

ارزیابی پاسخ تراز آب زیرزمینی به سناریوهای تغییر اقلیم با به کارگیری رویکرد ترکیبی ریزمقیاس سازی آماری و مدل هوش مصنوعی (مطالعه موردی: دشت مراغه-بناب)

علی اذدرزاده اسکویی^۱، مهدی ربانی زاده^۲، سینا صادق فام^{۳*}، سید بهمن موسوی^۴

۱- دانشجوی کارشناسی ارشد مدیریت منابع آب، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه مراغه، مراغه، ایران.

۲- دانشجوی کارشناسی ارشد مدیریت منابع آب، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه مراغه، مراغه، ایران.

۳- دانشیار، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه مراغه، مراغه، ایران.

۴- دانشیار، گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه مراغه، مراغه، ایران.

* نویسنده مسئول: s.sadeghfam@gmail.com

تاریخ پذیرش مقاله: ۱۴۰۵/۰۴/۲۰

تاریخ دریافت مقاله: ۱۴۰۵/۰۳/۰۹

چکیده

تغییر اقلیم و فعالیت‌های انسانی فشار مضاعفی بر منابع آب زیرزمینی در مناطق خشک و نیمه‌خشک، به‌ویژه در خاورمیانه، وارد کرده‌اند. علاوه بر اثرات اقلیمی، برداشت بیش‌ازحد از آبخوان‌ها در دشت‌های آبرفتی، منجر به افت تراز آب، کاهش کیفیت و تخریب اکوسیستم‌ها شده است. از این رو، ارزیابی دقیق این روندها برای مدیریت پایدار منابع آب ضروری است. در این پژوهش، به منظور پیش‌بینی اثرات تغییر اقلیم بر تراز آب زیرزمینی در چاه نمونه از دشت مراغه-بناب، از یک رویکرد ترکیبی اقلیمی-هوش مصنوعی استفاده شد. ابتدا متغیرهای اقلیمی با بهره‌گیری از مدل میانگین مدل‌های گردش عمومی جو پروژه CMIP6 و مدل تولیدکننده تصادفی LARS-WG، تحت دو سناریوی انتشار برای دوره‌های آتی ریزمقیاس سازی شدند. جهت مدل سازی ارتباط غیرخطی و پیچیده میان متغیرهای اقلیمی و تراز آب زیرزمینی، از مدل عمیق حافظه طولانی کوتاه مدت (LSTM) برای شبیه سازی و پیش‌بینی تراز آب زیرزمینی استفاده گردید. نوآوری کلیدی این پژوهش، تلفیق داده‌های نوین اقلیمی با معماری یادگیری عمیق و لحاظ نمودن اثر تأخیرهای زمانی متغیرهای هیدرولوژیکی و اقلیمی جهت ارتقای دقت پیش‌بینی‌ها است. نتایج پیشنهادی‌های اقلیمی حاکی از روند افزایشی معنادار دما در تمامی ماه‌ها و تغییر در توزیع زمانی بارش‌ها است که منجر به افزایش تبخیر و تفرق و کاهش تغذیه طبیعی آبخوان می‌شود. مدل LSTM نشان داد که تحت سناریوی‌های اقلیمی، تراز آب زیرزمینی با افت قابل توجهی مواجه خواهد شد. این کاهش تراز، پیامد مستقیم اثرات همزمان کاهش تغذیه اقلیمی و افزایش تقاضا برای منابع آب است.

واژه‌های کلیدی: تراز آب زیرزمینی، تغییر اقلیم، مدل LSTM، هوش مصنوعی، CMIP6.

مقدمه

فعالیت‌های انسانی طی چند قرن گذشته باعث تغییرات سریع اقلیمی شده‌اند. اثر تغییر اقلیم بر آب زیرزمینی می‌توان تغییر در مواردی همچون الگوهای بارش، دما، تبخیر و تفرق، شدت خشکسالی‌ها و تغییر در ذخیره برف و یخ عنوان کرد که همگی می‌توانند بر چرخه آب و دسترس پذیری منابع آب اثر بگذارند و فرآیند تغذیه آبخوان‌ها را دچار دگرگونی کنند (Parmesan).

