مدل‌های شبکه عصبی (ANN)، سیستم‌های استنتاج عصبی فازی تطبیقی (ANFIS)، ماشین بردار پشتیبان (SVM) و الگوریتم‌های فراکاوشی مانند الگوریتم ژنتیک (GA)، بهینه‌سازی ازدحام ذرات (PSO) و تبرید شبیه‌سازی (SA) و مدل‌های خودهمبسته (AR)، میانگین متحرک (MA)، خود همبسته میانگین متحرک (ARMA)، میانگین متحرک خودهمبسته یکپارچه (ARIMA) و میانگین متحرک خودهمبسته یکپارچه (SARIMA) اشاره کرد (Nhu et al., 2020; Xu et al., 2020). در این میان، مدل ماشین بردار پشتیبان مدلی است که در هیدرولوژی و هیدروژئولوژی کاربرد بسیاری داشته است. این مدل بر اساس تئوری یادگیری آماری است که توانایی حداقل‌سازی ریسک ساختاری را دارا می‌باشد (Yuan, 2013). در واقع این مدل توانایی تعمیم کامل کمبودهای مدل شبکه عصبی مصنوعی را دارد (Pham et al., 2019). ترکیب این مدل با الگوریتم‌های فراکاوشی منجر به افزایش دقت و بهبود عملکرد شده است. برای مثال در مطالعه‌ای لیو و همکاران، مدل SVM و مدل SVM تلفیقی با تکنیک جذب داده‌ها (DA) برای پیش‌بینی تغییرات سطح آبهای زیرزمینی را برای ۴۶ چاه واقع در شمال شرق ایالات متحده مورد ارزیابی قرار دادند و دریافتند هر دو مدل SVM و SVM-DA می‌توانند با دقت مناسبی سطح آبهای زیرزمینی را پیش‌بینی کنند (Liu et al., 2021). آدرمی و همکاران در پژوهشی سطح آبهای زیرزمینی ۱۰ منطقه‌ی کارستی واقع در آفریقا را با استفاده از چند مدل یادگیری ماشین (ML) و هوش مصنوعی (AI)، مانند مدل‌های رگرسیون، مدل‌های خودکار رگرسیون عمیق و مدل شبکه‌های عصبی خود رگرسیون غیرخطی با ورودی خارجی (NARX) و مدل‌های SVM مورد پیش‌بینی قرار دادند. نتایج آن‌ها برتری مدل‌های SVM و

منابع آب‌های زیرزمینی بزرگترین ذخیره قابل دسترس آب شیرین در کره زمین می‌باشد، این منابع به‌ویژه در مناطق خشک و نیمه‌خشک به شدت تحت تاثیر تغییرات آب و هوا می‌باشد (Fathi et al., 2019; Javadi et al., 2021; Kayhomayoon et al., 2021). در بسیاری از مناطق، منابع آب‌های سطحی به سرعت در حال کاهش است و فشار بیشتری بر آب‌های زیرزمینی وارد می‌شود (Javadi et al., 2021). در مناطق کم‌آب، مدیریت صحیح این ذخایر ارزشمند شناسایی، مدل‌سازی و پیش‌بینی تغییرات سطح آب‌های زیرزمینی جهت برنامه‌ریزی بلندمدت و استفاده بهینه‌تر و پایدارتر از پتانسیل‌های آبی موجود ضروری می‌باشد (Kardan Moghaddamet al., 2021; Kayhomayoon et al., 2021). با توجه به اینکه ایران در منطقه خشک و نیمه‌خشک واقع شده است، این عامل باعث شده که بارش سالانه حدود یک سوم بارش سالانه جهان باشد، کاهش این میزان بارندگی منجر به محدود شدن رواناب‌های فصلی و دائمی شده است، از این رو آب‌های موجود در آبخوان در این کشور از اهمیت به‌سزایی برخوردار می‌باشد. استان همدان نیز یکی از استان‌هایی است که با توجه به اتکاء بخش‌های کشاورزی، صنعت و شرب به منابع آب زیرزمینی، مدل‌سازی سفره‌های آب‌های زیرزمینی و پیش‌بینی تراز آب‌های زیرزمینی از نظر ایجاد سازه‌های مهندسی، مطالعات هیدرولوژیکی و مدیریتی، مصارف کشاورزی از اهمیت بسیاری در این منطقه برخوردار می‌باشد. یکی از مشکلات مهم در مورد آب‌های زیرزمینی، برداشت بی‌رویهی آب از آبخوان‌های زیرزمینی، افت سطح آب و متراکم شدن لایه‌ها و رسوبات لایه می‌باشد (Nozari and Zali, 2014). با توجه به اطلاعات و عدم قطعیت‌های موجود، مدل‌های مختلفی برای شبیه‌سازی رفتار تغییرات سطح آب‌های زیرزمینی ایجاد شده است. بطور کلی بدین منظور از سه نوع مدل می‌توان استفاده کرد: مدل‌های فیزیکی، مدل‌های عددی و مدل‌های رگرسیونی. عملکرد مدل‌های فیزیکی در پیش‌بینی مناسب می‌باشد اما هزینه‌های ساخت این مدل‌ها بسیار بالا می‌باشد و به اطلاعات فیزیکی دقیق نیاز دارند. مدل‌های عددی محدودیت‌های مدل‌های فیزیکی را ندارند اما به اطلاعات زمین‌شناسی بسیاری در مورد آبخوان شامل هدایت هیدرولیکی، ضریب ذخیره‌سازی و ضخامت آبخوان نیاز دارند که دستیابی به چنین اطلاعاتی بسیار دشوار و در بسیاری از مناطق امکان‌ناپذیر می‌باشند. از انواع این مدل‌ها می‌توان به مدل‌های FLOW، PMWIN و Visual MODFLOW اشاره کرد (Brunner and Simmons, 2012; Milan et al., 2018). مدل‌های رگرسیونی محدودیت‌های مدل‌های فیزیکی را ندارند و برای

محمدی قلعه‌نی و همکاران، تاثیر اقلیمی بر افت تراز آب زیرزمینی آبخوان دشت ساوه را مورد ارزیابی قرار دادند و نشان دادند که احداث سد ساوه بر روی رودخانه قره‌چای دلیل اصلی افت سطح آب زیرزمینی ساوه می‌باشد (Mohammadi et al., 2012).

کمبود آب در سال‌های اخیر موجب افت سطح آب زیرزمینی خصوصا در مناطق خشک و نیمه‌خشک کشور شده که این امر، بررسی روند تغییرات دشت‌ها را ضروری می‌نماید. در دشت همدان-بهار نیز فقدان رودخانه‌های دائمی منجر به برداشت بی رویه از آب‌های زیرزمینی شده است. از این رو، اهمیت آبخوان در دشت همدان-بهار و لزوم انجام مطالعات شبیه‌سازی جهت تصمیم‌گیری مدیران برای مدیریت بهتر منابع آب استان از یک سو و سهولت و دقت استفاده از مدل‌های SVM و SARIMA و ARIMA در پیش‌بینی پارامترهای هدرولوژیکی از سوی دیگر موجب شد تا پتانسیل مدل تلفیقی SVM-SA و مدل‌های SARIMA و ARIMA در پیش‌بینی سطح آب زیرزمینی دشت همدان-بهار مورد بررسی قرار گیرد.

