



مدیریت آب و آبیاری

دوره ۱۲ ■ شماره ۳ ■ پاییز ۱۴۰۱

صفحه‌های ۵۷۹-۵۶۱

DOI: 10.22059/jwim.2022.340171.975

مقاله پژوهشی:

پیش‌بینی اثرات تغییر اقلیم بر منابع آب زیرزمینی با استفاده از روش‌های هوش مصنوعی (مطالعه موردی: دشت تالش)

رضا سراج ابراهیمی^۱، سید سعید اسلامیان^{۱،۲*}، محمد جواد زارعیان^۳

۱. گروه مهندسی عمران، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران.

۲. گروه مهندسی آب، دانشکده کشاورزی، دانشگاه صنعتی اصفهان، اصفهان، ایران.

۳. پژوهشکده مطالعات و تحقیقات منابع آب، مؤسسه تحقیقات آب، تهران، ایران.

تاریخ پذیرش مقاله: ۱۴۰۱/۰۴/۲۸

تاریخ دریافت مقاله: ۱۴۰۰/۱۲/۲۰

چکیده

با توجه به افزایش گازهای گلخانه‌ای و به دنبال آن بحران‌های آبی و اقلیمی متعدد، پیش‌بینی دقیق تغییرات سطح آب زیرزمینی در مدیریت منابع آب مهم و ضروری است. لذا در این مطالعه به بررسی تغییرات اقلیمی دشت تالش تحت سناریوهای RCP با استفاده از Lars-WG و منابع آبی آن از مدل‌های SVR و ANN با استفاده از پارامترهای پمپاژ از آبخوان، تبخیر و تعرق پتانسیل، دمای کمینه و بیشینه، بارش طی بازه زمانی (۱۴۰۰-۱۴۱۰) پرداخته شد. نتایج تغییرات میانگین دمای کمینه و بیشینه تحت سناریوهای RCP حاکی از افزایش دما به میزان ۰/۹ و ۰/۶۹ درجه سانتی‌گراد می‌باشد. همچنین بررسی دقت مدل‌های SVR و ANN نشان می‌دهد که AUC در مرحله آموزش و آزمایش در مدل ANN حداکثر مقادیر AUC برابر با ۰/۸۷۶ و ۰/۷۶۹ محاسبه شد، در حالی که مدل SVR حداکثر مقادیر آن برابر ۰/۸۶۷ و ۰/۸۱۹ برآورد گردید، لذا SVR دقت پیش‌بینی بهتری دارد. همچنین در طی بازه زمانی (۱۳۸۴-۱۳۹۹) سطح آب زیرزمینی به میزان ۱۰ سانتی‌متر و در مدل SVR و ANN به ترتیب به میزان ۱۸ و ۲۰ سانتی‌متر به‌طور متوسط طی بازه زمانی ذکر شده کاهش سطح ایستابی داشته است. همچنین در بازه زمانی (۱۴۰۰-۱۴۱۰) در مدل‌های SVR و ANN به ترتیب به میزان ۲۰ و ۲۱ سانتی‌متر، ۲۰، ۲۱ و ۲۳ سانتی‌متر به ترتیب تحت سناریوهای RCP2.6، RCP4.5 و RCP8.5 کاهش سطح آب زیرزمینی رخ داده است. از این رو، پیشنهاد می‌شود در دشت تالش توجه به الگوی کشت متناسب با منابع آبی در نقاط مختلف دشت در اولویت برنامه‌ریزان بخش کشاورزی قرار گیرد.

کلیدواژه‌ها: آب زیرزمینی، تغییر اقلیم، رگرسیون بردار پشتیبان، شبکه عصبی مصنوعی.

Predicting the effects of climate change on groundwater resources using artificial intelligence methods (Case study: Talesh plain)

Reza Seraj Ebrahimi¹, Saeid Eslamian^{1,2*}, Mohammad Javad Zareian³

1. Department of Civil Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran.

2. Department of Water Engineering, College of Agriculture, Isfahan University of Technology, Isfahan, Iran.

3. Department of Water Resources Study and Research, Water Research Institute, Tehran, Iran.

Received: March 11, 2022

Accepted: July 19, 2022

Abstract

Due to the increase in greenhouse gases and numerous water and climate crises, accurate prediction of the changes groundwater levels is very important and vital in the water resources management. Therefore, in this paper, the climate changes of Talesh plain is studied under RCP scenarios using Lars-WG and its water sources from SVR and ANN models. Also, aquifer pumping parameters, evapotranspiration potential, minimum and maximum temperature and precipitation are used from (2021-2030). The results of the mean minimum and maximum temperature changes under RCP scenarios indicate the temperature increase by 0.9 and 0.69 °C. Also, studying the accuracy of SVR and ANN models shows that the AUC in the training and testing phase in the ANN model, the maximum AUC values were calculated as 0.876 and 0.769, while the SVR model, the maximum values were equal to 0.867 and 0.819. Thus SVR has better predictive accuracy. In addition to that during the time period (2005-2019) the groundwater level has decreased by 10 cm and in the SVR and ANN models by an average nine and six cm respectively more ever during in the time period (2021-2030) ground water levels have decreased in by 18, 20 and 21 cm, 20, 21 and 23 cm under the scenarios RCP2.6, RCP4.5 and RCP8.5 in SVR and ANN models, respectively. Therefore it is suggested that in Talesh plain considering the cultivation pattern appropriate to water resources in different parts of the plain should be the priority for agricultural planners.

Keywords: Artificial Neural Network, Climate change, Groundwater, SVR.

مقدمه

تغییر اقلیم و شرایط آب‌وهوایی، شهرنشینی، افزایش تقاضای آب و آلودگی آب همگی از عواملی هستند که در بحران اخیر آب در سراسر جهان نقش داشته‌اند (Craig et al., 2019; Mukherjee & Ramachandran, 2018). صنعتی شدن جوامع منجر به افزایش انتشار گازهای گلخانه‌ای در سال‌های اخیر شده که باعث گرم شدن کره زمین می‌شود و به نوبه خود بر سایر اجزای سیستم آب-وهوایی تأثیر می‌گذارد که تأثیر قابل توجهی بر سیستم‌های مختلف مانند منابع آب، کشاورزی، شرب و صنعت دارد به طوری که افزایش مداوم انتشار گازهای گلخانه‌ای این موارد را تشدید خواهد کرد و به طور غیرمستقیم بر تخلیه و ذخیره آب‌های زیرزمینی با تغییر شرایط تغذیه‌ای ناشی از ذوب برف، بارندگی و رواناب تأثیر می‌گذارد (Endo et al., 2015; IPCC, 2014; Chen et al., 2017). بنابراین، شناسایی و تجزیه و تحلیل پارامترهای مؤثر مانند پارامترهای اقلیمی می‌تواند کمک زیادی به پیش‌بینی خطرات جدی تهدیدکننده منابع آب زیرزمینی مانند فرونشست و خشکسالی کند (Dehghani et al., 2022). سازمان ملل تخمین می‌زند که حدود ۱/۲ میلیارد نفر در مناطقی با کمبود آب زندگی می‌کنند و حدود یک‌چهارم جمعیت جهان نیز به همین وضعیت نزدیک می‌شوند (Osman et al., 2021). آب‌های زیرزمینی به عنوان یکی از با ارزش‌ترین منابع طبیعی محدود نقش مهمی را در تأمین آب شرب (تأمین تقریباً ۵۰ درصد آب آشامیدنی جهانی در جهان) و صنعت و کشاورزی دارد که ۱۱۶/۲ میلیون هکتار (۳۸ درصد) از اراضی کشاورزی با آب‌های زیرزمینی آبیاری می‌شود (Mohapatra et al., 2021; Siebert et al., 2013).

لذا افزایش تقاضای منابع آب در بخش‌های صنعتی، مسکونی و کشاورزی و به دنبال آن کاهش شدید سطح

آب زیرزمینی در مناطق مختلف جهان توجه مهندسیین منابع آب را برای جلوگیری از عوارض جانبی کاهش سطح آب زیرزمینی از جمله ازدست‌دادن ظرفیت پمپاژ آب از چاه‌ها و فرونشست زمین به خود جلب کرده است. لذا برای مدیریت مؤثر آب‌های زیرزمینی، مدل‌سازی و پیش‌بینی نوسانات سطح آب زیرزمینی به منظور برنامه‌ریزی مسئولان، امری دارای اهمیت است (Guzmán et al., 2018). برحسب عمق آب زیرزمینی از سطح زمین اندازه‌گیری می‌شود و اندازه‌گیری از چاه‌های مشاهده‌ای است که در نقاط مجزای مکانی قرار دارند. هنگام تصمیم‌گیری در مورد مدیریت آب، هیدرولوژیست‌ها نتایج حاصل از بسیاری تکنیک‌ها را در نظر می‌گیرند که به آن‌ها در دستیابی به هدف کمک می‌کند. تکیه بر یک تکنیک ویژه در مدیریت منابع آب می‌تواند بسیار خطرناک باشد، به عنوان نتایج تصمیم‌گیری بسیار حساس است و بر زندگی مردم یک منطقه تأثیر می‌گذارد. از طرفی شبیه‌سازی GWL اغلب توسط مدل‌های فرایندمحور انجام می‌شود. این مدل‌ها به طیفی از داده‌های مکانی-زمانی برای تقریب فرایندهای هیدرولوژیکی پیچیده، سیستم‌های زیرسطحی ناهمگن و فعالیت‌های انسانی نیاز دارند و گسسته‌سازی دامنه‌های مدل و در دسترس بودن داده‌ها در نتیجه هزینه بالا و زمان محاسباتی طولانی و در نهایت دستیابی به شبیه‌سازی دقیق از طریق مدل‌های مبتنی بر فرایند به‌ویژه در کشورهای در حال توسعه بسیار چالش‌برانگیز است (Hosono et al., 2019; White et al., 2020; Kollet et al., 2017; Sun et al., 2016; Mohanty et al., 2013).