در سال‌های اخیر، دسترسی و کیفیت منابع آب به دلایل مختلف کاهش یافته که تغییر اقلیم^۱ یکی از مهم‌ترین عوامل آن است. به‌طور کلی، تغییر اقلیم به‌عنوان تهدیدی جدی برای اکوسیستم‌های طبیعی و به‌ویژه منابع آب شناخته می‌شود. شواهد علمی متعددی نشان می‌دهند که انقلاب صنعتی و

¹ Climate change

مسیرهای اجتماعی-اقتصادی مشترک (SSPs)^۶ جایگزین مسیرهای تمرکز معرف (RCPs)^۷ شدند تا علاوه بر متغیرهای اقلیمی، عوامل اجتماعی-اقتصادی نیز در پیش‌بینی‌ها لحاظ گردند. با این وجود، خروجی مدل‌های GCM دارای قدرت تفکیک مکانی پایینی بوده و برای استفاده در مدل‌های هیدرولوژیکی حوضه‌ای نیازمند تکنیک‌های ریزمقیاس‌سازی^۸ هستند. در میان روش‌های مختلف، رویکردهای آماری مانند SDSM و LARS-WG^۹ به دلیل کارایی محاسباتی و توانایی در برقراری روابط تجربی بین پیش‌بینی‌کننده‌های مقیاس بزرگ و مشاهدات محلی، بسیار مورد توجه قرار گرفته‌اند (خیاط و همکاران، ۱۴۰۰). در این راستا، مدل LARS-WG به‌عنوان یکی از معتبرترین و پرکاربردترین تولیدکننده‌های تصادفی آب‌وهوا^{۱۰} شناخته می‌شود. این ابزار قدرتمند برای شبیه‌سازی سری‌های زمانی متغیرهای هواشناسی، از توزیع‌های آماری پیچیده و نیمه‌تجربی^{۱۱} مبتنی بر طول دوره‌های خشک و تر، بارش روزانه و تابش استفاده می‌کند (Semenov, 2008).

بررسی ادبیات تحقیق نشان می‌دهد که اثرات تغییر اقلیم بر منابع آب زیرزمینی عمدتاً در محورهای تغذیه، پمپاژ (برداشت)، حجم ذخیره و تراز آب زیرزمینی ارزیابی می‌شود. پاسخ سامانه‌های آب زیرزمینی به تغییرات اقلیمی بسیار پیچیده و غیرخطی است؛ زیرا این سامانه‌ها مستقیماً تحت تأثیر برهم‌کنش میان بارش، دما، رواناب، نفوذ، تبخیر و تعرق، پوشش گیاهی و ویژگی‌های زمین‌شناسی قرار دارند. برای مدل‌سازی سطح آب زیرزمینی و بررسی این دینامیک پیچیده، معمولاً از مدل‌های فیزیکی، مفهومی، عددی و آماری استفاده می‌شود. پژوهش‌های پیشین عمدتاً از مدل‌های فیزیکی و عددی برای شبیه‌سازی بهره برده‌اند (Anderson et al., 2015). به‌همین منظور، استفاده از مدل‌های هیدرولوژیکی یکپارچه که بتوانند تعامل میان آب سطحی، منطقه غیراشباع و آب زیرزمینی را به‌خوبی شبیه‌سازی کنند، ضروری است. مطالعات متعددی از مدل‌های هیدرولوژیکی یکپارچه مانند

(et al., 2022). افزایش دما معمولاً باعث افزایش تبخیر، کاهش نفوذ آب به خاک و کاهش تغذیه آبخوان می‌شود و در کنار آن کاهش بارش و وقوع خشکسالی‌های طولانی‌مدت می‌تواند به افت سطح آب زیرزمینی شدت ببخشد. به‌همین دلیل، نگرانی‌ها درباره پیش‌بینی شرایط اقلیمی آینده و اثر آن بر منابع آب افزایش یافته تا بتوان خسارات آینده را مدیریت و کاهش داد (Aryasadr et al., 2024).