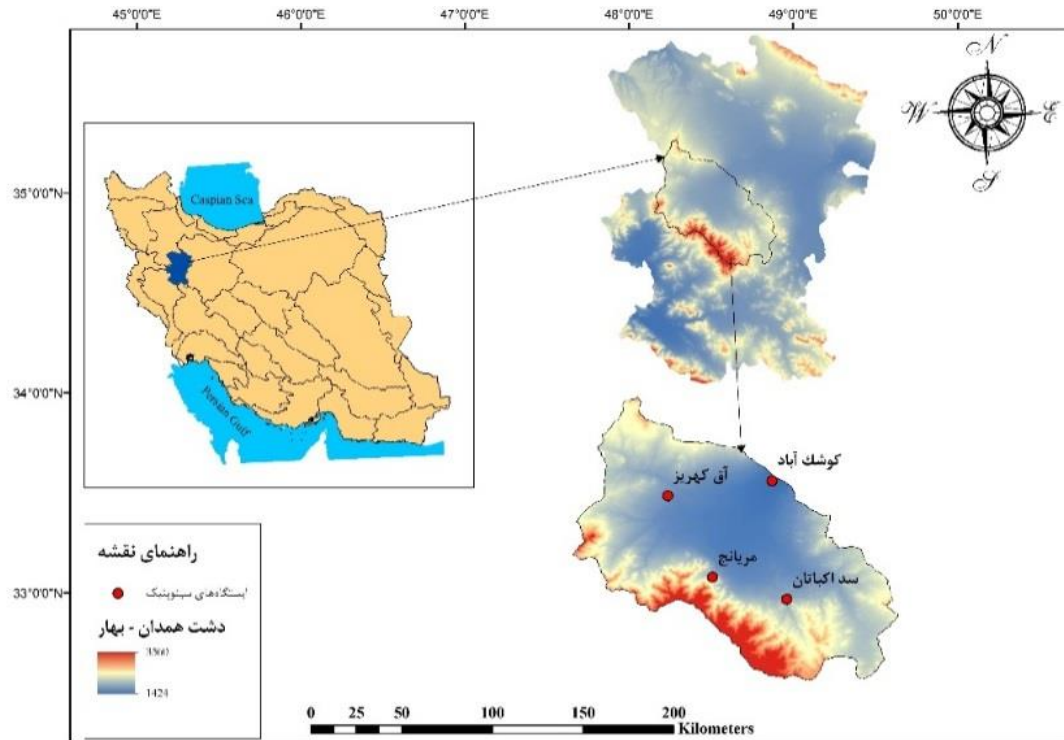
مواد و روش‌ها

منطقه مورد مطالعه

استان همدان در گستره‌ای به مساحت ۱۹۴۹۱ کیلومتر مربع، بین ۵۹° ۳۳' تا ۴۴° ۳۵' عرض شمالی و ۴۷° ۴۷' تا ۳۰° ۴۹' طول شرقی قرار دارد (شکل ۱). این استان هفت دشت مستقل دارد. دشت همدان-بهار با مساحت تقریبی ۴۶۸ کیلومتر مربع و با ارتفاع ۱۷۰۰ تا ۱۸۰۰ متر از سطح دریا در دامنه شمالی ارتفاعات الوند واقع شده است. این دشت کمترین وسعت را در بین دشت‌های منطقه دارد. بر اساس نمودار آب و هوای آمبرگه، در آب و هوای نیمه خشک با هوای سرد و کوهستانی قرار دارد. متوسط آمار بارندگی سالانه در دوره آماری ۳۰ ساله بر اساس ایستگاه‌های باران‌سنجی سد اکباتان، آق‌کهریز، مریانج و کوشک آباد ۳۵۷ میلی‌متر می‌باشد. بیشتر رودخانه‌های این حوضه از ارتفاعات جنوبی سرچشمه می‌گیرند و در قسمت مرکزی دشت به هم می‌پیوندند و رودخانه اصلی سیمینه‌رود را تشکیل می‌دهند. متوسط دبی دوره ۳۰ ساله این رودخانه ۲،۵۶ مترمکعب در سال که معادل ۷۸،۸ میلیون متر مکعب در سال و متوسط خروجی حوضه در پنج سال اخیر حدود ۲۷،۹۱ میلیون متر مکعب می‌باشد. سطح آب‌های زیرزمینی در این منطقه با توجه به روند افزایشی مصرف آب های زیرزمینی، رشد جمعیت، استفاده بی رویه از آب در کشاورزی و تغییر بهره برداری از اراضی همراه با کاهش نفوذپذیری خاک، کاهش یافته و با تغذیه سالانه از طریق نزولات جوی قادر به جبران خسارت نبوده است (Tapak et al., 2013). در این تحقیق از داده های سری زمانی ماهانه و

NARX را نسبت به بقیه‌ی مدل‌ها نشان داد (Aderemi et al., 2023). از سوی دیگر با توجه به مطالعات انجام گرفته می‌توان دریافت که مدل‌های سری زمانی از جمله مدل ARIMA و SARIMA در پیش‌بینی سطح آب زیرزمینی دقت قابل قبولی داشته‌اند. برای مثال، خراسانی و همکاران در مطالعه‌ای برای پیش‌بینی سطح آب زیرزمینی آبخوانی واقع در کبودآهنگ همدان طی سال‌های ۲۰۱۴-۲۰۱۷ از مدل ARIMA استفاده کردند. نتایج آن‌ها نشان داد که این مدل با دقت خوبی سطح آب زیرزمینی را مورد پیش‌بینی قرار داده است. همچنین نتایج آن‌ها نشان داد که سطح آب زیرزمینی در این آبخوان تا ۳ سال آینده ۵ متر کاهش می‌یابد (Khorasani et al., 2016). تاکافوجی و همکاران جهت پیش‌بینی سطح آب زیرزمینی آبخوانی در برزیل از مدل‌های زمین آماری شبیه‌سازی گاوسی متوالی (SGS) و ARIMA بکار بردند. نتایج آن‌ها نشانگر دقت قابل قبول هر دو مدل مورد استفاده در پیش‌بینی سطح آب زیرزمینی بوده است (Takafuji et al., 2019). در پژوهشی دیگر کومار و راتنام روند تغییرات ماهانه، سالانه و فصلی آب زیرزمینی را با استفاده از روش من‌کنندال بررسی نمودند و سطح آب زیرزمینی را با استفاده از مدل ARIMA مورد پیش‌بینی قرار دادند. نتایج آن‌ها نشان داد که مدل ARIMA با دقت خوبی قادر به پیش‌بینی بوده است (Satish Kumar and Venkata Rathnam, 2019). سارما و سینگ در مطالعه‌ای جهت پیش‌بینی سطح آب زیرزمینی در منطقه‌ای در پایتخت هند از پنج مدل متداول مبتنی بر داده اعم از SARIMA، پروسپترون چند لایه (، یادگیری ماشین افراطی (، هموارسازی نمایی HOLT-Winter و خودرگرسیون شبکه عصبی (استفاده کردند و نتایج قابل قبول تمامی مدل‌ها را نشان دادند (Sarma and Singh, 2022). موهاناساندرام و همکاران در مطالعه‌ای دیگر از مدل SARIMA و یک مدل ترکیبی خودرگرسیون و میانگین متحرک غیرفصلی شده (DS-ARMA) را جهت پیش‌بینی سطح آب زیرزمینی بکار بردند. نتایج آن‌ها نشان داد که مدل پیشنهادی نسبت به مدل SARIMA از دقت بالایی برخوردار می‌باشد (Mohanasundaram et al., 2019).

بررسی پژوهش‌هایی که تاکنون صورت گرفته است، نشان می‌دهد مدل SVM از دقت قابل قبولی در مدل‌سازی برخوردار است. در ایران نیز پژوهش‌های متعددی بیلان آبی و رفتار آب‌های زیرزمینی را مدل‌های هوش مصنوعی مورد ارزیابی قرار دادند. برای مثال، پورمحمدی و همکاران با استفاده از سنجش از دور و سیستم اطلاعات جغرافیایی اجزای بیلان آبی را در حوضه‌های خشک در منطقه‌ای از یزد مدل‌سازی کردند و نشان دادند که بیشتر هدررفت آبی این حوضه توسط تبخیر و تعرق واقعی صورت می‌گیرد (Poormohammadi et al., 2011).



شکل ۱. موقعیت جغرافیایی ایستگاه‌های سینوپتیک مورد مطالعه

$$\frac{1}{2}W^TW + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i^* \quad (1)$$

$$W^T\phi(x_i) + b - y_i \leq \varepsilon + \xi_i^* \quad (2)$$

$$y_i - W^T\phi(x_i) - b \leq \varepsilon + \xi_i$$

$$\xi_i^*, \xi_i \geq 0$$

در این روابط، C ضریب ثابت، W ضرایب بردار و b یک عدد ثابت می‌باشند و ξ_i ضریب کمبود، شاخص i موارد آموزشی N را نشان می‌دهد و هسته ϕ تابع کرنل می‌باشد (Nozari and Tavakoli, 2020).

محققین طی مطالعات مختلفی با استفاده از الگوریتم‌های فراکاوشی سعی در بهینه کردن پارامترهای مدل SVM دارند که از جمله این الگوریتم‌های می‌توان به الگوریتم‌های ژنتیک (GA)، کلونی مورچه (ACO)، بهینه‌سازی ازدحام ذرات (PSO) و تبرید شبیه‌سازی (SA) اشاره کرد (Zhang et al., 2010). الگوریتم تبرید شبیه‌سازی (SA)، بر مبنای مونت کارلو است که توسط متروپولیس و همکارانش در سال ۱۹۵۳ ارائه شده است که بر مبنای رابطه بین ساختار اتمی، آنتروپی و دما در طول تبرید یک ماده می‌باشد (Tran N and Tran K, 2007). این الگوریتم با روش جستجوی محلی سعی در یافتن جواب بهینه می‌کند. اساس این الگوریتم بر توابع توزیع احتمالی بولترمن می‌باشد (Cercignani, 1988). در این پژوهش نیز سعی شد با استفاده از این الگوریتم به بهینه‌سازی پارامترهای مدل SVM بپردازیم.