پژوهش‌گران در حال بررسی برنامه‌های جایگزین هستند. مدل‌های مبتنی بر داده‌ها براساس روابط بین ورودی‌ها و خروجی‌های مشاهده‌شده هستند و به پارامترهای سیستم و اطلاعاتی در مورد فرایندهای اساسی

(2018) و آب سطحی و زیرزمینی استفاده شده است (Yoon *et al.*, 2011; Sivapragasam & Liong, 2005). تکنیک‌های یادگیری ماشین به‌تازگی در زمینه هیدرولوژی، به‌ویژه در پایش و پیش‌بینی آب‌های زیرزمینی هم از نظر کمی و هم از نظر کیفی و هم‌چنین در زمینه پیش‌بینی در طول رویدادهای شدید آب‌وهوایی مانند سیل و حوادث آب‌وهوا، برجسته شده‌اند (Sadler *et al.*, 2018; Chakraborty *et al.*, 2020; Mukherjee *et al.*, 2021; Li *et al.*, 2020; Ruiz-Álvarez *et al.*, 2021). لذا ماشین‌های بردار پشتیبان به‌دلیل کاربردهای چندمنظوره‌شان و هم‌چنین کاربردهای اخیر در مطالعات پیش‌بینی هیدرولوژیک مشهور هستند. با توجه به مطالعات صورت‌گرفته در ارتباط با پژوهش‌های آبی می‌توان از متغیرهای دما، بارش، تبخیر و تعرق به‌عنوان متغیرهای هواشناسی برای تکنیک‌های یادگیری ماشین و هوش مصنوعی استفاده نمود (Mukherjee & Ramachandran, 2018). هم‌چنین در مدل‌سازی سطح آب زیرزمینی دشت سمنان با استفاده از روش‌های هوش مصنوعی از جمله مدل‌سازی RBF^۱، ANFIS^۲، SVR، ANN و ARIMA^۳ و ترکیب آن‌ها با روش‌های زمین‌آماری برای یافتن راه‌حل‌های مفید برای پیش‌بینی سطح آب‌های زیرزمینی نتایج حاکی از آن است که مدل ANFIS به‌عنوان بهترین مدل، پیش‌بینی دقیق‌تری از سطح آب زیرزمینی با همبستگی ۰/۹۹ و ۰/۸۸ درصد به‌ترتیب در مرحله آزمایش و ترکیب با روش کریجینگ از خود نشان داده است (Rabiee & Karami, 2022). از طرفی نتایج حاکی از آن است که مدل‌های SVR و ANN برای آبخوان‌های آزاد نسبت به آبخوان‌های محصور برای پیش‌بینی‌های تا سه ماه آینده دقیق‌تر می‌باشند. در هر دو سیستم هیدروژئولوژیک برای یک ماه آینده، مدل‌ها بهتر از پیش‌بینی‌های دو و سه ماهه عمل کردند و دقت مدل‌ها با افزایش ماه‌های آینده کاهش یافت. لذا مدل SVR برای

که در یک سیستم رخ می‌دهند نیازی ندارند و به‌طور گسترده در علوم هیدرولوژیک از جمله هیدرولوژی آب‌های زیرزمینی مورد استفاده قرار گرفته‌اند (Alizamir *et al.*, 2018; Yu *et al.*, 2018; Nadiri *et al.*, 2019; Rajaei *et al.*, 2019; Roshni *et al.*, 2019; Roshni *et al.*, 2020). هم‌چنین نتایج Suryanarayana *et al.* (2014) نشان داد رابطه بین پارامترهای اقلیمی و منابع آب زیرزمینی پیچیده و غیرخطی است و به عوامل پیچیده زیادی مانند بارش، تبخیر و ... بستگی دارد، لذا استفاده از مدل‌های هوش مصنوعی شامل مدل‌های ترکیبی مدرن راه‌حل مناسبی برای حل این مشکلات است. در بسیاری از مطالعات، تکنیک‌های هوش مصنوعی مانند شبکه عصبی مصنوعی (ANN)^۴، رگرسیون بردار پشتیبان (SVR)^۳ و ترکیب آن‌ها با الگوریتم‌های بهینه‌سازی برای تخمین و پیش‌بینی سطوح آب‌های زیرزمینی و مشکلات هیدروژئولوژیک مورد استفاده قرار گرفته‌اند (Kumar *et al.*, 2017). دقت بررسی آب‌های زیرزمینی به‌طور عمده به انتخاب پارامترهای مناسب و استفاده از رویکردهای دقیق برای مدل‌سازی مکانی بستگی دارد (Arabameri *et al.*, 2019; Chen *et al.*, 2019, Pham *et al.*, 2018). آن‌هایی که برای بررسی آب‌های زیرزمینی به‌کار می‌روند شامل ماشین بردار پشتیبان (SVM)^۴ می‌باشد (Lee *et al.*, 2018; Huang *et al.*, 2017; Natarajan & Sudheer, 2019; Tang *et al.*, 2019; Mirarabi *et al.*, 2020). اما بسیاری از الگوریتم‌های جدید مشابه نیز با موفقیت در زمینه‌های دیگر با دقت بالا اجرا شده‌اند و بنابراین باید برای پیش‌بینی سطح آب‌های زیرزمینی آزمایش شوند. از جمله این الگوریتم‌های جدید، رگرسیون بردار پشتیبان (SVR) که از استراتژی رگرسیون SVM پیروی می‌کند و به‌طور گسترده در پیش‌بینی سیلاب‌های ناگهانی و مراحل سیلاب (Wu *et al.*, 2019) زمین‌لغزش (Miao *et al.*,)

آب زیرزمینی دشت تالش واقع در ایران و ارزیابی عملکرد آن‌ها با استفاده از ROC-AUC همراه با داده‌های آموزشی و آزمایشی طی بازه زمانی (۱۳۹۹-۱۳۸۴) و (۱۴۱۰-۱۴۰۰) صورت می‌پذیرد که تاکنون پژوهش‌های بسیار اندکی در این زمینه انجام شده است.

مواد و روش‌ها

منطقه مورد مطالعه

دشت تالش واقع در شمال غرب استان گیلان در شمال ایران با وسعت $488/02$ کیلومترمربع در موقعیت $48^{\circ} 48' 5''$ تا $49^{\circ} 11' 15''$ طول شرقی و $37^{\circ} 31' 35''$ تا $38^{\circ} 27' 2''$ عرض شمالی و محدوده ارتفاعی 26 - متر تا 76 متر بالاتر از سطح دریا آزاد قرار دارد (شکل ۱). این دشت یکی از 13 محدوده مطالعاتی حوضه سفیدرود بزرگ و تالش-تالاب انزلی بوده و پایانه اصلی آن حوضه دریای خزر است. از نظر زمین‌شناسی راجع به این دشت می‌توان عنوان نمود که این منطقه از سنگ‌های دگرگونی مربوط به قبل از دوران اول و جوان‌ترین سازند متعلق به رسوبات ناپیوسته عهد حاضر می‌باشد. سنگ‌های آذرین تخریبی به میزان $54/8$ درصد، بیش‌ترین بیرون زدگی را در این دشت دارند. در این پهنه مطالعاتی بیش‌ترین ضریب قابلیت انتقال به میزان 1116 مترمربع در روز و کم‌ترین آن به میزان 114 مترمربع در روز گزارش شده است. هم‌چنین 13432 حلقه چاه نیمه‌عمیق (تا عمق 50 متر) و تعداد 314 حلقه چاه عمیق (بیش از 50 متر) تاکنون در این منطقه شناسایی شده است. هم‌چنین مصارف آب در سه بخش کشاورزی، شرب و صنعت به ترتیب به میزان $320/24$ ، $41/53$ و $16/66$ میلیون مترمکعب می‌باشد. این منطقه از نظر آب‌وهوایی جزو مناطق مرطوب و نیمه‌مرطوب به‌شمار می‌آید و متوسط بارندگی سالانه آن $1139/7$ میلی‌متر می‌باشد. این دشت از

پیش‌بینی سطح آب زیرزمینی یک، دو و سه ماهه بهتر از مدل ANN عمل می‌نماید. بنابراین مدل SVR می‌تواند با موفقیت در پیش‌بینی آب زیرزمینی ماهانه در سیستم‌های محدود و نامحدود استفاده شود (Gaur et al., 2021; Mirarabi et al., 2019). از طرفی مطالعات مختلفی در اقصی نقاط جهان از مدل‌های هوش مصنوعی SVR و ANN صورت گرفته و در آن بیان شده است که هر کدام نسبت به دیگری عملکرد بهتری داشته است (Shiri et al., 2013; Mirzavand et al., 2015; Yoon et al., 2016; Gong et al., 2016; Zhang et al., 2017; Huang et al., 2017; Das et al., 2017; Yadav et al., 2018; Zare & Koch, 2018; Guzman et al., 2019; Tang et al., 2019). نتایج به‌کارگیری مدل‌های هوش مصنوعی SVR و ANN برای مدل‌سازی آب‌های زیرزمینی، توانایی این مدل‌ها را نشان داد که در مقایسه با روش‌های مدل‌سازی فیزیکی، عملکرد بهتری داشتند. با توجه به این‌که کم‌تر به بررسی این دو مدل هوش مصنوعی در ارتباط با پدیده تغییر اقلیم در دشت تالش به‌عنوان یکی از آسیب‌پذیرترین مناطق ساحلی که در معرض تأثیرات یکپارچه فعالیت‌های انسانی و تغییرات آب‌وهوایی قرار دارد صورت گرفته و بیانگر آن است که امنیت غذایی، زندگی و معیشت میلیون‌ها نفر در خطر بوده و نیاز فوری به مدیریت منابع آب زیرزمینی رو به کاهش را به‌طور کارآمد و عاقلانه دارد. در مدل‌سازی فضایی، دو اصل همیشه در بهبود دقت نتایج مؤثر بوده‌اند؛ ۱- دقت داده‌های مورداستفاده و ۲- قدرت مدل مورد استفاده برای پیش‌بینی (Paryani et al., 2022). در این پژوهش، در راستای این دو اصل و هم‌چنین از لحاظ نوآوری پژوهش حاضر، با استفاده از جدیدترین مدل گردش عمومی جو (پنجمین گزارش IPCC) و ریزمقیاس‌نمایی لارس و مقایسه دو مدل داده‌محور SVR و ANN در پیش‌بینی زمانی تغییرات سطح

پیش‌بینی اثرات تغییر اقلیم بر منابع آب زیرزمینی با استفاده از روش‌های هوش مصنوعی (مطالعه موردی: دشت تالش)

بین GWL و متغیرهای هواشناسی موجود در تالش حداقل و حداکثر دمای هوا، تبخیر و تعرق پتانسیل، بارندگی، مقادیر پمپاژ از چاه‌های بهره‌بردار و GWL در سال ۱۳۹۹ و قبل از آن به‌عنوان ورودی استفاده می‌شود. اطلاعات هواشناسی توسط سازمان هواشناسی استان گیلان و داده‌های سطح آب زیرزمینی (چاه‌های مشاهده‌ای) و مقادیر پمپاژ چاه‌های بهره‌بردار توسط سازمان آب منطقه‌ای استان گیلان تهیه شد. کل مجموعه داده به مجموعه داده‌های آموزشی (۱۳۸۴-۱۳۹۴) و آزمایشی (۱۳۹۵-۱۳۹۹) تقسیم می‌شود.

روش تحقیق

هدف این مطالعه استفاده از رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی براساس داده‌های ورودی بالا با فرمت‌های مختلف برای یافتن خروجی بهینه از سطح آب زیرزمینی است. هم‌چنین از معیارهای ارزیابی خطای آماری شامل ریشه میانگین مربعات خطا (RMSE)، میانگین خطای مطلق (MAE) و خطای میانگین (ME)، منحنی (ROC) برای یافتن مناسب‌ترین مدل پیش‌بینی سطح آب زیرزمینی استفاده شد. هم‌چنین به‌منظور پیش‌بینی تغییرات اقلیمی آینده از نرم‌افزار اقلیمی LARS-WG استفاده شد.