Mustafa et al. (2019) عنوان کرده‌اند که مطالعات زیادی درباره اثر تغییر اقلیم بر منابع آب سطحی انجام شده است؛ اما تعداد پژوهش‌هایی که اثر آن بر آب زیرزمینی را بررسی کرده‌اند محدود است، در حالی که منابع آب زیرزمینی نقش حیاتی در تأمین آب شرب، کشاورزی و مصارف شهری، به‌ویژه در مناطق نیمه‌خشک و خشک ایفا می‌کنند (Jakeman et al., 2019; Allen et al., 2016). مطالعات اخیر نیز نشان داده‌اند در بسیاری از مناطق جهان، کاهش تغذیه طبیعی آبخوان‌ها و افزایش تقاضای آب ناشی از رشد جمعیت و توسعه شهری، موجب افت سطح آب زیرزمینی شده است. باتوجه به اینکه آب زیرزمینی در آینده همچنان یک منبع حیاتی خواهد بود، زیرا بخش مهمی از آب شیرین در دسترس سیاره ما را تشکیل می‌دهد و همچنین نسبت به آب‌های سطحی در برابر تغییرات اقلیمی کوتاه‌مدت و فصلی حساسیت کمتری دارد اهمیت پرداختن به این موضوع را بیشتر می‌کند.

در دهه‌های گذشته، بسیاری از سیستم‌های مدیریت منابع آب با فرض ایستایی اقلیم^۱ طراحی شده بودند؛ اما با اثبات ناپایداری شرایط اقلیمی، امروزه نیاز مبرمی به مدل‌سازی‌های گذرا^۲ به‌جای اتکا به روش‌های سنتی ارزیابی ایستا در انتهای قرن وجود دارد تا بتوان تغییرپذیری و عدم قطعیت‌های اقلیمی را در طول زمان به درستی مدیریت کرد (Goderniaux et al., 2011). ارزیابی اثرات این تغییرات مستلزم استفاده از مدل‌های گردش عمومی جو (GCM)^۳ است. با انتشار ششمین گزارش ارزیابی هیئت بین‌دولتی تغییر اقلیم (IPCC)^۴ و معرفی پروژه مقایسه مدل‌های جفت‌شده فاز ششم (CMIP6)^۵، سناریوهای

⁷ Representative Concentration Pathway

⁸ Downscaling

⁹ Long Ashton Research Station – Weather Generator

¹⁰ Stochastic Weather Generators

¹¹ Semi-empirical distributions

¹ Climate Stationarity

² Transient

³ Global Climate Model

⁴ Intergovernmental Panel on Climate Change

⁵ Coupled Model Intercomparison Project Phase 6

⁶ Shared Socioeconomic Pathways

فضایی را استخراج کرده و شبکه LSTM وابستگی‌های زمانی داده‌های سری زمانی را مدل‌سازی می‌کند (Rouhani et al., 2025). ترکیب این دو روش ابزار قدرتمندی برای پیش‌بینی تغییرات آب زیرزمینی و رفتار پمپاژ در شرایط اقلیمی متغیر فراهم می‌آورد (Patra et al., 2024). با این حال، باید توجه داشت که رویکردهای هوش مصنوعی نیز با چالش‌هایی نظیر تعمیم‌پذیری پایین، خطر بیش‌برازش^۷، مدل‌سازی نامناسب و استفاده از داده‌های نامرتب مواجه هستند.