سالانه بارش و سطح آب زیرزمینی حدود ۳۰ سال (مهر ۱۳۷۰ تا شهریور ۱۴۰۰) دشت همدان-بهار که از طریق سایت آب منطقه‌ای استان همدان ارائه شده است، استفاده شد. موقعیت جغرافیایی ایستگاه‌های سینوپتیک مذکور واقع در دشت همدان-بهار در شکل (۱) قابل مشاهده می‌باشد.

مدل ماشین بردار پشتیبان تلفیقی با الگوریتم تبرید شبیه‌سازی (SVM-SA)

مدل ماشین بردار پشتیبان (SVM) برای مسائل رگرسیون و طبقه‌بندی توسط واینیک در سال ۱۹۶۵ ارائه گردید. این مدل بر اساس تئوری یادگیری آماری معرفی شد و در مسائل پیش‌بینی به‌عنوان رگرسیون بردار پشتیبان (SVR) شناخته می‌شود. این مدل با سایر روش‌های رگرسیونی تفاوت دارد و بر اساس کمینه‌سازی ریسک ساختاری به‌جای ریسک تجربی استفاده می‌کند (Radhika and Shashi, 2009). از ویژگی‌های برجسته این مدل می‌توان به قابلیت عمومی‌سازی و سازگاری با داده‌های ناقص و پراکنده اشاره کرد (Behzad et al., 2009). در واقع این مدل با در نظر گرفتن محدودیت‌های معادله (۲) منجر به حداقل رساندن خطای معادله (۱) می‌شود (Granata et al., 2017). در این مدل ۴ تابع پایه خطی، سیگموئیدی، چندجمله‌ای و شعاعی برای تابع هسته جایگزین می‌شوند که در این مطالعه از تابع RBF به‌دلیل استحکام آن برای حل مسائل غیرخطی استفاده شده است (Wang et al., 2013).

تصادفی مستقل از زمان و Z_t متغیر نرمال استاندارد شده وابسته به زمان می‌باشند.

مقادیر $\varphi(B)$ و $\theta(B)$ در رابطه (۶) به ترتیب چند جمله‌ای از درجه p و q بوده و به صورت زیر می‌باشند:

$$\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \quad (۷)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (۸)$$

مدل میانگین متحرک یکپارچه خودهمبسته فصلی (SARIMA)

مدل‌های سری زمانی کاربردهای بسیاری در شبیه‌سازی و پیش‌بینی سری‌های زمانی و پارامترهای هیدرولوژیکی دارند. هرگاه در یک سری بعد از هر فاصله‌ی زمانی مشخص شباهت وجود داشته باشد، سری دارای رفتار فصلی یا تناوبی با دوره تناوب s می‌باشد. در واقع اگر سری زمانی دارای رفتار تناوبی باشد، مدل میانگین متحرک یکپارچه خودهمبسته فصلی (SARIMA) مناسب می‌باشد. مدل SARIMA در واقع معیار فصلی را به مدل ARIMA اضافه کرده است. مدل مذکور به صورت $SARIMA(p,d,q)*(P,D,Q)_s$ محاسبه می‌شود. فرم پایه این مدل به صورت (۹) معادله ارائه شده که در آن d, p, q, P, D, Q مرتبه‌های مدل و s طول فصل می‌باشد (Nozari et al., 2023).

$$\varphi_p(B)\varphi_P(B^s)(1-B)^d(1-B^s)^D Z_t = \theta_q(B)\theta_Q(B^s)\varepsilon_t + \theta_0 \quad (۹)$$

مقادیر $\varphi_p(B)$ ، $\varphi_P(B^s)$ ، $\theta_q(B)$ و $\theta_Q(B^s)$ به ترتیب چند جمله‌ای از درجه p, P, q, Q می‌باشند که به کمک روابط زیر محاسبه می‌شوند:

$$\varphi_p(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \quad (۱۰)$$

$$\varphi_P(B^s) = 1 - \varphi_s B^s - \varphi_{2s} B^{2s} - \dots - \varphi_{Ps} B^{Ps} \quad (۱۱)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (۱۲)$$

$$\theta_Q(B^s) = 1 - \theta_s B^s - \theta_{2s} B^{2s} - \dots - \theta_{Qs} B^{Qs} \quad (۱۳)$$

معیارهای ارزیابی

برای ارزیابی دقت مدل‌های مورد استفاده از شاخص‌های آماری نظیر ریشه میانگین خطا (RMSE)، ضریب نش سائکلیف (NSE)، ضریب میانگین خطای استاندارد (SE)، ضریب تبیین (R^2) و ضریب اطلاعاتی آکائیک (AIC) استفاده شد. شکل ریاضی این شاخص‌ها به صورت معادله‌های ۱۵ الی ۱۸ ارائه شده است (Nozari et al., 2023; Pouyanfar et al., 2023):

$$P(E) \propto \exp(-E/k_b T) \quad (۳)$$

در رابطه فوق، E و T به ترتیب معرف انرژی و دمای سیستم و k_b نشان‌دهنده ثابت بولتزمن می‌باشد.

توابع خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF)

توابع خودهمبستگی (ACF) توابعی است که وابستگی زمانی در ساختار یک سری را نشان می‌دهد. رابطه تابع خودهمبستگی با تاخیر k به صورت رابطه (۴) محاسبه می‌شود:

$$\rho_k = \frac{\sum_{i=1}^{n-k} (Z_i - \bar{Z})(Z_{i+k} - \bar{Z})}{\sum_{i=1}^n (Z_i - \bar{Z})^2}, -1 \leq \rho_k \leq 1 \quad (۴)$$

در رابطه فوق، ρ_k مقدار تابع خودهمبستگی سری زمانی با تاخیر k ، Z_i و Z_{i+k} مقادیر متغیرها یا داده‌های سری زمانی در مرحله زمانی i و مرحله با تاخیر زمانی k و \bar{Z} مقدار میانگین متغیرها می‌باشد.

همچنین روش دیگر برای نشان دادن وابستگی زمانی در ساختار یک سری زمانی از تابع خودهمبستگی جزئی نیز استفاده می‌شود که رابطه تابع خودهمبستگی جزئی با تاخیر k به صورت رابطه (۵) می‌باشد:

$$\varphi_k = \frac{\rho_k - \sum_{i=1}^{k-1} \varphi_i(k-i)\rho_{k-i}}{1 - \sum_{i=1}^{k-1} \varphi_i(k-i)\rho_i} \quad (۵)$$

مدل ARMA در کاربردهای وسیعی از مسائل هیدرومتئورولوژی مورد استفاده قرار گرفته است. اما برای استفاده از آن باید فرآیند ایستایی برقرار باشد. بنابراین باکس و همکاران (۱۹۹۴) با اضافه کردن مرتبه تفاضلی d ، مدل ARIMA را ارائه نمودند. این مدل جزء مدل‌های کلاسیک برای پیش‌بینی سری‌های زمانی است که به‌عنوان مدل Box و Jenkins شناخته می‌شود. فرم پایه مدل‌های تلفیقی خود همبسته- میانگین متحرک $ARIMA(p,d,q)$ برای متغیر نرمال استاندارد شده Z_t به صورت رابطه (۶) بوده که در آن $(1-B)^d Z_t$ سری تفاضلی شده Z_t می‌باشد که از یک فرآیند ایستای $ARMA(p,q)$ پیروی می‌کند. لذا اگر $d=0$ باشد، سری اولیه Z_t ایستا می‌شود (Nozari et al., 2023):

$$\varphi(B)(1-B)^d Z_t = \theta(B)\varepsilon_t + \theta_0 \quad (۶)$$

در این رابطه $\varphi(B)$ عملگر مدل AR، $\theta(B)$ عملگر مدل MA، d مرتبه تفاضلی، θ_0 پارامتر روند قطعی، ε_t متغیر