رگرسیون بردار پشتیبان

رگرسیون بردار پشتیبان (SVR) یک روش ناپارامتریک است، که توسط Vapnik (1995) توسعه یافته است. به‌عنوان یک ابزار یادگیری ماشین برای طبقه‌بندی و رگرسیون استفاده شده است (Mirarabi et al., 2019). عملکرد SVR به‌شدت به هسته (Kernel) آن بستگی دارد. یک مجموعه داده را در نظر بگیرید $\{(xi, di)\}_i^N$ ، جایی که xi بردار ورودی، di مقدار هدف و N تعداد

رسوبات کواترنری تشکیل شده و مواد تشکیل‌دهنده رسوبات شن، ماسه، سیلت و رس است. در قسمت مرکزی دشت رسوبات دارای حداکثر اندازه و هرچه به سمت بالادست و پایین‌دست دشت حرکت شود از اندازه رسوبات کاسته می‌شود، به‌طوری‌که رسوبات بالادست نسبت به رسوبات پایین‌دست درشت‌تر هستند (Mahmoudpour et al., 2021; Al-Sheikh et al., 2004).

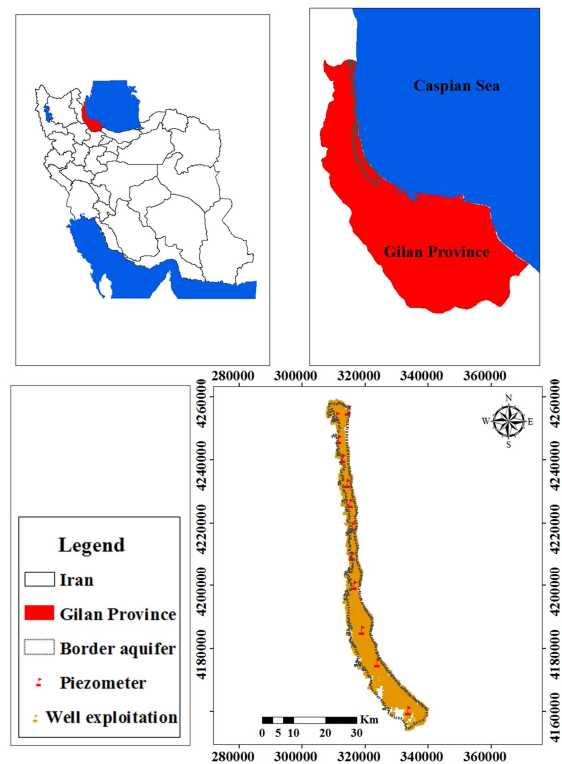


Figure 1. Study area of Talesh plain

داده‌ها

عوامل مختلفی مانند دمای هوا، رطوبت، بارندگی، تبخیر و تعرق، ظرفیت ذخیره‌سازی آبخوان، میزان برداشت از چاه‌ها و تغذیه آبخوان‌ها بر GWL تأثیر می‌گذارند (Jafary et al., 2021; Bayatvarkeshi et al., 2018). اما تنها زیرمجموعه‌ای از این متغیرها در دشت تالش موجود است. براساس مطالعات صورت‌گرفته و تحلیل همبستگی

شبکه عصبی مصنوعی

همان‌طورکه از نام آن پیداست، شبکه عصبی مصنوعی از سیستم عصبی بیولوژیکی توسعه یافته است. لایه‌های ورودی، پنهان و خروجی با گره‌ها و توابع فعال‌سازی، عناصر اساسی یک ساختار ANN تعمیم‌یافته هستند. به‌طورکلی (رابطه ۶):

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) \quad (6)$$

$$m = 0, 1, \dots, (M - 1); a^0 = P; a = a^M$$

جایی‌که در آن P متغیرهای ورودی و a خروجی شبکه است. تعداد لایه‌ها در ساختار شبکه M است. f, b, W و به‌ترتیب تابع فعال‌سازی، بایاس و وزن هستند. Back-Propagation و Resilient BackPropagation الگوریتم‌هایی کارآمد و پرکاربرد برای آموزش یک مدل ANN می‌باشند. به‌منظور ساخت و تأیید مدل‌های SVR و ANN همان‌طورکه در بخش‌های بالا توضیح داده شد، از نرم‌افزار R و بسته‌های R مختلف (بسته e1071 برای مدل‌سازی رگرسیون بردار پشتیبانی و بسته شبکه عصبی برای مدل‌سازی شبکه عصبی مصنوعی) استفاده شد. بسته Python scikit-learn نیز برای ساخت مدل‌های SVR و ANN استفاده شده است. برای هر دو روش مورد استفاده (SVR و ANN)، سطح آب زیرزمینی به‌عنوان متغیر خروجی در نظر گرفته شد. برای ساخت مدل از متغیرهای هواشناسی (حداکثر دما، حداقل دما، بارش، تبخیر و تعرق) به‌همراه پمپاژ از آبخوان و سطح آب زیرزمینی به‌عنوان متغیر وابسته برای ساخت رگرسیون بردار پشتیبانی (SVR) و شبکه عصبی مصنوعی (ANN) استفاده شد. مقادیر حداکثر دما (MaxTemp)، حداقل دما (MinTemp) و تبخیر و تعرق که برای یک زمان مشاهده t_n در مدل‌های SVR و ANN استفاده شده‌اند، درحالی‌که مقدار بارش (Prept) مورد استفاده در مدل‌ها برای زمان مشاهده t_n می‌باشد. مجموع مقادیر بارش بین دو بازه

نمونه‌های داده است. تابع SVR ($f(x)$) به‌صورت رابطه (۱) می‌باشد:

$$f(x) = \omega \cdot \phi(x) + b \quad (1)$$

جایی‌که در آن ω وزن بردار، ϕ تابع انتقال غیرخطی و b بایاس (Bias) می‌باشد. برای دستیابی به عملکرد مناسب $f(x)$ ، مسئله رگرسیون با به حداقل رساندن تابع ریسک ساختاری برآورد می‌شود (رابطه ۲):

$$\text{minimize} = \frac{1}{2} \omega^2 + C \left(\sum_{i=1}^N (\xi_i + \xi_i^*) \right) \quad (2)$$

$$\text{Subject to} \left\{ \begin{array}{l} \omega \cdot \phi(x_i) + b_i - d_i \leq \varepsilon + \xi_i^* \\ d_i - \omega \cdot \phi(x_i) + b_i \leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0, i = 1, 2, \dots, N \end{array} \right\} \quad (3)$$

جایی‌که در آن ξ_i و ξ_i^* متغیرهای slack و c خطای مجاز که بیانگر مبادله عبارت ریسک و منظم‌سازی مشاهده شده است، به‌طوری‌که انحراف ε قابل تحمل باشد و ε تحمل خطا است (Suryanarayana et al., 2014). با ایجاد تغییر مناسب در فرمول اولیه تابع هدف، می‌توانیم آن را به یک مسئله دوگانه برای برنامه‌نویسی درجه دوم تبدیل کنیم. سپس از برنامه‌نویسی درجه دوم برای حل مشکل SVR استفاده می‌شود (رابطه ۴):

$$f(x) = \sum_{i=1}^N (a_i - a_i^*) \cdot k(x_i, x) + b \quad (4)$$

جایی‌که در آن a_i و a_i^* ضرب‌کننده‌های لاگرانژ، $k(x_i, x)$ و تابع کرنل (Kernel) که برابر است با $(\phi(x_i) \cdot \phi(x))$. از معادله فوق برای تحلیل رگرسیون خطی و غیرخطی استفاده می‌شود. انتخاب پارامترهای مناسب برای دستیابی به پیش‌بینی قابل اعتماد بسیار مهم است (Zounemat-Kermani et al., 2016). یکی از توابعی که به‌طور گسترده مورد استفاده قرار می‌گیرد، تابع پایه شعاعی است که در زیر آورده شده است، تابع پایه شعاعی است که در زیر آورده شده است (رابطه ۵):

$$k(x_i, x) = \exp(\gamma \|x - x_i\|^2) \quad (5)$$

جایی‌که γ عرض هسته می‌باشد (Yu et al., 2018).

خورشیدی (مگاژول بر مترمربع در روز) را برای شرایط حاضر و آینده پیش‌بینی کند. همچنین در تحلیل خود همبستگی زمانی داده‌های مینیمم و ماکزیمم مورد استفاده قرار می‌گیرند (Mohammadloo & Tahmasebipour, 2018). مکانیسم عمل آن به این صورت است که در ابتدا با استفاده از تولید داده ماهانه که در برگزیده رفتار اقلیم پایه می‌باشد، تمامی داده‌های ماهانه را مطابق رابطه (V) محاسبه می‌کند:

$$F_{fut} = F_{obs} + (F_{fut}(GCM) - F_{base}(GCM)) \quad (V)$$

که در آن، F_{fit} آینده و F_{obs} گذشته می‌باشد. سپس با حفظ میانگین، انحراف معیار آن‌ها را مطابق رابطه (A) تغییر می‌دهد:

$$F_{fut} = \frac{STD_{obs}}{STD_{base}(GCM)} * STD_{fut}(GCM) \quad (A)$$

تبخیر و تعرق پتانسیل

تبخیر و تعرق حجم تبخیر شده به سطح آب زیرزمینی، بافت خاک، دمای محیط، پوشش گیاهی، شدت باد، رطوبت نسبی و غلظت نمک خاک بستگی دارد. این عامل بیش‌تر در سفره‌های زیرزمینی شمال کشور رخ می‌دهد و گاهی تا ۲۰ میلیون مترمکعب در سال به دلیل تبخیر از بین می‌رود (Iran Water Resources Management Company, 2017)، که در روش SVR و ANN برای دوره پایه و آینده مورد استفاده قرار می‌گیرد. از طرفی در ایران روش Hargreaves-Samani (HS) (رابطه ۹) را مناسب‌تر نسبت به روش Penman-Monteith (PM) پیشنهاد نمودند (Raziei & Pereira, 2013).

زمانی مشاهده t_n و t_{n-1} است. به منظور محاسبه زمان تأخیر بین بارندگی و تأثیر آن بر سطح آب زیرزمینی، مقادیر بارش دوره زمانی قبلی (بارش با تأخیر زمانی یک‌ماهه، نشان داده شده با $Prcpt_LAG$) به مدل اضافه شد، یعنی در حین ساخت مدل برای زمان مشاهده t_n مقدار بارش برای زمان مشاهده t_{n-1} به همراه مقدار بارش برای زمان t_n در نظر گرفته شده است. به دلیل محدودیت داده‌ها، بارش با زمان تأخیر بیش از یک ماه نمی‌تواند به مدل‌ها اضافه شود. بنابراین، با گنجاندن متغیرهای هواشناسی به عنوان متغیرهای کمکی توضیحی همراه با پمپاژ از چاه‌های بهره‌برداری (Pwell)، مدل‌های SVR و ANN تبدیل به $(Pwell + MaxTemp + MinTemp + Prcpt + Eva + Pcpct_LAG)$ می‌شوند.