علاوه بر تفاوت در ساختار مدل‌ها، مرور پژوهش‌های پیشین در ارزیابی اثرات تغییر اقلیم بر آب‌های زیرزمینی، نشان‌دهنده دو رویکرد متفاوت از منظر متغیر هدف و داده‌های ورودی است. دسته نخست، عمدتاً بر پیش‌بینی تراز آب زیرزمینی با اتکا به محرک‌های صرفاً اقلیمی تمرکز دارند؛ برای مثال، Osman et al. (2024) با بهره‌گیری از مدل‌های یادگیری ماشین، نوسانات تراز آب را تنها براساس سناریوهای دما، بارش و داده‌های تاریخی مدل‌سازی کردند. در مقابل، دسته دوم با رویکردی واقع‌بینانه‌تر، حجم ذخیره یا تراز آبخوان را با تلفیق همزمان داده‌های اقلیمی و متغیرهای انسانی-هیدرولوژیکی ارزیابی می‌کنند. به‌عنوان نمونه، Afruzi et al. (2021) با استفاده از مدل پویایی سیستم، تأثیر سناریوهای اقلیمی را در کنار عواملی چون پمپاژ چاه‌ها و تغذیه مصنوعی بر بیلان و افت ذخیره دشت همدان شبیه‌سازی کردند. اهمیت این تلفیق در مدل‌های نوین داده‌محور نیز توسط Patra et al. (2024) اثبات شده است؛ آن‌ها با توسعه مدل ترکیبی یادگیری عمیق (CNN-LSTM) نشان دادند که پیش‌بینی دقیق تراز آب مستلزم ادغام خروجی‌های اقلیمی CMIP6 با متغیرهای برداشت است، زیرا افت آبخوان صرفاً تابع مستقیم تغییر اقلیم نبوده و به‌شدت متأثر از افزایش پمپاژهای ناشی از تنش‌های اقلیمی^۸ است.

با وجود محدودیت‌های ذکر شده، از آن‌جا که مدل‌های یادگیری ماشین بسیار کاربردی‌تر بوده، هزینه‌های محاسباتی پایینی دارند و در زمان بسیار کوتاه‌تری به جواب می‌رسند، استفاده از آن‌ها برای حل مسائل پیچیده آبخوان‌ها توجیه

MODFLOW، GSFLOW و SWAT استفاده کرده‌اند که امکان شبیه‌سازی فرآیندهای پیچیده‌ای نظیر جریان آب سطحی، نفوذ و تبادل آب سطحی و زیرزمینی را فراهم می‌کنند (Hashemi et al., 2015; Hughes et al., 2017; Ouyang et al., 2021; Ryter et al., 2025; Gemitzi et al., 2017; Khara et al., 2025). نتایج این مطالعات نشان داده‌اند که حتی در شرایط افزایش بارش، افزایش دما (به‌دلیل تشدید تبخیر و تعرق) می‌تواند باعث کاهش خالص ذخیره آب زیرزمینی شود (Hughes et al., 2021).

با این وجود، چالش‌های اساسی در مسیر مدل‌سازی آب زیرزمینی وجود دارد. مدل‌سازی رفتار آبخوان‌ها به دلیل پیچیدگی سیستم‌های هیدروژئولوژیکی، روابط غیرخطی، ناهمگنی مکانی و کمبود داده‌های میدانی بسیار دشوار است. مدل‌های فیزیکی و عددی سنتی معمولاً نیازمند داده‌های فراوان، پارامترهای متعدد، شناخت دقیق ویژگی‌های فیزیکی آبخوان و زمان محاسباتی بالا هستند. به‌همین دلیل، در سال‌های اخیر استفاده از رویکردهای داده‌محور به‌عنوان جایگزین یا مکمل مدل‌های فیزیکی افزایش یافته است؛ چرا که مدل‌های هوش مصنوعی ساده‌تر بوده و با محدودیت‌های محاسباتی و داده‌ای کمتری مواجه‌اند (Al Atawneh et al., 2021).

مدل‌های هوش مصنوعی می‌توانند بدون نیاز به درک کامل و حل معادلات پیچیده فرآیندهای فیزیکی، روابط پنهان بین متغیرهای اقلیمی و سطح آب زیرزمینی را یاد بگیرند. به‌همین دلیل، مدل‌های جعبه‌سیاه مانند شبکه‌های عصبی مصنوعی (ANN)^۱، ماشین بردار پشتیبان (SVR)^۲، سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)^۳ و الگوریتم ژنتیک (GA)^۴ به جایگزین‌های مناسبی تبدیل شده‌اند (Secci et al., 2023; Dastjerdi et al., 2024). در میان این روش‌ها، شبکه‌های عصبی، مدل‌های یادگیری عمیق^۵ و روش‌های بازگشتی کاربرد گسترده‌ای پیدا کرده‌اند. به‌عنوان مثال، شبکه‌های عصبی عمیق، به‌ویژه مدل‌های ترکیبی CNN-LSTM، توانایی بالایی در یادگیری روابط زمانی و مکانی دارند؛ شبکه CNN^۶ الگوهای