SA به صورت کدنویسی در محیط (2017) MATLAB استفاده شد. ابتدا جهت آموزش مدل از تابع کرنل پایه شعاعی طبق مطالعات گذشته استفاده شد (Sedghnejad et al., 2024). در نهایت سطح آب زیرزمینی به دو صورت ماهانه و سالانه برآورد گردید. نتایج محاسبه شاخص‌های آماری در مرحله واسنجی و صحت‌سنجی برای دوره‌های سالانه و ماهانه جهت برآورد و نمودارهای مقادیر مشاهده‌ای و شبیه‌سازی شده برای دوره‌ی واسنجی و صحت‌سنجی در هر دو دوره زمانی ماهانه و سالانه به ترتیب در جدول (۱) و شکل‌های (۲)، (۳)، (۴) و (۵) قابل مشاهده می‌باشد. با توجه به نتایج می‌توان دریافت که مدل SVM-SA با ضریب نش ساتکلیم 0/993 و 0/962 به ترتیب در دوره‌های واسنجی و صحت‌سنجی در دوره ماهانه و با ضریب نش ساتکلیم 0/945 و 0/412 به ترتیب در دوره‌های واسنجی و صحت‌سنجی در دوره سالانه مقادیر تراز سطح آب زیرزمینی را شبیه‌سازی کرده است. با توجه به اینکه مقدار ضریب NSE از بی نهایت تا یک متغیر است و مقادیر نزدیک به یک نشان‌دهنده تطابق نزدیک بین داده‌های مشاهده‌ای و شبیه‌سازی می‌باشد، از این رو می‌توان نتیجه گرفت که مدل SVM-SA با دقت بالایی قادر به شبیه‌سازی تراز سطح آب زیرزمینی بوده است. از سوی دیگر با توجه به داده محور بودن مدل SVM-SA، شبیه‌سازی در دوره ماهانه نسبت به سالانه به دلیل وجود تعداد بیشتر داده جهت آموزش مدل، از دقت بالاتری برخوردار می‌باشد (Sedghnejad et al., 2024). همچنین با توجه به شاخص RMSE در هر دو دوره‌ی زمانی ماهانه و سالانه می‌توان اظهار کرد افت آب زیرزمینی در دشت همدان-بهار با تغییرات بارش در این منطقه رابطه معنی داری ندارد. در واقع همانطور که محمدی و همکاران طی پژوهشی به تاثیر کم بارش در افت شدید سطح آب زیرزمینی تاکید کرده بودند (Mohammadi et al., 2012)، در این مطالعه نیز نتایج حاکی از آن است که افت شدید سطح آب زیرزمینی به دلیل تغییر اقلیم و کمبود بارش نمی‌باشد بلکه به دلیل برداشت‌های بی رویه از منابع آب‌های زیرزمینی می‌باشد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_m - Y_p)^2}{n}} \quad (14)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (Y_m - Y_p)^2}{\sum_{i=1}^n (Y_m - \bar{Y}_p)^2} \quad (15)$$

$$SE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Y_m - Y_p)^2}}{\bar{Y}_m} \quad (16)$$

$$R^2 = \frac{[\sum_{i=1}^n (Y_m - \bar{Y}_m)(Y_p - \bar{Y}_p)]^2}{\sum_{i=1}^n (Y_m - \bar{Y}_m)^2 \cdot \sum_{i=1}^n (Y_p - \bar{Y}_p)^2} \quad (17)$$

$$AIC = N \cdot \ln \sigma_\epsilon^2 + 2(k) \quad (18)$$

در روابط فوق n تعداد ماه‌های مورد مطالعه، Y_m مقادیر اندازه‌گیری شده در هر روز، Y_p مقدار پیش‌بینی شده، \bar{Y}_m میانگین داده‌های اندازه‌گیری شده، \bar{Y}_p میانگین داده‌های پیش‌بینی شده، N تعداد نمونه، k مجموع پارامترهای مدل و σ_ϵ^2 واریانس باقیمانده‌ها می‌باشند.

همچنین برای بررسی عدم قطعیت و دقت نتایج حاصل از برآورد تراز سطح آب زیرزمینی، از شاخص آماری میانگین طول بازه نسبی (ARIL) استفاده گردید که معادله ریاضی این شاخص در رابطه ۱۹ ارائه شده است (Marashi et al., 2023):

$$ARIL = \frac{1}{N_p} \sum \frac{W_{max} - W_{min}}{W_0} \quad (19)$$

در رابطه بالا W_{min} و W_{max} حد بالا و حد پایین تراز سطح آب زیرزمینی محاسبه شده و W_0 تراز سطح آب زیرزمینی مشاهده‌ای می‌باشند. هر چه مقدار این شاخص به صفر نزدیک‌تر باشد، نشان دهنده دقت بالای مدل می‌باشد.


نتایج و بحث

برآورد سطح آب زیرزمینی به کمک مدل SVM-SA

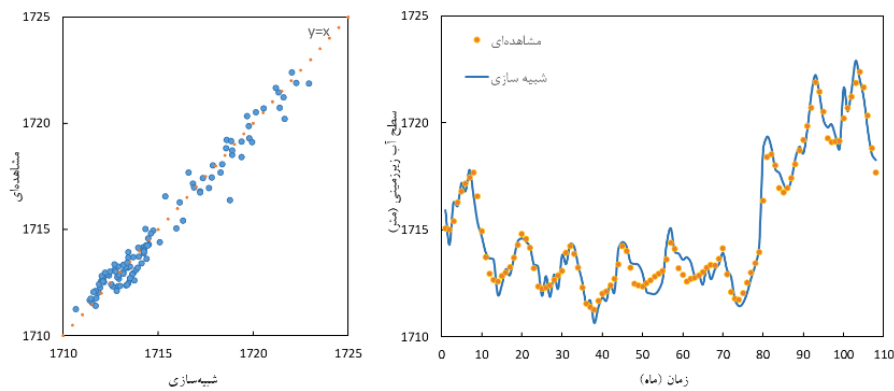
در این پژوهش به منظور برآورد سطح آب زیرزمینی واقع در دشت همدان-بهار، از سری زمانی سطح آب زیرزمینی و بارش ۳۰ ساله ۴ ایستگاه سینوپتیک واقع در دشت همدان-بهار استفاده شد. ۸۰٪ از سری زمانی ۳۰ ساله مورد استفاده جهت واسنجی و ۲۰٪ از آن‌ها جهت صحت‌سنجی مورد استفاده قرار گرفت. جهت برآورد مقادیر سطح آب زیرزمینی، از مدل SVM-

جدول ۱. نتایج مربوط به برآورد سطح آب زیرزمینی بصورت ماهانه و سالانه در منطقه مورد مطالعه به کمک مدل SVM-SA

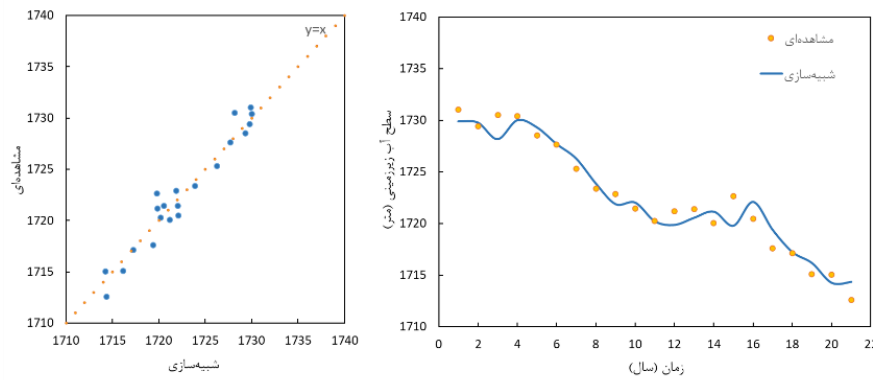
مرحله صحت‌سنجی			مرحله واسنجی			پیش‌بینی
R ²	RMSE (m)	SE	R ²	RMSE (m)	SE	
۰/۵۶۶	۲/۱۵۵	۰/۰۰۱	۰/۹۴۷	۱/۲۴۷	۰/۰۰۱	سالانه
۰/۹۶۶	۰/۵۸۴	۰/۰۰۰۳	۰/۹۹۳	۰/۴۱۷	۰/۰۰۰۲	ماهانه



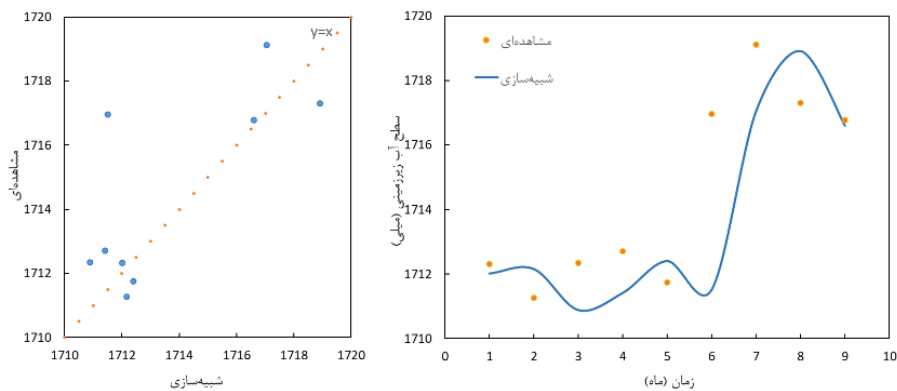
شکل ۲. مقایسه سطح آب زیرزمینی مشاهده‌ای و شبیه‌سازی شده ماهانه دوره واسنجی به کمک مدل SVM-SA