تغییر اقلیم

در این پژوهش داده‌های بارش و دما روزانه ایستگاه سینوپتیک تالش جهت بررسی پدیده تغییر اقلیم طی دوره زمانی (۱۳۷۱-۱۳۹۹) جمع‌آوری شدند. با توجه به بزرگ‌مقیاس بودن مدل‌های گردش عمومی جو، یکی از راه‌کارهای غلبه بر نقیصه فضایی کم این مدل‌ها استفاده از ریزمقیاس‌نمایی آماری است (جدول ۱). از جمله این مدل‌ها مدل LARS-WG است که برای ریزمقیاس‌نمایی از روش آماری استفاده می‌کند (Karimi & Nabizadeh, 2018). این مدل قادر است داده‌های بارش (میلی‌متر)، دمای کمینه و بیشینه (درجه سانتی‌گراد) و تابش

Table 1. Specifications of the HadGEM2-ES General Circulation Model Available as the Input of Lars-WG Software (Eskandari et al., 2021)

CO ₂ concentrations	Radiative forcing (w/m ²)	Scenario	Resolution	Reference	IPCC	Model
490 PPM before 2100 and then reduce	Its maximum value to 3W/m ² and then reduced	RCP2.6		MOHC,		
690 PPM remains stable after 2100	Its maximum value to 4.5W/m ² after 2100 remains stable	RCP4.5	1.875×1.25	Met Office Hadley Center, UK	IPCC-AR5	HadGEM2-ES
1370 PPM to 2100	More than 8.5W/m ² in 2100	RCP8.5				

$$RMSE = \sqrt{\frac{1}{n} \sum_i^n (hm - hs)^2} \quad (12)$$

که در آن n تعداد داده‌ها، hm مقادیر سطح آب مشاهده به متر و hs مقادیر سطح آب شبیه‌سازی شده به متر می‌باشد. همچنین به منظور بررسی عملکرد مدل LARS-WG از معیارهای آماری R^2 ، RMSE و نش ساتکلیف (NSE) استفاده شد (روابط ۱۳ و ۱۴).

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - E_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (13)$$

$$R^2 = \frac{[\sum_{i=1}^n (O_i - \bar{O}) \cdot (E_i - \bar{E})]^2}{[\sum_{i=1}^n (O_i - \bar{O})^2]^{0.5} \cdot [\sum_{i=1}^n (E_i - \bar{E})^2]^{0.5}} \quad (14)$$

که در آن O_i داده مشاهداتی، E_i داده شبیه‌سازی شده در دوره پایه، \bar{O} میانگین داده مشاهداتی و \bar{E} میانگین داده شبیه‌سازی شده در دوره پایه می‌باشد.

$$PET = 0.0023 \times Ra \times (T_{max} - T_{min})^{0.5} \times \left(\frac{T_{max} + T_{min}}{2} + 17.8 \right) \quad (9)$$

که در آن T_{min} و T_{max} به ترتیب دمای بیشینه و کمینه، Ra تابش خورشیدی (MJ/m^2) extraterrestrial (radiation) که با توجه به عرض جغرافیایی و تعداد روزهای جولیان (Julian day number) به دست می‌آید (شکل ۲).

عملکرد مدل‌ها

برای بررسی عملکرد مدل‌ها در روش SVR و ANN از سه روش زیر برای نشان دادن معیار واسنجی و صحت‌سنجی استفاده شد (روابط ۱۰، ۱۱ و ۱۲):

$$ME = \frac{1}{n} \sum_i^n (hm - hs) \quad (10)$$

$$MAE = \frac{1}{n} \sum_i^n |(hm - hs)| \quad (11)$$

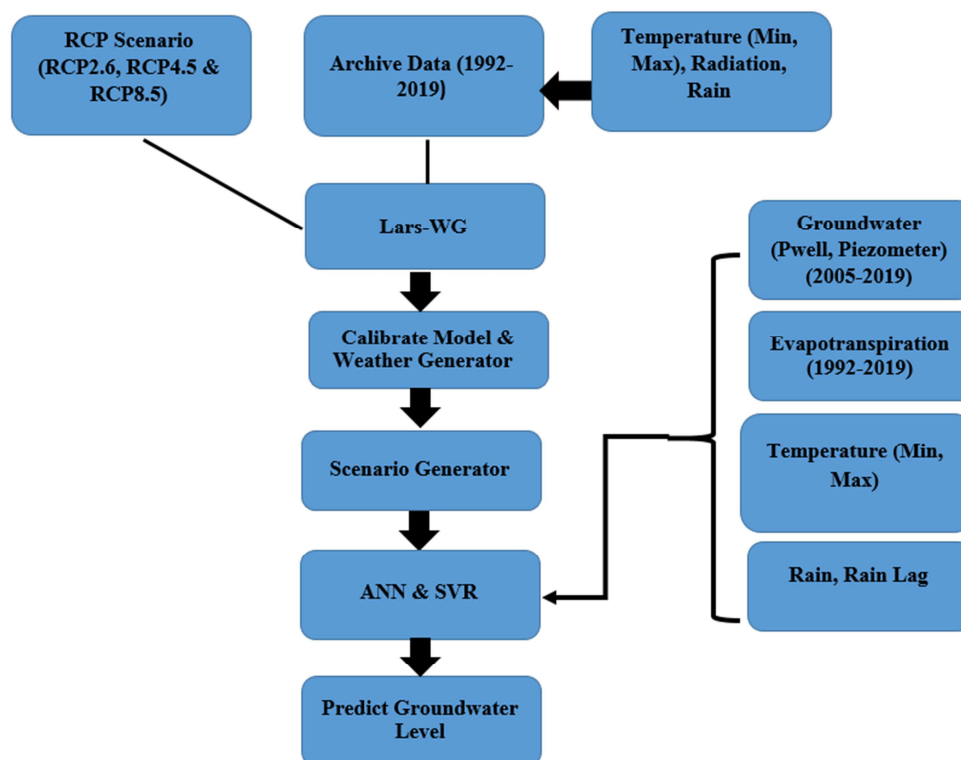


Figure 2. Steps performed for Predict Groundwater Level

نتایج و بحث

خروجی حاصل از مدل گردش عمومی جو مدل HadGem2-es تحت سه سناریوی انتشار RCP2.6، RCP4.5 و RCP8.5 به صورت ماهانه پس از ریزمقیاس‌نمایی در شکل (۳) نمایش داده شده است. نتایج بیانگر آن است که تغییرات دمایی کمینه و بیشینه افزایشی می‌باشد. اما تغییرات بارندگی و تبخیر و تعرق در هر کدام از سناریوها از قاعده خاصی پیروی ننموده و افزایشی و کاهش می‌باشد. لذا نتایج حاکی از آن است که دمای مینیمم در طی دوره (۱۴۱۰-۱۴۰۰) در ایستگاه سینوپتیک تالش تحت سناریوهای RCP2.6، RCP4.5 و RCP8.5 به ترتیب به میزان ۰/۸۹، ۰/۷۸ و ۱/۰۳ درجه سانتی‌گراد افزایش می‌یابد. این تغییرات برای دمای بیشینه به ترتیب به میزان ۰/۶۹، ۰/۵۶ و ۰/۸۴ درجه سانتی‌گراد افزایش خواهد یافت. هم‌چنین در این ایستگاه در سناریوهای RCP2.6 و RCP8.5 به میزان ۵/۳۱ و ۱/۶۱ درصد افزایشی می‌یابد. اما در سناریو RCP4.5 بارندگی به میزان ۰/۱۰ درصد کاهش می‌یابد.

نتایج حاصل از عملکرد مدل HadGem2-es به منظور ارزیابی قابلیت آن در ریزمقیاس‌نمایی سه پارامتر بارش، دمای کمینه و بیشینه طی دوره پایه حاکی از آن است که این مدل قابلیت بالایی را در شبیه‌سازی تغییرات اقلیمی دشت تالش برای دوره (۱۴۱۰-۱۴۰۰) دارد. بر طبق جدول (۲) ریزمقیاس‌نمایی دمای کمینه و بیشینه بهترین عملکرد را نسبت به بارش روزانه دارد که یکی از دلایل آن می‌تواند این باشد که تغییرات دمایی نسبت به تغییرات بارش در طی یک بازه زمانی از توزیع نرمال پیروی می‌کند، درحالی‌که پارامتر بارش داری نوساناتی زیادی می‌باشد. با توجه به دو معیار ارزیابی NSE و R^2 عملکرد مدل HadGem2-es در کلاس خیلی خوب و خوب قرار می‌گیرد.

Table 2. Performance results of HadGem2-es model in predicting climatic variables of Talesh plain (1992-2019)

Station	Parameter	Evaluation criteria		
		R^2	RMSE	NSE
Talesh	precipitation	0.90	17.33	0.78
	Minimum temperature	0.99	0.82	0.97
	Maximum temperature	0.99	0.68	0.98




Figure 3. Average of climate variables during the period (2021-2030) under RCP scenarios compared to the base period

حداکثر مقادیر AUC برابر ۰/۸۷۶ و ۰/۸۶۹ محاسبه شد، درحالی که مدل SVR مقادیر AUC برابر ۰/۸۶۷ و ۰/۸۱۹ برآورد شد (شکل ۴). نتایج هر دو مقادیر AUC داده‌های آموزشی و آزمایشی نشان می‌دهد که SVR دقت پیش‌بینی بهتری دارد.

هم‌چنین در شکل‌های (۵) و (۶) روند تغییرات سطح آب زیرزمینی در دوره مرحله آزمایش و تست و هم‌چنین شبیه‌سازی‌های مبتنی بر دو مدل ANN و SVR را نشان می‌دهد. مبتنی بر این دو نمودار سطح آب زیرزمینی در طی بازه زمانی (۱۳۹۹-۱۳۸۴) به میزان ۱۰ سانتی‌متر و در دو مدل SVR و ANN به ترتیب به میزان ۱ و ۲ سانتی‌متر به‌طور متوسط طی بازه زمانی ذکر شده کاهش سطح ایستابی داشته است. هم‌چنین در بازه زمانی (۱۴۱۰-۱۴۰۰) در مدل‌های SVR و ANN به ترتیب به میزان ۱۸، ۲۰ و ۲۱ سانتی‌متر، ۲۰، ۲۱ و ۲۳ سانتی‌متر به ترتیب تحت سناریوهای RCP2.6، RCP4.5 و RCP8.5 کاهش سطح آب زیرزمینی رخ داده است (شکل ۷).

با توجه به مطالعه صورت‌گرفته نتایج تغییر اقلیم نشان می‌دهد که مؤلفه‌های آماری در زمینه پیش‌بینی مؤلفه‌های اقلیمی عملکردی مناسب را داشته است به‌گونه‌ای که بهترین عملکرد در زمینه پیش‌بینی دمای بیشینه که مقادیر NSE و R^2 در آن بیش از ۹۵ درصد و نزدیک به یک می‌باشد که با طبقه‌بندی *Moriasi et al.* (2007) که چهار کلاس طبقه‌بندی دارد و با نتایج *Jafary et al.* (2021) مطابقت دارد. لذا مبتنی بر عملکرد مدل، نتایج تغییرات مؤلفه‌های اقلیمی دمای کمینه و بیشینه در ماه‌های مختلف سال همسو با گرمایش جهانی می‌باشد به‌گونه‌ای که میانگین سناریوهای RCP به ترتیب دمای کمینه و بیشینه به میزان ۰/۹ و ۰/۶۹ درجه سانتی‌گراد افزایش یافته است که این افزایش دما به‌نوبه خود بر روی ذوب سریع‌تر برف و یا رخداد بارش و هم‌چنین تأثیرات مثبت یا منفی در رویش محصولات

منطبق بر جدول‌های (۳) و (۴) نتایج نشان می‌دهد که هر دو مدل ANN و SVR در پیش‌بینی داده‌های آموزشی کارآمد می‌باشد. اما عملکرد آن‌ها در مرحله اعتبارسنجی ضعیف می‌باشد. بالاترین دقت پیش‌بینی برای ANN با RMSE، MAE و ME به ترتیب برابر با ۰/۰۹؛ ۰/۰۹ و ۰/۰۷ به دست آمد. هم‌چنین دقت پیش‌بینی برای SVR با RMSE، MAE و ME به ترتیب برابر با ۰/۰۷، ۰/۰۱ و ۰/۰۲ محاسبه شد. لذا خطا در هر دو مدل قابل توجه نمی‌باشد. به‌عبارتی عملکرد مدل‌ها مناسب می‌باشد.