^۵ Deep Learning

^۶ Convolutional Neural Network

^۷ Overtraining

^۸ Climate-induced pumping

^۱ Artificial Neural Network

^۲ Support Vector Regression

^۳ Adaptive Neuro-Fuzzy Inference System

^۴ Genetic Algorithm

شبکه هیدرولوژیکی این دشت عمدتاً تحت تأثیر رودخانه دائمی صوفی‌چای قرار دارد که با سرچشمه گرفتن از ارتفاعات سهند و عبور از سد علویان، نقش حیاتی در تأمین منابع آب سطحی ایفا می‌کند (شکل ۱-ب). براساس داده‌های سازمان هواشناسی کشور (IRIMO)^۵ طی دوره آماری ۲۰۱۵ تا ۲۰۲۴، میانگین بارش سالانه در این دشت و ارتفاعات اطراف آن به‌ترتیب ۲۳۵ و ۳۶۴ میلی‌متر و میانگین دمای سالانه ۱۵ درجه سانتی‌گراد است که طبق طبقه‌بندی آمبرژه^۶، اقلیم منطقه را در رده نیمه خشک و سرد قرار می‌دهد. در ماه‌های گرم سال با کاهش جریان آب سطحی و ذخایر سد علویان، دسترسی به آب‌های سطحی در پایین‌دست رودخانه به‌شدت محدود می‌شود، بنابراین کشاورزان برای تأمین نیاز آبی کشاورزی از آب‌های زیرزمینی بهره‌برداری می‌کنند.

ساختار زمین‌شناسی و لیتولوژی منطقه مطابق با شکل ۱-ج تنوع بالایی از نهشته‌های آبرفتی، تراورتن و سنگ‌های آذرین را نشان می‌دهد. این بسترهای زمین‌شناسی، ظرفیت مناسبی را برای تشکیل آبخوان دشت مراغه-بناب فراهم کرده‌اند؛ به‌گونه‌ای که این محدوده به‌عنوان یک آبخوان آبرفتی آزاد با وسعتی در حدود ۲۶۰ کیلومتر مربع شناخته می‌شود که ضخامت رسوبات آبرفتی آن در برخی نقاط به بیش از ۲۰۰ متر می‌رسد و سنگ بستر آن عمدتاً از لایه‌های نفوذناپذیر رس و مارن تشکیل شده است. سطح آب زیرزمینی در این آبخوان دارای نوسانات فصلی است؛ به‌طوری‌که بالاترین تراز در ماه‌های اردیبهشت-خرداد و پایین‌ترین سطح در شهریور-مهر مشاهده می‌شود. در بخش غربی دشت، این آبخوان به یک باتلاق نمکی با نهشته‌های ریزدانه دریاچه‌ای ختم می‌شود که هدایت هیدرولیکی بسیار پایینی دارند. با توجه به افزایش توسعه شهری و نیاز روزافزون بخش کشاورزی به منابع آب، در دهه‌های اخیر حفر چاه‌های متعدد و برداشت بی‌رویه از آبخوان، در کنار تأثیرات تغییر اقلیم و کاهش نزولات جوی، منجر به افت شدید سطح آب زیرزمینی در این منطقه شده است. لذا، ارزیابی و پیش‌نمایی نوسانات تراز آب زیرزمینی تحت سناریوهای تغییر اقلیم با استفاده از داده‌های یک ایستگاه هواشناسی و یک چاه مشاهداتی مندرج در جدول ۱