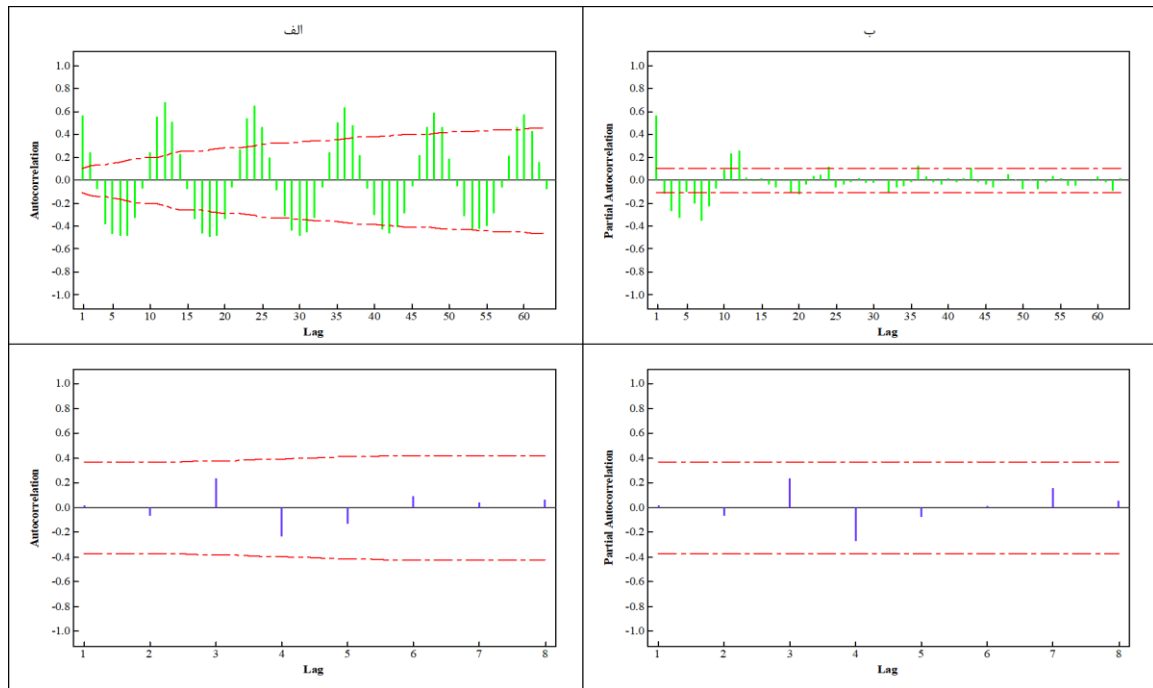
شکل ۳. مقایسه سطح آب زیرزمینی مشاهده‌ای و شبیه‌سازی شده ماهانه دوره صحت‌سنجی به کمک مدل SVM-SA



شکل ۴. مقایسه سطح آب زیرزمینی مشاهده‌ای و شبیه‌سازی شده سالانه دوره واسنجی به کمک مدل SVM-SA



شکل ۵. مقایسه سطح آب زیرزمینی مشاهده‌ای و شبیه‌سازی شده سالانه دوره صحت‌سنجی به کمک مدل SVM-SA



شکل ۶. نمودار ACF و PACF ایستگاه سینوپتیک سد اکباتان به صورت ماهانه (الف) و سالانه (ب) در مرحله واسنجی

گرفتند. در جداول (۲)، (۳)، (۴) و (۵) بطور مختصر نتایج مدل SARIMA و ARIMA برای ۴ ایستگاه سینوپتیک در مرحله واسنجی به صورت ماهانه و سالانه ارائه شده است. مدل‌های منتخب با توجه به شاخص‌های ارزیابی برای ایستگاه آق‌کهریز در دوره ماهانه و سالانه به ترتیب $SARIMA(3,0,1)*(1,0,1)$ و $ARIMA(3,0,2)$ ، ایستگاه سد اکباتان در دوره ماهانه و سالانه به ترتیب $SARIMA(1,0,1)*(1,1,2)$ و $ARIMA(3,1,3)$ ، برای ایستگاه کوشک آباد در دوره ماهانه و سالانه به ترتیب $SARIMA(1,1,3)*(1,1,1)$ و $ARIMA(2,0,3)$ و برای ایستگاه مریانج در دوره ماهانه و سالانه به ترتیب $SARIMA(1,0,1)*(1,1,2)$ و $ARIMA(3,0,2)$ به عنوان الگوهای برگزیده انتخاب گردید. نتایج نشان داد مقدار SE مدل‌های منتخب در ایستگاه‌های آق‌کهریز، سد اکباتان، کوشک آباد و مریانج به ترتیب برابر با ۱/۱۶، ۰/۸۲، ۰/۹۲ و ۱ برای دوره ماهانه و برابر با ۰/۲۲، ۰/۴، ۰/۳۶ و ۰/۲ برای دوره سالانه می‌باشد. در نهایت مقادیر بارش ماهانه و سالانه با استفاده از الگوهای برگزیده برای ۵ سال آینده پیش‌بینی گردید. نمودارهای بارش پیش‌بینی شده در ایستگاه‌های مورد مطالعه به صورت ماهانه (الف) و سالانه (ب) در شکل (۷) قابل مشاهده می‌باشد.

خودهمبستگی و خودهمبستگی جزئی در مقادیر بارش به منظور تشخیص ماهیت داده‌های بارش، نمودارهای ACF و PACF داده‌های بارش ۴ ایستگاه باران‌سنجی آق‌کهریز، سد اکباتان، کوشک آباد و مریانج در دوره زمانی ۷۰-۷۱ تا ۹۹-۱۴۰۰ به صورت ماهانه و سالانه به کمک نرم‌افزار MINITAB ترسیم شد. پس از مشاهده روند فصلی داده‌های بارش، مدل SARIMA جهت پیش‌بینی فصلی انتخاب گردید. برای نمونه نمودارهای ACF و PACF ایستگاه سینوپتیک سد اکباتان در مرحله واسنجی در شکل (۶) قابل مشاهده می‌باشد.

پیش‌بینی بارش ماهانه و سالانه به کمک مدل‌های SARIMA و ARIMA

پس از مشاهده فرایند فصلی در سری زمانی بارش ماهانه و سالانه، پیش‌بینی به کمک مدل SARIMA انجام گردید. بدین منظور حالت ایستایی در میانگین و واریانس سری زمانی به کمک تحلیل روند و روش BOX-COX مورد تجزیه و تحلیل قرار گرفت که با توجه به ایستایی سری زمانی بارش ماهانه و سالانه، هیچ تغییری برای سری زمانی صورت نگرفت (Box and Cox, 1964). ابتدا مرتبه پارامترهای مدل SARIMA به کمک نمودارهای ACF و PACF انتخاب گردید و در گام بعد جهت دستیابی به بهترین مدل، مرتبه‌های دیگر نیز مورد آزمون قرار

جدول ۲. مقادیر معیارهای ارزیابی مدل‌های SARIMA و ARIMA برای دوره‌های ماهانه و سالانه در دوره واسنجی ایستگاه باران‌سنجی آق‌کهریز

AIC	SE	RMSE (m)	R ²	مدل منتخب	دوره زمانی
۱۱.۲۴	۱.۱۶	۲۵.۳۱	۰.۳۰	SARIMA(۱,۰,۰) (۱,۰,۱)	ماهانه
۱۵.۲۶	۱.۱۷	۲۵.۴۴	۰.۲۸	SARIMA(۱,۰,۱) (۱,۱,۱)	
۱۷.۲۷	۱.۱۶	۲۵.۳۸	۰.۲۸	SARIMA(۱,۰,۱) (۲,۱,۱)	
۱۷.۲۶	۱.۱۷	۲۵.۳۹	۰.۲۸	SARIMA(۲,۰,۱) (۱,۱,۱)	
۱۷.۲۴	۱.۱۶	۲۵.۲۴	۰.۳۰	SARIMA(۳,۰,۱) (۱,۰,۱)	
۱۱.۷۱	۰.۲۵	۸۱.۹۲	۰.۱۸	ARIMA(۱,۰,۱)	سالانه
۱۷.۳۴	۰.۲۶	۸۶.۵۶	۰.۱۲	ARIMA(۱,۱,۳)	
۱۳.۹۴	۰.۲۴	۷۸.۳۲	۰.۲۷	ARIMA(۲,۰,۱)	
۱۳.۱۴	۰.۲۸	۹۲.۶۵	۰.۱۰	ARIMA(۳,۱,۱)	
۱۷.۹۸	۰.۲۲	۷۲.۷۶	۰.۳۷	ARIMA(۳,۰,۲)	