Table 3. Error values of piezometers (Meter) in different models in Train Data stage

Model Piezometer	SVR			ANN		
	ME	MAE	RMSE	ME	MAE	RMSE
p1	0.20	0.20	0.20	0.01	0.09	0.11
p2	-0.10	0.20	0.22	-0.03	0.19	0.30
p3	0.10	0.10	0.10	0.01	0.10	0.12
p4	0.12	0.21	0.22	0.02	0.18	0.29
p5	0.06	0.18	0.26	-0.01	0.15	0.24
p6	0.07	0.16	0.17	0.00	0.12	0.16
p7	0.00	0.22	0.38	-0.05	0.22	0.36
p8	0.06	0.60	0.74	0.00	0.19	0.30
p9	-0.05	0.31	0.39	0.00	0.11	0.17
p10	-0.14	0.29	0.30	-0.01	0.12	0.16
p11	-0.08	0.26	0.37	-0.01	0.15	0.27
p12	-0.02	0.12	0.16	-0.03	0.16	0.24
ALL	0.02	0.01	0.07	0.07	0.09	0.09

Table 4. Error values of piezometers (Meter) in different models in Test Data stage

Model Piezometer	SVR			ANN		
	ME	MAE	RMSE	ME	MAE	RMSE
p1	0.20	0.20	0.20	0.04	0.17	0.22
p2	-0.20	0.20	0.20	0.04	0.47	0.61
p3	0.10	0.10	0.10	0.08	0.23	0.27
p4	0.11	0.24	0.25	0.19	0.59	0.79
p5	-0.04	0.16	0.19	-0.12	0.27	0.34
p6	-0.07	0.15	0.16	0.20	0.32	0.47
p7	0.03	0.50	0.78	-0.36	0.60	0.79
p8	-0.14	0.53	0.70	0.22	0.59	0.74
p9	-0.07	0.13	0.16	0.13	0.20	0.26
p10	0.20	0.20	0.20	-0.10	0.17	0.22
p11	-0.03	0.22	0.29	0.01	0.24	0.30
p12	0.01	0.18	0.24	-0.13	0.29	0.41
ALL	-0.01	0.02	0.08	0.14	0.11	0.18

اعتبارسنجی مدل با استفاده از منحنی ROC-AUC با مجموعه داده‌های آموزشی و آزمایشی انجام شد. برای AUC با استفاده از داده‌های آموزش و آزمایش، در مدل ANN

پیش‌بینی اثرات تغییر اقلیم بر منابع آب زیرزمینی با استفاده از روش‌های هوش مصنوعی (مطالعه موردی: دشت تالش)

گرمايش جهانی نشان می‌دهد که بارش در بعضی از سناریوها افزایشی و در بعضی کاهش می‌باشد، اما تبخیر و تعرق منطقه همسو با گرمايش جهانی می‌باشد، لذا در بررسی دقت مدل‌های SVR و ANN نشان می‌دهد که AUC با استفاده از داده‌های آموزش و آزمایش، در مدل ANN حداکثر مقادیر AUC برابر با ۰/۸۷۶ و ۰/۷۶۹ محاسبه شد، در حالی که مدل SVR حداکثر مقادیر آن برابر ۰/۸۶۷ و ۰/۸۱۹ برآورد شد. لذا نتایج هر دو مقادیر AUC داده‌های آموزشی و آزمایشی نشان می‌دهد که SVR دقت پیش‌بینی بهتری دارد. لذا منطبق بر نتایج هر چه ناحیه زیر منحنی ROC-AUC به یک نزدیک‌تر باشد، پیش‌بینی مدل بهتر است (Jafary et al., 2021; Band et al., 2021; Panahi et al., 2020; Emami et al., 2018).

کشاورزی از خود به جای می‌گذارد که با نتایج Koocheki Mohammadloo et al. (2016) & Nasiri Mahalati Hasirchian et al. (2019) Soleyman Nejad et al. (2017) al. (2019) و Eichsteller et al. (2022) مطابقت دارد. هم‌چنین تبخیر و تعرق پتانسیل به میزان ۴/۳۲، ۳/۹۵ و ۵/۱۰ درصد به ترتیب تحت سناریوهای RCP2.6، RCP4.5 و RCP8.5 نسبت به دوره پایه افزایش یافته است که با توجه به این‌که در این منطقه سطح آب زیرزمینی نزدیک به سطح زمین می‌باشد منجر به بیلان منفی در این دشت می‌شود که می‌تواند اثرات منفی بر روی گیاهان این منطقه و یا کشاورزی این منطقه داشت باشد (Babolhekami et al., 2021; Srivastava et al., 2018). از طرفی اثرات تغییر اقلیم مثبتی بر افزایش




Figure 4. ROC curve for SVR and ANN models in Train Data and Test Data stages

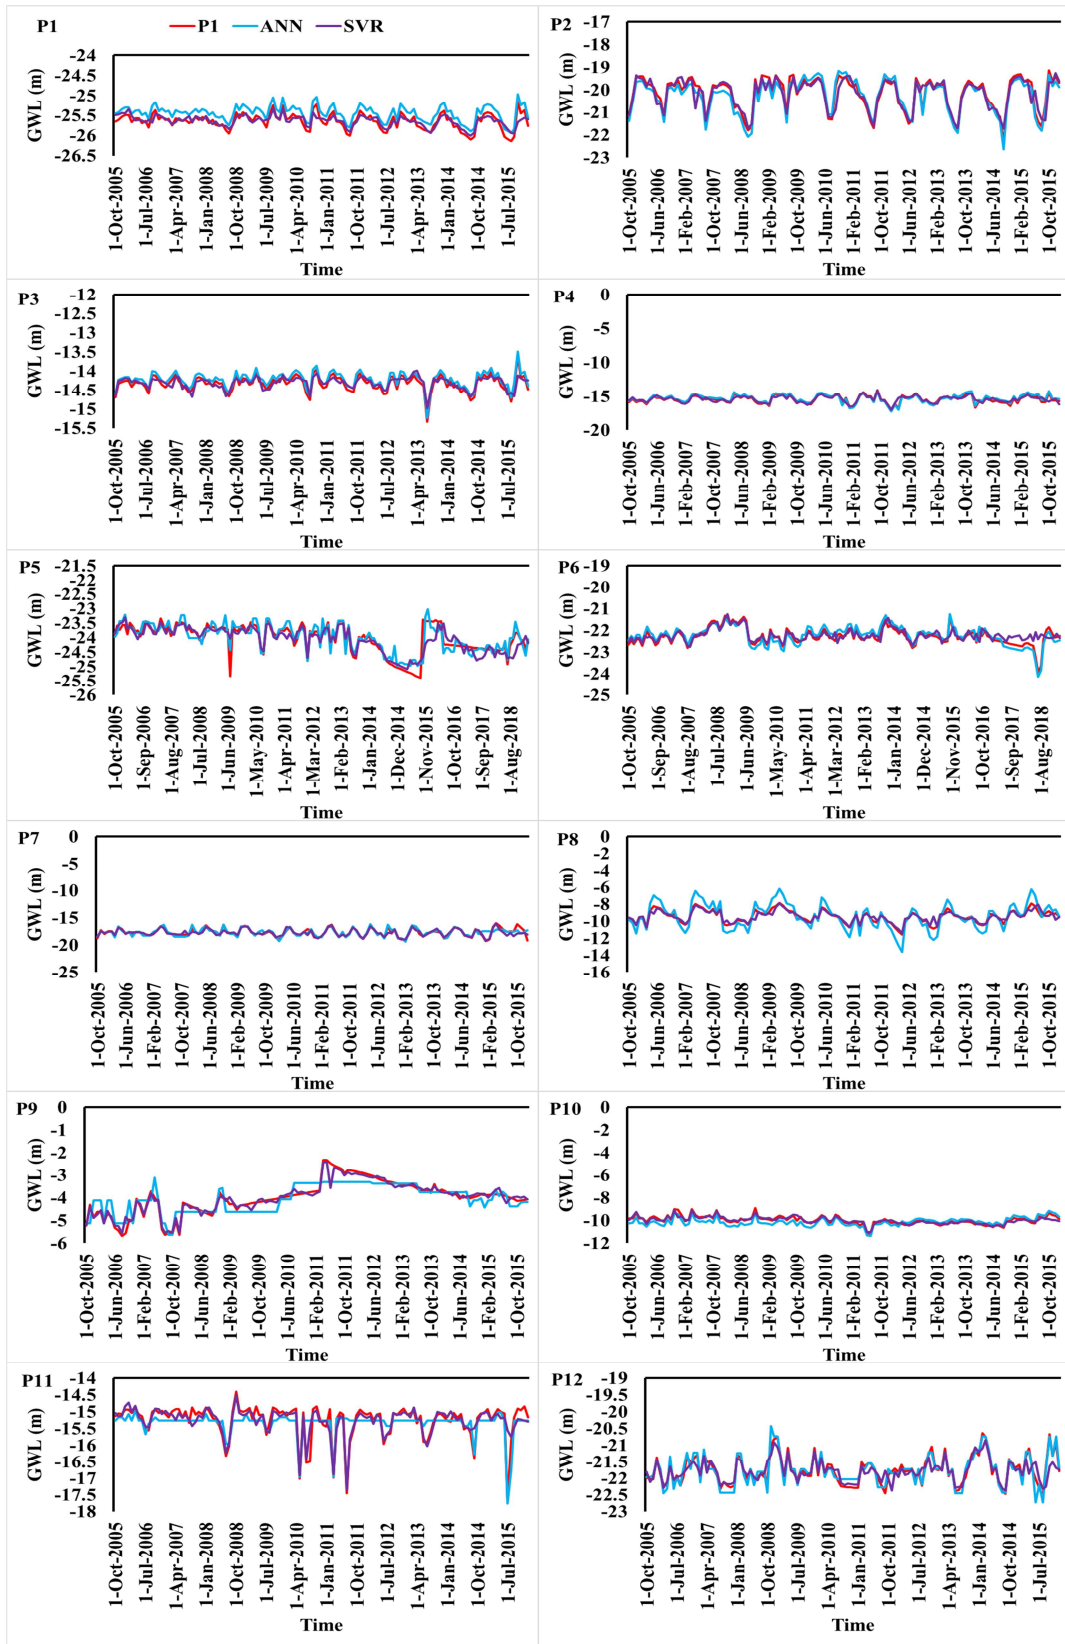


Figure 5. Groundwater level in Train Data period in SVR and ANN models

پیش‌بینی اثرات تغییر اقلیم بر منابع آب زیرزمینی با استفاده از روش‌های هوش مصنوعی (مطالعه موردی: دشت تالش)