علمی و منطقی بالایی دارد. با این حال، مرور مطالعات نشان می‌دهد که هنوز تحقیقات محدودی درباره استفاده از روش‌های یادگیری عمیق برای ارزیابی اثر تغییر اقلیم بر آب زیرزمینی وجود دارد و پژوهش‌های اندکی به بررسی همزمان تغییرات سطح آب زیرزمینی و مصرف انرژی پمپاژ تحت سناریوهای تغییر اقلیم پرداخته‌اند (Nohani et al., 2025). لذا، درک ارتباط میان تغییرات اقلیمی، مصرف انرژی و برداشت آب زیرزمینی همچنان نیازمند بررسی بیشتر است. اگرچه قبلاً از مدل‌های هوش مصنوعی برای پیش‌بینی تراز آب زیرزمینی استفاده شده، اما پژوهش حاضر با استفاده ترکیبی از نسل جدید سناریوهای اقلیمی (CMIP6/SSPs) با مدل LARS-WG8 و مدل LSTM^۱ با در نظر گرفتن تأخیرهای زمانی^۲ برای چاه نمونه از دشت مراغه-بناب، رویکرد جدیدی است که دقت پیش‌بینی را به شدت بالا می‌برد.

مواد و روش‌ها

منطقه مورد مطالعه

دشت مراغه-بناب با وسعتی در حدود ۳۳۰ کیلومتر مربع، در جنوب‌غربی استان آذربایجان شرقی و در حاشیه شرقی دریاچه ارومیه واقع شده است (شکل ۱-الف). این منطقه به‌عنوان یکی از مراکز مهم کشاورزی و شهری در شمال غرب ایران شناخته می‌شود و شهرهای مراغه و بناب به‌عنوان قطب‌های اصلی جمعیتی و اقتصادی در آن توسعه یافته‌اند. از نظر توپوگرافی و مورفولوژی، همان‌طور که در نقشه مدل رقومی ارتفاع (DEM)^۳ استخراج‌شده از پایگاه داده‌های سازمان زمین‌شناسی آمریکا (USGS)^۴ که مرجع ارتفاعی آن، تراز ارتفاعی نسبت به میانگین سطوح دریا‌های آزاد (AMSL) می‌باشد مشاهده می‌شود، منطقه دارای شیب عمومی از شرق (دامنه‌های کوه سهند با ارتفاع بیش از ۳۶۰۰ متر) به سمت غرب (پست‌بوم‌های حاشیه دریاچه ارومیه) است. دشت اصلی در تراز ارتفاعی بین ۱۴۰۰ تا ۱۵۰۰ متر از سطح دریا گسترده شده و گذار از دامنه‌های کوهستانی به دشت‌های هموار در این منطقه به وضوح قابل تشخیص است.

^۴ United States Geological Survey

^۵ Islamic Republic of Iran Meteorological Organization

^۶ Emberger's classification

^۱ Long Short-Term Memory

^۲ Time-lag


^۳ Digital Elevation Model

برای دوره‌های آتی (نزدیک و دور)، هدف اصلی این پژوهش را تشکیل می‌دهد.

جدول ۱- منابع و داده‌های گردآوری شده.

Table 1- Sources and aggregated data.

Data	Description	Data Source
Meteorological data (1984–2025)	Precipitation, temperature	Iran Meteorological Organization (IRIMO)
Observation well data (2001–2022)	Water level, elevation head	Ministry of Energy



شکل ۱- منطقه مورد مطالعه: (الف) موقعیت جغرافیایی و مدل رقومی ارتفاع، (ب) نقشه کاربری اراضی، (ج) نقشه لیتولوژی.

Figure 1- Study area: (a) geographical location and DEM; (b) land use map; (c) lithological map.

بررسی می‌شود (Jahangir et al., 2022). با این وجود، خروجی

مدل LARS-WG

مدل‌های GCM دارای قدرت تفکیک مکانی پایینی بوده و برای استفاده در مدل‌های هیدرولوژیکی محلی، نیازمند تکنیک‌های ریزمقیاس‌سازی هستند. در میان روش‌های مختلف، رویکردهای آماری به‌دلیل کارایی محاسباتی بالا و توانایی در برقراری روابط تجربی بین پیش‌بینی‌کننده‌های مقیاس بزرگ و مشاهدات محلی، بسیار مورد توجه قرار گرفته‌اند.