جدول ۳. مقادیر معیارهای ارزیابی مدل‌های SARIMA و ARIMA برای دوره‌های ماهانه و سالانه در دوره واسنجی ایستگاه باران‌سنجی سد اکباتان

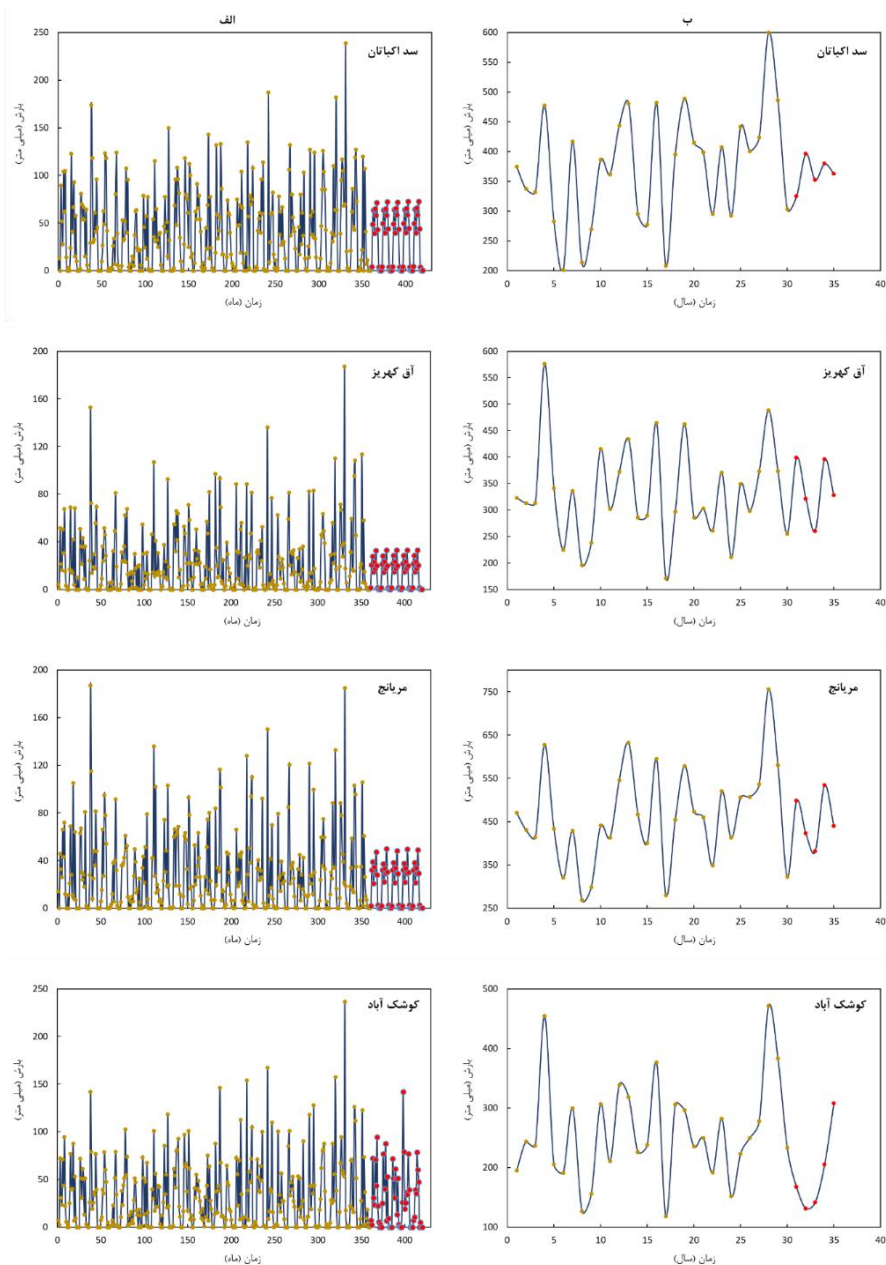
AIC	SE	RMSE (m)	R ²	مدل منتخب	دوره زمانی
۱۲.۷۲	۰.۸۳	۳۱.۹۳	۰.۴۵	SARIMA(۱,۰,۱) (۱,۱,۱)	ماهانه
۱۴.۷۲	۰.۸۲	۳۱.۶۹	۰.۴۵	SARIMA(۱,۰,۱) (۱,۱,۲)	
۱۶.۷۲	۰.۸۲	۳۱.۷۲	۰.۴۵	SARIMA(۱,۰,۲) (۱,۱,۲)	
۱۸.۷۵	۰.۸۳	۳۲.۰۳	۰.۴۵	SARIMA(۲,۰,۲) (۲,۰,۲)	
۱۴.۶۷	۰.۸۳	۳۱.۹۲	۰.۴۵	SARIMA(۳,۰,۱) (۱,۰,۱)	
۷.۹۶	۰.۳۸	۱۴۳.۸۷	۰.۱۵	ARIMA(۱,۰,۱)	سالانه
۱۸.۰۵	۰.۳۹	۴۴.۲۱	۰.۲۲	ARIMA(۱,۱,۳)	
۱۴.۳۶	۰.۳۹	۱۴۶.۴۰	۰.۳۱	ARIMA(۳,۰,۲)	
۱۳.۷۹	۰.۴۵	۶۷.۲۰	۰.۱۹	ARIMA(۳,۱,۱)	
۱۷.۸۳	۰.۴۰	۱۴۸.۸۰	۰.۱۴	ARIMA(۳,۱,۳)	

جدول ۴. مقادیر معیارهای ارزیابی مدل‌های SARIMA و ARIMA برای دوره‌های ماهانه و سالانه در دوره واسنجی ایستگاه باران‌سنجی کوشک آباد

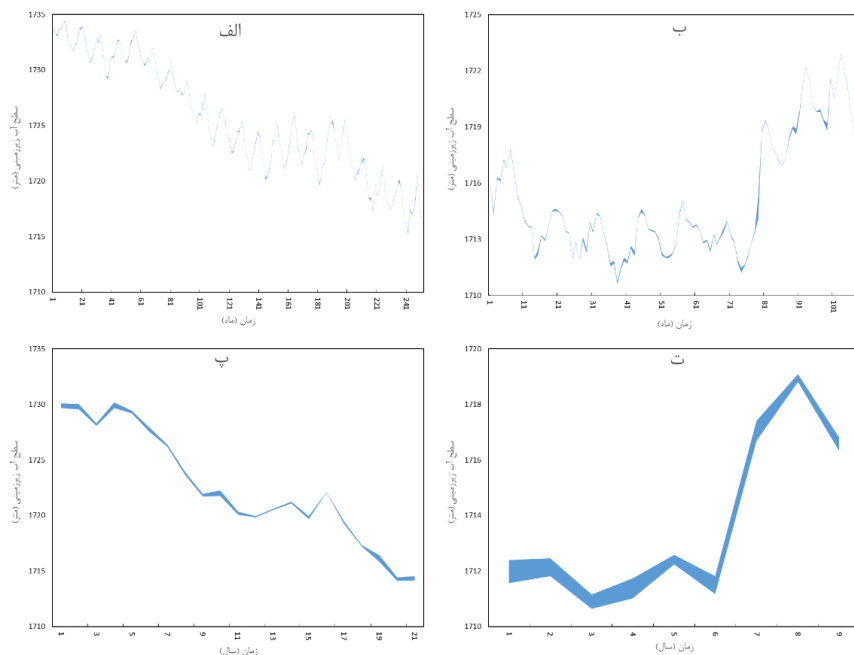
AIC	SE	RMSE (m)	R ²	مدل منتخب	دوره زمانی
۱۲.۵۲	۰.۹۵	۲۹.۶۲	۰.۴۰	SARIMA(۱,۰,۱) (۱,۰,۱)	ماهانه
۱۶.۵۶	۰.۹۵	۲۹.۵۸	۰.۴۰	SARIMA(۱,۰,۱) (۲,۰,۲)	
۱۶.۵۴	۰.۹۵	۲۹.۶۹	۰.۴۰	SARIMA(۱,۰,۱) (۳,۰,۱)	
۱۶.۴۸	۱.۰۰	۳۱.۲۳	۰.۳۶	SARIMA(۱,۱,۱) (۱,۱,۱)	
۲۰.۵۸	۰.۹۲	۲۸.۷۲	۰.۴۲	SARIMA(۱,۱,۳) (۱,۱,۱)	
۱۱.۲۱	۰.۴۰	۱۰۶.۲۹	۰.۰۸	ARIMA(۱,۰,۱)	سالانه
۱۴.۸۹	۰.۴۱	۱۰۹.۲۹	۰.۰۱	ARIMA(۱,۱,۲)	
۱۵.۵۵	۰.۳۹	۱۰۲.۸۳	۰.۱۹	ARIMA(۲,۰,۲)	
۱۷.۷۹	۰.۳۶	۹۳.۶۱	۰.۲۳	ARIMA(۲,۰,۳)	
۱۹.۱۵	۰.۳۸	۱۰۱.۵۲	۰.۰۷	ARIMA(۲,۱,۳)	