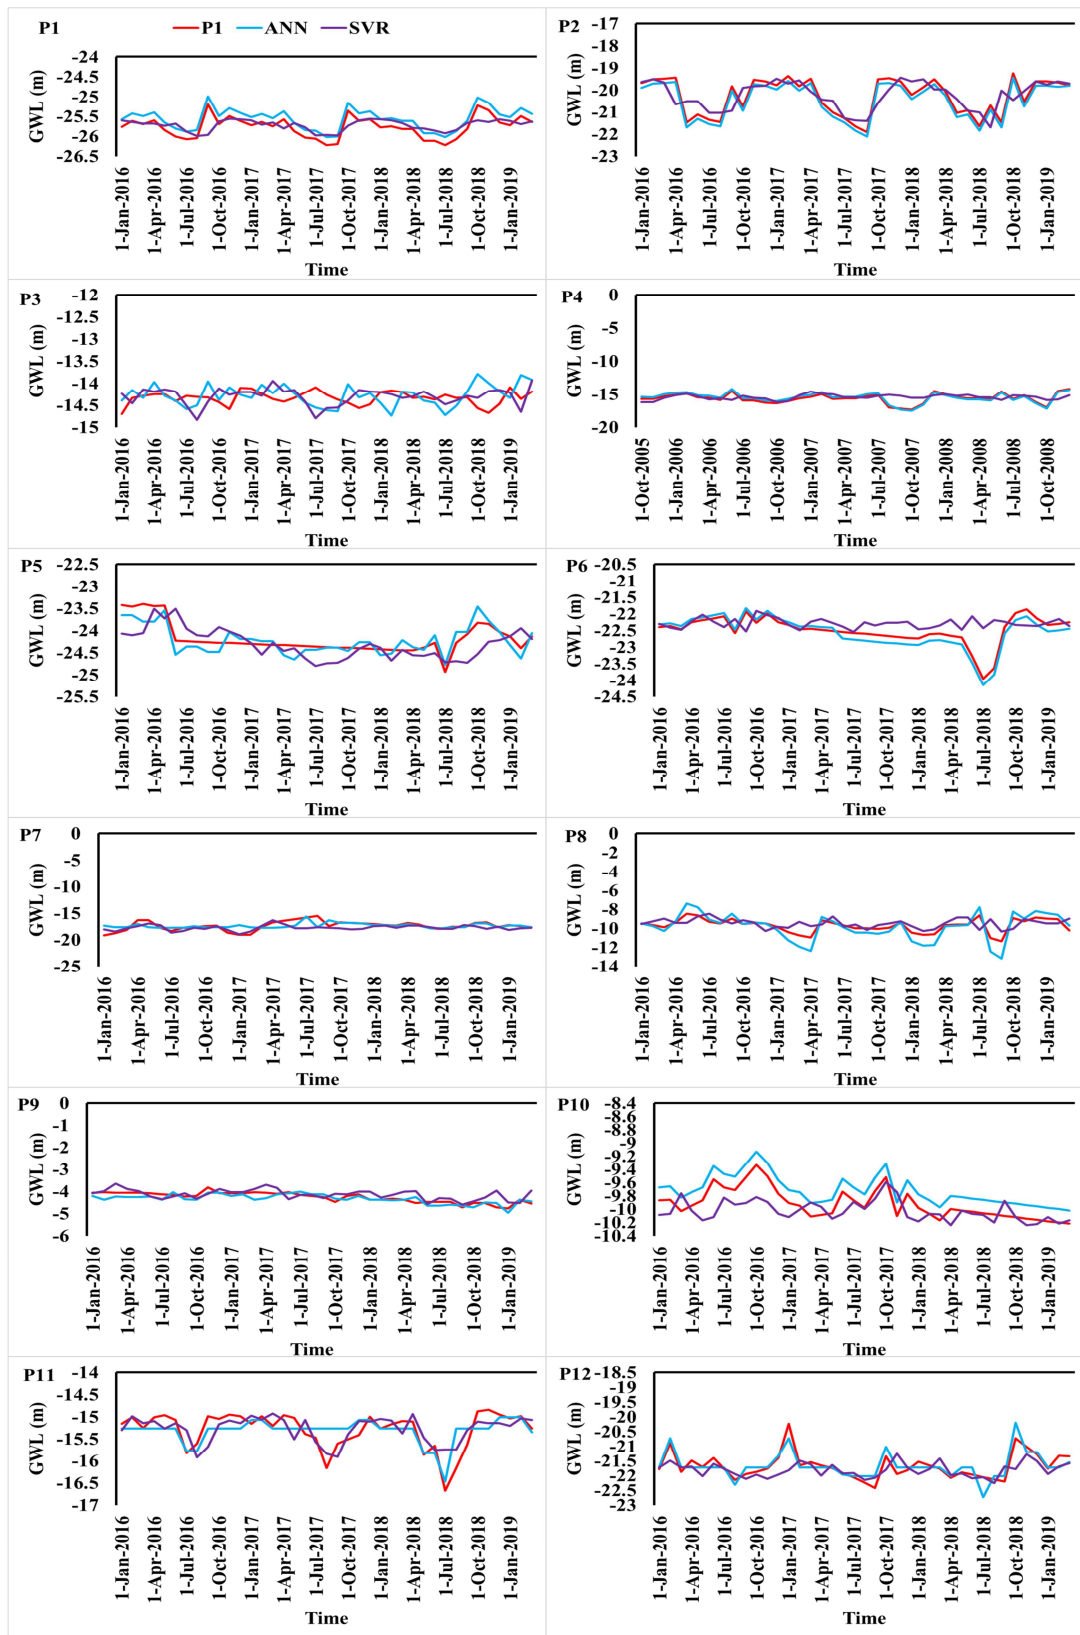


Figure 6. Groundwater level in Test Data period in SVR and ANN models

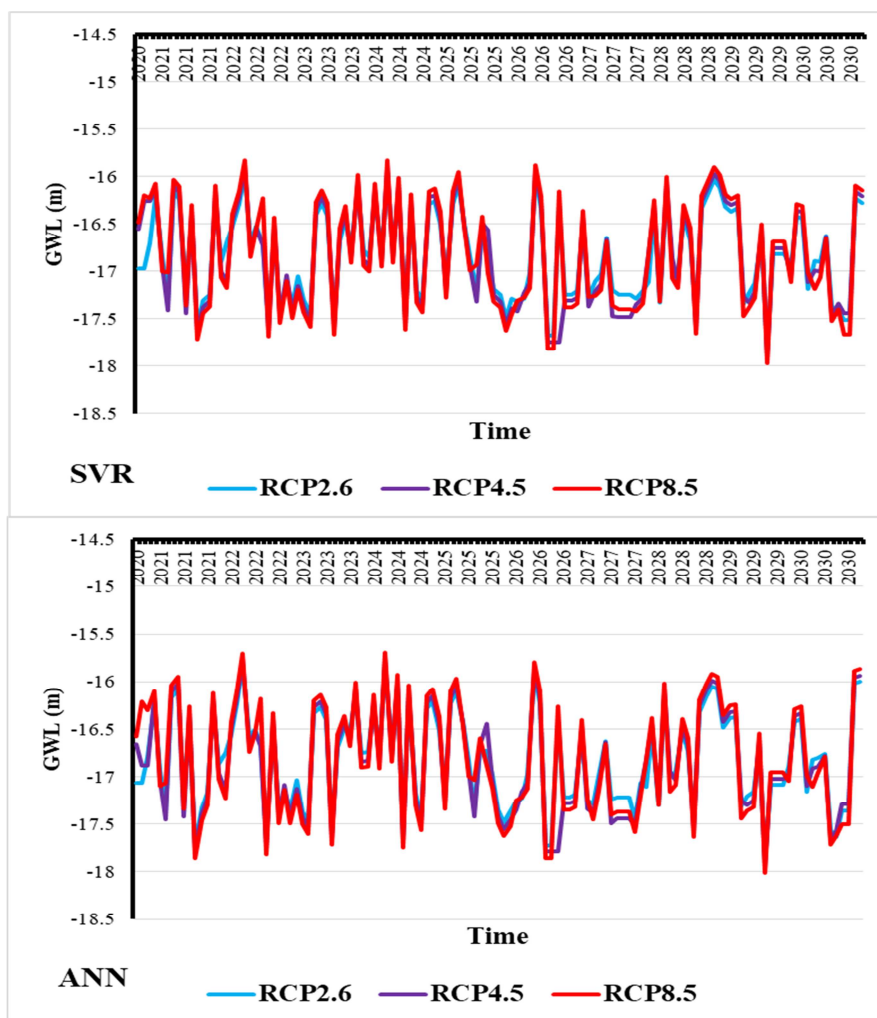


Figure 7. Groundwater level in Talesh plain during the period (2021-2030) under RCP scenarios

زیرزمینی رخ داده، حاکی از آن است که میزان برداشت بیش از حد مجاز و از طرفی تغییرات اقلیمی رخ داده و به دنبال آن با پیشرفت روزافزون تکنولوژی، بشر در راستای دستیابی به حداکثر منافع و سود بدون در نظر گرفتن نیازهای نسل‌های آتی می‌باشد (Jamour *et al.*, 2019; Salem *et al.*, 2018; Panahi *et al.*, 2018; Varalakshmi *et al.*, 2014). هم‌چنین پیشنهاد می‌شود که نتایج این پژوهش با نتایج به دست آمده از مدل‌های ریاضی مانند GMS و MODFLOW نیز مورد بررسی و تجزیه و تحلیل قرار گیرد که نتایج آن نشان‌دهنده دقت بالاتر می‌باشد.