جدول ۵. مقادیر معیارهای ارزیابی مدل‌های SARIMA و ARIMA برای دوره‌های ماهانه و سالانه در دوره واسنجی ایستگاه باران سنجی مریانج

AIC	SE	RMSE (m)	R ²	مدل منتخب	دوره زمانی
۱۵.۰۱	۱.۰۱	۲۸.۰۱	۰.۳۷	SARIMA(۱,۰,۱) (۱,۱,۱)	ماهانه
۱۷.۰۳	۱.۰۱	۲۷.۹۴	۰.۳۶	SARIMA(۱,۰,۱) (۲,۱,۱)	
۱۷.۰۱	۱.۰۰	۲۷.۶۷	۰.۳۸	SARIMA(۱,۰,۱) (۱,۱,۲)	
۱۶.۹۴	۱.۰۷	۲۹.۵۷	۰.۳۲	SARIMA(۱,۱,۱) (۱,۱,۱)	
۲۰.۹۵	۱.۰۶	۲۹.۴۰	۰.۳۳	SARIMA(۱,۱,۳) (۱,۱,۱)	
۱۱.۳۹	۰.۲۲	۱۰۲.۸۶	۰.۱۶	ARIMA(۱,۰,۱)	سالانه
۱۵.۲۲	۰.۲۲	۱۰۴.۲۰	۰.۱۶	ARIMA(۱,۱,۲)	
۱۵.۳۹	۰.۲۱	۱۰۰.۴۹	۰.۲۰	ARIMA(۲,۰,۲)	
۱۷.۵۶	۰.۲۰	۹۴.۱۴	۰.۲۹	ARIMA(۳,۰,۲)	
۱۷.۰۴	۰.۲۳	۱۰۹.۲۲	۰.۱۸	ARIMA(۳,۱,۱)	



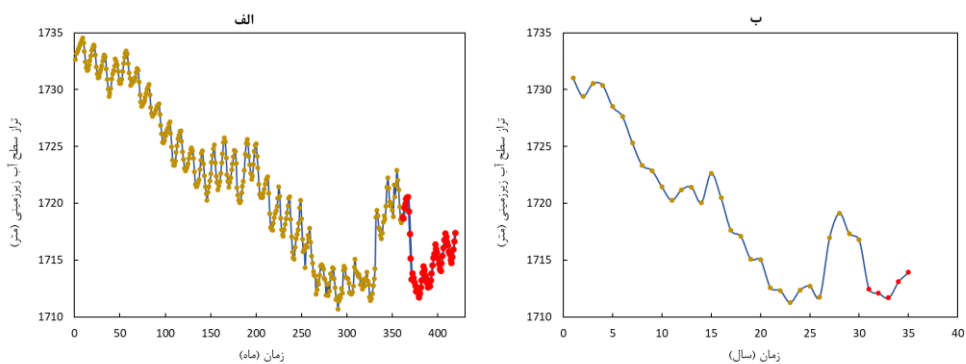
شکل ۷. بارش پیش‌بینی شده ماهانه (الف) و سالانه (ب) به کمک مدل‌های SARIMA و ARIMA در ایستگاه‌های مورد مطالعه



شکل ۸. ارزیابی عدم قطعیت تراز سطح آب زیرزمینی پیش‌بینی شده ماهانه و سالانه در دوره‌های واسنجی و صحت‌سنجی به کمک مدل SVM-SA

جدول ۶. شاخص عدم قطعیت مدل SVM-SA در برآورد تراز سطح آب زیرزمینی

ARIL		
مرحله واسنجی	مرحله صحت‌سنجی	
۰.۰۰۰۱۷	۰.۰۰۰۳۴	سالانه
۰.۰۰۰۰۳۷	۰.۰۰۰۰۵۸	ماهانه



شکل ۹. بارش پیش‌بینی شده ماهانه (الف) و سالانه (ب) به کمک مدل SVM-SA

آن است که مدل SVM-SA با ساختار مناسب، تراز سطح آب زیرزمینی را بطور دقیق برآورد کرده است.

پیش‌بینی سطح آب زیرزمینی به کمک مدل SVM-SA پس از پیش‌بینی بارش ماهانه و سالانه به کمک مدل‌های SARIMA و ARIMA، سطح آب زیرزمینی نیز به کمک مدل SVM-SA مورد پیش‌بینی قرار گرفت. بطوریکه نتایج مقادیر

ارزیابی عدم قطعیت مدل SVM-SA در برآورد سطح آب زیرزمینی عدم قطعیت مدل SVM-SA در برآورد تراز سطح آب زیرزمینی در شکل (۸) بصورت ماهانه برای دوره‌های واسنجی (الف) و صحت‌سنجی (ب) و بصورت سالانه برای دوره‌های واسنجی (پ) و صحت‌سنجی (ت) نشان داده شده است. جهت ارزیابی از معیار کیفیت ARIL استفاده شد. نتایج جدول ۶ حاکی از آن است که مقدار شاخص ARIL نزدیک به صفر می‌باشد که این نتایج گویای

و ARIMA بصورت ماهانه و سالانه برای ۵ سال آینده (۱۴۰۵-۱۴۰۱) مورد پیش‌بینی قرار گرفت. و در نهایت با استفاده از داده‌های سری زمانی بارش ماهانه و سالانه پیش‌بینی شده به کمک مدل SARIMA و ARIMA، مقادیر سطح آب زیرزمینی بصورت ماهانه و سالانه برای ۵ سال آینده (۱۴۰۵-۱۴۰۱) به کمک مدل SVM-SA مورد پیش‌بینی قرار گرفت. در حالت کلی با توجه به ارزیابی‌های انجام شده می‌توان اظهار کرد که مدل‌های استوکستیک از جمله مدل‌های SVM-SA و SARIMA و ARIMA از دقت قابل قبولی در برآورد و پیش‌بینی بارش و سطح آب زیرزمینی برخوردار می‌باشند. همچنین از دیگر نتایج مهم این مطالعه می‌توان به معنی‌دار نبودن رابطه بین کاهش بارش و افت شدید سطح آب زیرزمینی واقع در منطقه مورد مطالعه اشاره کرد. در واقع با توجه به نتایج می‌توان دریافت که دلیل اصلی افت آب‌های زیرزمینی در این منطقه ناشی از برداشتهای بی‌رویه و بهره‌برداهای نامتناسب می‌باشد. از این رو لازم است که تا با مدیریت صحیح و نظارت دقیق بر نحوه برداشت آب‌های زیرزمینی، تعادلی بین تغذیه و برداشت ایجاد نمود. در غیر اینصورت در آینده باید شاهد از بین رفتن این منابع آب ارزشمند باشیم.

بارش پیش‌بینی شده‌ی ۴ ایستگاه سینوپتیک آق کهریز، سد اکباتان، کوشک آباد و مریانج به‌عنوان ورودی به مدل SVM-SA جهت پیش‌بینی سطح آب زیرزمینی معرفی شد و تراز سطح آب زیرزمینی بصورت ماهانه و سالانه برای ۵ سال آینده پیش‌بینی گردید. نمودار تراز سطح آب زیرزمینی در دوره آماری ۱۳۷۰ تا ۱۴۰۵ در شکل (۹) قابل مشاهده می‌باشد.

نتیجه‌گیری

ابتدا در این مطالعه از مدل تلفیقی SVM-SA جهت برآورد سطح آب زیرزمینی بصورت ماهانه و سالانه واقع در دشت همدان-بهار استفاده شد و عملکرد این مدل مورد ارزیابی قرار گرفت. با بررسی عملکرد مدل، می‌توان اظهار کرد که اختلاف معناداری بین نتایج پیش‌بینی در هر دوره زمانی ماهانه و سالانه وجود ندارد و مدل دارای دقت قابل قبولی جهت برآورد سطح آب زیرزمینی ماهانه و سالانه می‌باشد. و به‌عنوان مدل مناسب جهت استفاده محققین در زمینه برآورد سطح آب زیرزمینی و حفاظت منابع طبیعی توصیه می‌شود. در گام بعد، مقادیر بارش ماهانه و سالانه ۴ ایستگاه سینوپتیک آق کهریز، سد اکباتان، کوشک آباد و مریانج با استفاده از مدل SARIMA

Reference:

- Aderemi, B. A., Olwal, T. O., Ndambuki, J. M., and Rwanga, S. S. (2023). Groundwater levels forecasting using machine learning models: A case study of the groundwater region 10 at Karst Belt, South Africa. *Systems and Soft Computing*, 5, 200049.
- Arya Azar, N., Kardan, N., and Ghordoyee Milan, S. (2023). Developing the artificial neural network-evolutionary algorithms hybrid models (ANN-EA) to predict the daily evaporation from dam reservoirs. *Engineering with Computers*, 39(2), 1375-1393.
- Behzad, M., Asghari, K., and Coppola Jr, E. A. (2010). Comparative study of SVMs and ANNs in aquifer water level prediction. *Journal of Computing in Civil Engineering*, 24(5), 408-413.
- Box, GEP., Cox, DR. 1964. An analysis of transformations. *Journal of the royal statistical society series b-methodological*, 26(2), 211-252.
- Brunner, P., and Simmons, C. T. (2012). HydroGeoSphere: a fully integrated, physically based hydrological model. *Ground water*, 50(2), 170-176.
- Cercignani, C., and Cercignani, C. (1988). *The boltzmann equation* (pp. 40-103). Springer New York.
- Fathi, A., Lee, T., and Mohebzadeh, H. (2019). Allocating underground dam sites using remote sensing and GIS case study on the southwestern plain of Tehran Province, Iran. *Journal of the Indian Society of Remote Sensing*, 47, 989-1002.
- Granata, F., Papirio, S., Esposito, G., Gargano, R., and De Marinis, G. (2017). Machine learning algorithms for the forecasting of wastewater quality indicators. *Water*, 9(2), 105.
- Javadi, S., Saatsaz, M., Shahdany, S. M. H., Neshat, A., Milan, S. G., and Akbari, S. (2021). A new hybrid framework of site selection for groundwater recharge. *Geoscience Frontiers*, 12(4), 101144.
- Kardan Moghaddam, H., Ghordoyee Milan, S., Kayhomayoon, Z., Rahimzadeh kivi, Z., and Arya Azar, N. (2021). The prediction of aquifer groundwater level based on spatial clustering approach using machine learning. *Environmental Monitoring and Assessment*, 193, 1-20.
- Kayhomayoon, Z., Azar, N. A., Milan, S. G., Moghaddam, H. K., and Berndtsson, R. (2021). Novel approach for predicting groundwater storage loss using machine learning. *Journal of Environmental Management*, 296, 113237.
- Kayhomayoon, Z., Ghordoyee Milan, S., Arya Azar, N., and Kardan Moghaddam, H. (2021). A new approach for regional groundwater level simulation: clustering, simulation, and optimization. *Natural Resources Research*, 30, 4165-4185.
- Khorasani, M., Ehteshami, M., Ghadimi, H., & Salari, M. (2016). Simulation and analysis of temporal changes of groundwater depth using time series modeling. *Modeling Earth Systems and Environment*, 2, 1-10.

- Liu, D., Mishra, A. K., Yu, Z., Lü, H., and Li, Y. (2021). Support vector machine and data assimilation framework for Groundwater Level Forecasting using GRACE satellite data. *Journal of Hydrology*, 603, 126929.
- Marashi, A., Kouchakzadeh, S., & Yonesi, H. A. (2023). Rotary gate discharge determination for inclusive data from free to submerged flow conditions using ENN, ENN-GA, and SVM-SA. *Journal of Hydroinformatics*, 25(4), 1312-1328.
- Milan, S. G., Roozbahani, A., and Banihabib, M. E. (2018). Fuzzy optimization model and fuzzy inference system for conjunctive use of surface and groundwater resources. *Journal of hydrology*, 566, 421-434.
- Mirarabi, A., Nassery, H. R., Nakhaei, M., Adamowski, J., Akbarzadeh, A. H., and Alijani, F. (2019). Evaluation of data-driven models (SVR and ANN) for groundwater-level prediction in confined and unconfined systems. *Environmental Earth Sciences*, 78, 1-15.
- Mohammadi, G. M., Ebrahimi, K., & Araghinejad, S. (2012). Evaluation impact of drought, extraction and construction of dam on the groundwater drop-case study Saveh aquifer.
- Mohanasundaram, S., Suresh Kumar, G., & Narasimhan, B. (2019). A novel deseasonalized time series model with an improved seasonal estimate for groundwater level predictions. *H2Open Journal*, 2(1), 25-44.
- Nadiri, A. A., Naderi, K., Khatibi, R., and Gharekhani, M. (2019). Modelling groundwater level variations by learning from multiple models using fuzzy logic. *Hydrological sciences journal*, 64(2), 210-226.
- Nhu, V. H., Shirzadi, A., Shahabi, H., Singh, S. K., Al-Ansari, N., Clague, J. J., ... and Ahmad, B. B. (2020). Shallow landslide susceptibility mapping: A comparison between logistic model tree, logistic regression, naïve bayes tree, artificial neural network, and support vector machine algorithms. *International journal of environmental research and public health*, 17(8), 2749.
- Nozari, H., & Zali, A. (2014). Investigating Groundwater Extraction from the Hamedan-Bahar Plain, s Aquifer. *Water and Soil Science*, 23(4), 277-289. (In Persian)
- Nozari, H., and Tavakoli, F. (2020). Forecasting hydrologic parameters using linear and nonlinear stochastic models. *Journal of Water and Climate Change*, 11(4), 1284-1301.
- Nozari, H., Azadi, S., Sedghnejad, N., & Pouyanfar, S. (2023). Predicting monthly evaporation using linear and nonlinear time series models Case study: meteorological station of Ekbatan Dam. *Journal of Agricultural Meteorology*, (In Persian).
- Pham, B. T., Jaafari, A., Prakash, I., and Bui, D. T. (2019). A novel hybrid intelligent model of support vector machines and the MultiBoost ensemble for landslide susceptibility modeling. *Bulletin of Engineering Geology and the Environment*, 78, 2865-2886.
- Poormohammadi, S., Dastorani, M. T., Cheraghi, S. A. M., Mokhtari, M. H., & Rahimian, M. H. (2011). Evaluation and Estimation of Water Balance Components in Arid Zone Catchments Using RS and GIS Case Study: Manshad Catchment, Yazd Province. *Journal of Water and Wastewater; Ab va Fazilab (in persian)*, 22(3), 99-108.
- Pouyanfar, S., Nozari, H., and Khodamorad Pour, M. (2023). Comparison of the performances of the gene expression programming model and the RegCM model in predicting monthly runoff. *Journal of Water and Climate Change*, 14(10), 3810-3829.
- Radhika, Y., and Shashi, M. (2009). Atmospheric temperature prediction using support vector machines. *International journal of computer theory and engineering*, 1(1), 55.
- Sarma, R., & Singh, S. K. (2022). A comparative study of data-driven models for groundwater level forecasting. *Water Resources Management*, 36(8), 2741-2756.
- Satish Kumar, K., & Venkata Rathnam, E. (2019). Analysis and prediction of groundwater level trends using four variations of Mann Kendall tests and ARIMA modelling. *Journal of the Geological Society of India*, 94, 281-289.
- Sedghnejad, N., Nozari, H., & Marofi, S. (2024). Comparative analysis of classification techniques and input-output patterns for monthly rainfall prediction. *Water Science*, 38(1), 192-208.
- Takafuji, E. H. D. M., Rocha, M. M. D., & Manzione, R. L. (2019). Groundwater level prediction/forecasting and assessment of uncertainty using SGS and ARIMA models: a case study in the Bauru Aquifer System (Brazil). *Natural Resources Research*, 28(2), 487-503.
- Tapak, L., Rahmani, A. R., and Moghimbeigi, A. (2013). Prediction the groundwater level of Hamadan-Bahar plain, west of Iran using support vector machines. *Journal of research in health sciences*, 14(1), 82-87.
- Tran, N. H., and Tran, K. (2007). Combination of fuzzy ranking and simulated annealing to improve discrete fracture inversion. *Mathematical and Computer Modelling*, 45(7-8), 1010-1020.
- Wang, W. C., Xu, D. M., Chau, K. W., Chen, S. (2013). Improved annual rainfall-runoff forecasting using PSO-SVM model based on EEMD. *J. Hydroinformatics*, 15(4), 1377-1390.
- Xu, Z., Huang, X., Lin, L., Wang, Q., Liu, J., Yu, K., and Chen, C. (2020). BP neural networks and random forest models to detect damage by *Dendrolimus punctatus* Walker. *Journal of forestry research*, 31, 107-121.
- Yuan, Y. (2013). Forecasting the movement direction of exchange rate with polynomial smooth support vector machine. *Mathematical and Computer Modelling*, 57(3-4), 932-944.
- Zhang, X., Chen, X., and He, Z. (2010). An ACO-based algorithm for parameter optimization of support vector machines. *Expert systems with applications*, 37(9), 6618-6628.