از طرفی تغییر در عملکرد و توانایی پیش‌بینی ممکن است به دلیل عدم تشابه در ساختارهای مدل باشد. پس از قابلیت‌های مدل در پیش‌بینی سطح آب زیرزمینی، در طی بازه زمانی (۱۳۹۹-۱۳۸۴) سطح آب زیرزمینی به میزان ۱۰ سانتی‌متر و در دو مدل SVR و ANN به ترتیب به میزان ۸ و ۱۰ سانتی‌متر به طور متوسط طی بازه زمانی ذکر شده کاهش سطح ایستابی داشته است. هم‌چنین در بازه زمانی (۱۴۱۰-۱۴۰۰) در مدل‌های SVR و ANN به ترتیب به میزان ۱۸، ۲۰ و ۲۱ سانتی‌متر، ۲۰، ۲۱ و ۲۳ سانتی‌متر به ترتیب تحت سناریوهای RCP2.6، RCP4.5 و RCP8.5 کاهش سطح آب

نتیجه‌گیری

از میان حدود ۵۴۴ سفره آب زیرزمینی ایران، ۱۷۸ آبخوان مهم دارای قابلیت اطمینان هستند. از آنجایی که ایران کشوری خشک و نیمه‌خشک است، بیش‌تر آب در بخش کشاورزی مصرف می‌شود که به‌طور عمده از منابع آب زیرزمینی تأمین می‌شود. لذا بیش از نیمی از دشت‌های این کشور برای کشاورزی ممنوع اعلام شده است که نگران‌کننده است. بنابراین با توجه به هزینه‌های زیاد و کمبود نیروی انسانی، وضعیت آبخوان‌های اصلی هر دو سال یک‌بار به‌طور نامنظم بررسی می‌شود، لذا ضرورت مدل‌سازی (ANN و SVR) به‌منظور مدیریت هرچه بهتر با توجه به گسترش هوش مصنوعی بیش‌ازپیش ضروری می‌باشد. با توجه به این‌که کشور ایران بیش‌ترین مساحت آن در مناطق خشک و نیمه‌خشک واقع شده است و کمبود آب آن را می‌توان به بارندگی ناکافی، عدم مدیریت صحیح و توسعه کشاورزی و به‌دنبال آن بهره‌برداری بیش از حد دانست. هم‌چنین در قرن گذشته تحولات اقلیمی باعث نگرانی‌های زیادی برای دولت‌ها و جوامع شده است. بنابراین شناخت و رصد این تغییرات با استفاده از مدل‌های مذکور برای برنامه‌ریزی‌های حال و آینده بسیار دارای اهمیت می‌باشد. با توجه به این‌که تنها مناطق شمالی آن به‌عنوان کمربندی سبز شناخته شده و قطب کشت برنج ایران که یکی از محصولات اساسی در تأمین امنیت غذایی می‌باشد. لذا بیش‌ازپیش تمهیدات لازم به‌منظور مدیریت منابع آبی در این مناطق دارای اهمیت است. هم‌چنین نتایج به‌طورکلی حاکی از آن است که دمای هوا در دشت تالش همپای افزایش دمای جهانی در حال افزایش است. در نهایت با توجه به نتایج به‌دست‌آمده می‌توان ادعان نمود، با توجه به این‌که شهرهای شمالی ایران درحالی‌که لقب کمربند سبز ایران را به خود اختصاص داده‌اند، با این‌حال لزوم تدوین راهبردهای

جهانی بیش از پیش ضروری می‌باشد و در نهایت می‌توان بیان نمود براساس گزارش IPCC جمعیت در حال افزایش بوده و این جمعیت رو به افزایش نیاز به غذا و انرژی دارد، لذا انسان با فشار به منابع طبیعی و هم‌چنین منابع آب زیرزمینی درصدد تأمین نیازهای حیاتی خود می‌باشد از طرفی دیگر این تغییرات اقلیمی باعث محدودیت در این منابع می‌شود.

پی‌نوشت‌ها

1. Groundwater Level
2. Artificial Neural Network
3. Support Vector Regression
4. Support Vectore Machine
5. Radial Basis Function
6. Neuro-Fuzzy Inference System
7. AutoRegressive Integrated Moving Average

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

منابع

1. Alizamir, M., Kisi, O., & Zounemat-Kermani, M. (2018). Modelling long-term groundwater fluctuations by extreme learning machine using hydro-climatic data. *Hydrological sciences journal*, 63(1), 63-73.
2. Al-Sheikh, A., Hamrah, M., Helali, M., & Fatehi, A. (2004). Application of GIS in Groundwater Resources Balance of Talesh Plain, *Applied Research in Geographical Sciences (Geographical Sciences)*, 3(3-4), 99-119. (In Persian).
3. Arabameri, A., Rezaei, K., Cerda, A., Lombardo, L., & Rodrigo-Comino, J. (2019). GIS-based groundwater potential mapping in Shahroud plain, Iran. A comparison among statistical (bivariate and multivariate), data mining and MCDM approaches. *Science of the total environment*, 658, 160-177.
4. Babolhekami, A., Gholami Sefidkouhi, M., & Emadi, A. (2020). The Impact of Climate Change on Reference Evapotranspiration in Mazandaran Province. *Iranian Journal of Soil and Water Research*, 51(2), 387-401. (In Persian) doi: 10.22059/ijswr.2019.285571.668266.

5. Band, S. S., Heggy, E., Bateni, S. M., Karami, H., Rabiee, M., Samadianfard, S., ... & Mosavi, A. (2021). Groundwater level prediction in arid areas using wavelet analysis and Gaussian process regression. *Engineering Applications of Computational Fluid Mechanics*, 15(1), 1147-1158.
6. Bayatvarkeshi, M., Fasihi, R., (2018). Monitoring of groundwater quality changes trend in four plains of Gilan province during a 12-year period. *Iranian Journal of Health and Environment*, 10 (4), 547-558.(In Persian).
7. Chakraborty, M., Sarkar, S., Mukherjee, A., Shamsudduha, M., Ahmed, K. M., Bhattacharya, A., & Mitra, A. (2020). Modeling regional-scale groundwater arsenic hazard in the transboundary Ganges River Delta, India and Bangladesh: Infusing physically-based model with machine learning. *Science of the total environment*, 748, 141107.
8. Chen, W., Pradhan, B., Li, S., Shahabi, H., Rizeei, H. M., Hou, E., & Wang, S. (2019). Novel hybrid integration approach of bagging-based fisher's linear discriminant function for groundwater potential analysis. *Natural Resources Research*, 28(4), 1239-1258.
9. Chen, Y., Li, Z., Fan, Y., Wang, H., & Deng, H. (2015). Progress and prospects of climate change impacts on hydrology in the arid region of northwest China. *Environmental Research*, 139, 11-19.
10. Craig, C. A., Feng, S., & Gilbertz, S. (2019). Water crisis, drought, and climate change in the southeast United States. *Land use policy*, 88, 104110.
11. Das, U. K., Roy, P., & Ghose, D. K. (2019). Modeling water table depth using adaptive Neuro-Fuzzy Inference System. *ISH Journal of Hydraulic Engineering*, 25(3), 291-297.
12. Dehghani, R., Poudesh, H. T., & Izadi, Z. (2022). The effect of climate change on groundwater level and its prediction using modern meta-heuristic model. *Groundwater for Sustainable Development*, 16, 100702.
13. Eichsteller, M., Njagi, T., & Nyukuri, E. (2022). The role of agriculture in poverty escapes in Kenya—Developing a capabilities approach in the context of climate change. *World Development*, 149, 105705.
14. Emami, H., Jafari Godeneh, M., Nazari Samani, A., Malekian, A. (2018). Application of Geomorphometric Indices in Spatial Modeling of Groundwater Springs Occurrence in Middle Alborz Region, with Possible Control Weight Approach, *Remote Sensing and GIS of Iran*, 10 (2), 61-74.(In Persian).
15. Endo, H., Kitoh, A., Mizuta, R., & Ishii, M. (2017). Future changes in precipitation extremes in East Asia and their uncertainty based on large ensemble simulations with a high-resolution AGCM. *Sola*, 13, 7-12.
16. Eskandari Damaneh, H., Jafari, M., Eskandari Damaneh, H., Behnia, M., Khoorani, A., & Tiefenbacher, J. P. (2021). Testing possible scenario-based responses of vegetation under expected climatic changes in Khuzestan Province. *Air, Soil and Water Research*, 14, 1-17
17. Gaur, S., Johannet, A., Graillot, D., & Omar, P. J. (2021). Modeling of groundwater level using artificial neural network algorithm and WA-SVR Model. In *Groundwater resources development and planning in the semi-arid region* (pp. 129-150). Springer, Cham.
18. Gong, Y., Zhang, Y., Lan, S., & Wang, H. (2016). A comparative study of artificial neural networks, support vector machines and adaptive neuro fuzzy inference system for forecasting groundwater levels near Lake Okeechobee, Florida. *Water resources management*, 30(1), 375-391.
19. Guzman, S. M., Paz, J. O., Tagert, M. L. M., & Mercer, A. E. (2019). Evaluation of seasonally classified inputs for the prediction of daily groundwater levels: NARX networks vs support vector machines. *Environmental Modeling & Assessment*, 24(2), 223-234.
20. Guzmán, S. M., Paz, J. O., Tagert, M. L. M., Mercer, A. E., & Pote, J. W. (2018). An integrated SVR and crop model to estimate the impacts of irrigation on daily groundwater levels. *Agricultural systems*, 159, 248-259.
21. Hasirchian, M., Zahabiyou, B., & Khazaei, M. (2019). Assessment of SDSM model performance to investigate the effect of climate change on precipitation and temperature. *Irrigation and Water Engineering*, 9(2), 108-120.(In Persian). doi: 10.22125/iwe.2019.87385.
22. Hosono, T., Yamada, C., Shibata, T., Tawara, Y., Wang, C. Y., Manga, M., ... & Shimada, J. (2019). Coseismic groundwater drawdown along crustal ruptures during the 2016 Mw 7.0 Kumamoto earthquake. *Water Resources Research*, 55(7), 5891-5903.
23. Huang, F., Huang, J., Jiang, S. H., & Zhou, C. (2017). Prediction of groundwater levels using evidence of chaos and support vector machine. *Journal of Hydroinformatics*, 19(4), 586-606.

24. IPCC. (2014). Climate Change 2013-The Physical Science Basis: Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change, website: <https://www.ipcc.ch>.
25. Iran Water Resources Management Company, (2017). Iran Water Resources Balance. *Ministry of Energy, Tehran, Iran*. (In Persian).
26. Jafary Godeneh, M., Salajegheh, A., & Malekian, A. (2021). Investigating the Impact of Different Climate Change Scenarios on Groundwater Fluctuations in Arid and Semi-Arid Regions (Case Study: Kerman Plain), *Irrigation & Water Engineering*, 11(44), 252-275. (In Persian).
27. Jamour, R., Eilbeigy, M., & Morsali, M. (2019). Assessment of the Land Subsidence Crisis and the Advent of Salt Water in the Minab Plain Aquifer. *Iranian journal of Ecohydrology*, 6(1), 223-238. (In Persian).
28. Karimi, M., & Nabizadeh, A. (2018). Evaluation of Climate Change Impacts on Climate Parameters of Lake Urmia Watershed during 2040-2011 Using LARS-WG Model. *Journal of Geography and Planning*, 22(65), 267-285. (In Persian).
29. Kollet, S., Sulis, M., Maxwell, R.M., Paniconi, C., Putti, M., Bertoldi, G., Coon, E.T., Cordano, E., Endrizzi, S., Kikinzon, E., & Mouche, E., (2017). The integrated hydrologic model intercomparison project, IH-MIP2: A second set of benchmark results to diagnose integrated hydrology and feedbacks. *Water Resources Research*, 53(1), 867-890.
30. Koocheki, A., & Nasiri Mahalati, M. (2016). Climate Change Effects on Agricultural Production of Iran: II. Predicting Productivity of Field Crops and Adaptation Strategies. *Iranian Journal of Field Crops Research*, 14(1), 19-20. (In Persian).
31. Kouziokas, G. N., Chatzigeorgiou, A., & Perakis, K. (2018). Multilayer feed forward models in groundwater level forecasting using meteorological data in public management. *Water resources management*, 32(15), 5041-5052.
32. Kumar, D., Thakur, M., Dubey, C. S., & Shukla, D. P. (2017). Landslide susceptibility mapping & prediction using support vector machine for Mandakini River Basin, Garhwal Himalaya, India. *Geomorphology*, 295, 115-125.
33. Lee, S., Hong, S. M., & Jung, H. S. (2018). GIS-based groundwater potential mapping using artificial neural network and support vector machine models: the case of Boryeong city in Korea. *Geocarto international*, 33(8), 847-861.
34. Li, M., Zhang, Y., Wallace, J., & Campbell, E. (2020). Estimating annual runoff in response to forest change: a statistical method based on random forest. *Journal of Hydrology*, 589, 125168.
35. Mahmoudpour, H., Janat Rostami, S., & Ashrafzadeh, A. (2021). Qualitative assessment of the coastal aquifer of Talesh plain using the modified DRASTIC vulnerability model, *Journal of Soil and Water Sciences (Agricultural Science and Technology and Natural Resources)*, 24 (3), 97-118. (In Persian).
36. Miao, F., Wu, Y., Xie, Y., & Li, Y. (2018). Prediction of landslide displacement with step-like behavior based on multialgorithm optimization and a support vector regression model. *Landslides*, 15(3), 475-488.
37. Mirarabi, A., Nassery, H. R., Nakhaei, M., Adamowski, J., Akbarzadeh, A. H., & Alijani, F. (2019). Evaluation of data-driven models (SVR and ANN) for groundwater-level prediction in confined and unconfined systems. *Environmental Earth Sciences*, 78(15), 1-15.
38. Mirzavand, M., Khoshnevisan, B., Shamshirband, S., Kisi, O., Ahmad, R., & Akib, S. (2015). Evaluating groundwater level fluctuation by support vector regression and neuro-fuzzy methods: a comparative study. *Natural Hazards*, 1(1), 1-15.
39. Mohammadloo, M., Haghizadeh, A., Zinivand, H., & Tahmasbi Pour, N. (2017). Evaluation of climate change on temperature and precipitation trends in Barandozchay watershed, In the West Azerbaijan, using General Circulation Models (GCM). *Geographical space*, 16(56), 151-168. (In Persian).
40. Mohammadloo, M., & Tahmasebipour, N. (2018). Assessing the Impacts of Climate Change on Climate Classifications in Parts of Northwestern Iran. *Rainwater Surface Systems*, 5(4), 35-46. (In Persian).
41. Mohanty, S., Jha, M. K., Kumar, A., & Panda, D. K. (2013). Comparative evaluation of numerical model and artificial neural network for simulating groundwater flow in Kathajodi-Surua Inter-basin of Odisha, India. *Journal of Hydrology*, 495, 38-51.
42. Mohapatra, J. B., Jha, P., Jha, M. K., & Biswal, S. (2021). Efficacy of machine learning techniques in predicting groundwater fluctuations in agro-ecological zones of India. *Science of The Total Environment*, 785, 147319.

43. Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900.
44. Mukherjee, A., & Ramachandran, P. (2018). Prediction of GWL with the help of GRACE TWS for unevenly spaced time series data in India: Analysis of comparative performances of SVR, ANN and LRM. *Journal of hydrology*, 558, 647-658.
45. Mukherjee, A., Sarkar, S., Chakraborty, M., Duttagupta, S., Bhattacharya, A., Saha, D., ... & Gupta, S. (2021). Occurrence, predictors and hazards of elevated groundwater arsenic across India through field observations and regional-scale AI-based modeling. *Science of The Total Environment*, 759, 143511.
46. Nadiri, A., Naderi, K., Khatibi, R., & Gharekhani, M. (2019). Modelling groundwater level variations by learning from multiple models using fuzzy logic. *Hydrological sciences journal*, 64(2), 210-226.
47. Natarajan, N., & Sudheer, C. (2020). Groundwater level forecasting using soft computing techniques. *Neural Computing and Applications*, 32(12), 7691-7708.
48. Osman, A. I. A., Ahmed, A. N., Chow, M. F., Huang, Y. F., & El-Shafie, A. (2021). Extreme gradient boosting (Xgboost) model to predict the groundwater levels in Selangor Malaysia. *Ain Shams Engineering Journal*, 12(2), 1545-1556.
49. Panahi, M., Misaghi, F., & Asgari, P. (2018). Simulation and estimation of groundwater level fluctuations using GIS (Case study of Zanjan plain). *Journal of Environmental Sciences*, 16 (1), 1-14. (In Persian).
50. Panahi, M., Sadhasivam, N., Pourghasemi, H. R., Rezaie, F., & Lee, S. (2020). Spatial prediction of groundwater potential mapping based on convolutional neural network (CNN) and support vector regression (SVR). *Journal of Hydrology*, 588, 125033.
51. Paryani, S., Neshat, A., Pourghasemi, H. R., Ntona, M. M., & Kazakis, N. (2022). A novel hybrid of support vector regression and metaheuristic algorithms for groundwater spring potential mapping. *Science of The Total Environment*, 807, 151055.
52. Pham, B. T., Hoang, T. A., Nguyen, D. M., & Bui, D. T. (2018). Prediction of shear strength of soft soil using machine learning methods. *Catena*, 166, 181-191.
53. Rabiee, M., & Karami, H. (2022). Estimation of Temporal and Spatial Variations of Groundwater Level by Combining Intelligent Models and Geostatistical Methods) Semnan Plain. *Irrigation and Water Engineering*, 12(3), 221-243. (In Persian).
54. Rajaei, T., Ebrahimi, H., & Nourani, V. (2019). A review of the artificial intelligence methods in groundwater level modeling. *Journal of hydrology*, 572, 336-351.
55. Raziqi, T., & Pereira, L. S. (2013). Estimation of ETo with Hargreaves-Samani and FAO-PM temperature methods for a wide range of climates in Iran. *Agricultural water management*, 121, 1-18.
56. Roshni, T., Jha, M. K., & Drisya, J. (2020). Neural network modeling for groundwater-level forecasting in coastal aquifers. *Neural Computing and Applications*, 32(16), 12737-12754.
57. Roshni, T., Jha, M. K., Deo, R. C., & Vandana, A. (2019). Development and evaluation of hybrid artificial neural network architectures for modeling spatio-temporal groundwater fluctuations in a complex aquifer system. *Water Resources Management*, 33(7), 2381-2397.
58. Ruiz-Álvarez, M., Gomariz-Castillo, F., & Alonso-Sarriá, F. (2021). Evapotranspiration response to climate change in semi-arid areas: Using random forest as multi-model ensemble method. *Water*, 13(2), 222.
59. Sadler, J. M., Goodall, J. L., Morsy, M. M., & Spencer, K. (2018). Modeling urban coastal flood severity from crowd-sourced flood reports using Poisson regression and Random Forest. *Journal of hydrology*, 559, 43-55.
60. Salem, G. S. A., Kazama, S., Shahid, S., & Dey, N. C. (2018). Impacts of climate change on groundwater level and irrigation cost in a groundwater dependent irrigated region. *Agricultural water management*, 208, 33-42.
61. Shiri, J., Kisi, O., Yoon, H., Lee, K. K., & Nazemi, A. H. (2013). Predicting groundwater level fluctuations with meteorological effect implications-A comparative study among soft computing techniques. *Computers & Geosciences*, 56, 32-44.
62. Siebert, S., Henrich, V., Frenken, K., & Burke, J. (2013) Update of the digital global map of irrigation areas to version 5. *Rheinische Friedrich-Wilhelms-Universität, Bonn, Germany and FAO, Rome, Italy*.
63. Sivapragasam, C., & Liong, S. Y. (2005). Flow categorization model for improving forecasting. *Hydrology Research*, 36(1), 37-48.

64. Soleymani Nejad, S., Dourandish, A., Sabouhi, M., & Banayan Aval, M. (2019). The Effects of Climate Change on Cropping Pattern (Case Study: Mashhad Plain). *Iranian Journal of Agricultural Economics and Development Research*, 50(2), 249-263. (In Persian).
65. Srivastava, A. K., Mboh, C. M., Zhao, G., Gaiser, T., & Ewert, F. (2018). Climate change impact under alternate realizations of climate scenarios on maize yield and biomass in Ghana. *Agricultural Systems*, 159, 157-174.
66. Sun, Y., Wendi, D., Kim, D. E., & Liang, S. Y. (2016). Application of artificial neural networks in groundwater table forecasting—a case study in a Singapore swamp forest. *Hydrology and Earth System Sciences*, 20(4), 1405-1412.
67. Suryanarayana, C., Sudheer, C., Mahammood, V., & Panigrahi, B. K. (2014). An integrated wavelet-support vector machine for groundwater level prediction in Visakhapatnam, India. *Neurocomputing*, 145, 324-335.
68. Tang, Y., Zang, C., Wei, Y., & Jiang, M. (2019). Data-driven modeling of groundwater level with least-square support vector machine and spatial-temporal analysis. *Geotechnical and Geological Engineering*, 37(3), 1661-1670.
69. Vapnik, V. (1995). The nature of statistical learning theory. *New York: Springer-Verlag*.
70. Varalakshmi, V., B. Venkateswara Rao, L. SuriNaidu, & M. (2014). Tejaswini. Groundwater flow modeling of a hard rock aquifer: case study. *Journal of Hydrologic Engineering*, 19(5), 877-886.
71. Wei, Z. L., Wang, D. F., Sun, H. Y., & Yan, X. (2020). Comparison of a physical model and phenomenological model to forecast groundwater levels in a rainfall-induced deep-seated landslide. *Journal of Hydrology*, 586, 124894.
72. White, J. T., Knowling, M. J., & Moore, C. R. (2020). Consequences of groundwater-model vertical discretization in risk-based decision-making. *Groundwater*, 58(5), 695-709.
73. Wu, J., Liu, H., Wei, G., Song, T., Zhang, C., & Zhou, H. (2019). Flash flood forecasting using support vector regression model in a small mountainous catchment. *Water*, 11(7), 1327.
74. Yadav, B., Mathur, S., Ch, S., & Yadav, B. K. (2018). Data-based modelling approach for variable density flow and solute transport simulation in a coastal aquifer. *Hydrological Sciences Journal*, 63(2), 210-226.
75. Yoon, H., Hyun, Y., Ha, K., Lee, K. K., & Kim, G. B. (2016). A method to improve the stability and accuracy of ANN-and SVM-based time series models for long-term groundwater level predictions. *Computers & geosciences*, 90, 144-155.
76. Yoon, H., Jun, S. C., Hyun, Y., Bae, G. O., & Lee, K. K. (2011). A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of hydrology*, 396(1-2), 128-138.
77. Yu, H., Wen, X., Feng, Q., Deo, R. C., Si, J., & Wu, M. (2018). Comparative study of hybrid-wavelet artificial intelligence models for monthly groundwater depth forecasting in extreme arid regions, Northwest China. *Water resources management*, 32(1), 301-323.
78. Zare, M., & Koch, M. (2018). Groundwater level fluctuations simulation and prediction by ANFIS-and hybrid Wavelet-ANFIS/Fuzzy C-Means (FCM) clustering models: Application to the Miandarband plain. *Journal of Hydro-environment Research*, 18, 63-76.
79. Zhang, N., Xiao, C., Liu, B., & Liang, X. (2017). Groundwater depth predictions by GSM, RBF, and ANFIS models: a comparative assessment. *Arabian Journal of Geosciences*, 10(8), 1-12.
80. Zounemat-Kermani, M., Kişi, Ö., Adamowski, J., & Ramezani-Charmahineh, A. (2016). Evaluation of data driven models for river suspended sediment concentration modeling. *Journal of Hydrology*, 535, 457-472.