در این پژوهش، از مدل LARS-WG ورژن ۸ (آخرین ورژن) به‌عنوان یکی از معتبرترین تولیدکننده‌های تصادفی آب‌وهوا

ارزیابی اثرات تغییر اقلیم بر منابع آب زیرزمینی مستلزم استفاده از مدل‌های گردش عمومی جو (GCMs) است. با انتشار ششمین گزارش ارزیابی هیئت بین‌الدولی تغییر اقلیم و معرفی پروژه مقایسه مدل‌های جفت شده فاز ششم (CMIP6)، سناریوهای مسیرهای اجتماعی-اقتصادی مشترک (SSPs) جایگزین مسیرهای تمرکز معرف (RCPs) شدند. در سناریوهای جدید (SSPs)، چگونگی تغییر شرایط اقتصادی-اجتماعی مانند رشد جمعیت، پیشرفت اقتصادی، شهرنشینی، توسعه و تکنولوژی در کنار متغیرهای اقلیمی شبیه‌سازی و

برای ریزمقیاس‌نمایی داده‌های هواشناسی ایستگاه سینوپتیک مراغه استفاده شد. این ابزار قدرتمند برای شبیه‌سازی سری‌های زمانی متغیرهای هواشناسی، از توزیع‌های آماری پیچیده و نیمه‌تجربی مبتنی بر طول دوره‌های خشک و تر، بارش روزانه و تابش خورشیدی استفاده می‌کند. فرآیند اجرای این مدل در دو مرحله اصلی واسنجی (استخراج ویژگی‌های آماری اقلیم منطقه از داده‌های مشاهداتی دوره پایه) و اعتبارسنجی (تولید سری زمانی مصنوعی و مقایسه مشخصات

آماري آن با داده‌های مشاهداتی جهت اطمینان از توانایی مدل) انجام می‌پذیرد. مدل‌های گزارش ششم (AR6) در جدیدترین نسخه نرم‌افزار LARS-WG تعریف شده‌اند. در این مطالعه، براساس جدول ۲، از خروجی ۵ مدل معروف گردش عمومی جو که دارای تطابق مناسبی با شرایط اقلیمی ناحیه خاورمیانه هستند، استفاده شد. برای ریزمقیاس‌نمایی خروجی این مدل‌ها، دو سناریوی انتشار شامل مسیر میانه‌رو (SSP2-) 4.5 و بدبینانه (SSP5-8.5) انتخاب گردید.

جدول ۲- مشخصات مدل‌های CMIP6 انتخاب شده.

Table 2- Specifications of the selected CMIP6 models.

No.	GCM Model	Developing Country / Center	Year Released in CMIP6	Atmospheric Resolution	Oceanic Resolution	Features / Performance in Climate Studies
1	CanESM5	Canada – Canadian Centre for Climate Modelling	2019	~2.8°×2.8°	~1°	Focus on carbon cycle and climate–biosphere feedbacks
2	CNRM-CM6-1	France – CNRM / Météo-France	2018	~1°×1°	~1°	Good performance in simulating atmospheric circulation and Europe/Mediterranean climate
3	GFDL-ESM4	United States – NOAA GFDL	2018	~1°×1.25°	~1°	Accurate simulation of ocean–atmosphere and biogeochemical cycle interactions
4	HadGEM3-GC31-LL	United Kingdom – Met Office Hadley Centre	2018	~1.25°×1.875°	~0.25°	Strong performance in simulating atmospheric circulation and large-scale climate phenomena
5	MPI-ESM1-2-LR	Germany – Max Planck Institute for Meteorology	2019	~1.9°×1.9°	~0.4°	Widely used model with accurate energy and carbon cycle simulation

عدد اول در نام هر سناریو (SSP) بیانگر مسیر توسعه مربع (W/m^2) نشان می‌دهد. در جدول ۳ مشخصات و ویژگی‌های هر یک از این سناریوها ارائه شده است.

تابشی^۱ پیش‌بینی شده تا سال ۲۱۰۰ را بر حسب وات بر متر

جدول ۳- مشخصات و ویژگی‌های سناریوها.

Table 3- Specifications and features of the scenarios.

Scenario	Development Pathway Description	Radiative Forcing by 2100	Scenario Interpretation
SSP2-4.5	This scenario represents a “middle-of-the-road” pathway where economic, social, and technological trends follow historical patterns, with limited policies for greenhouse gas emission control.	4.5 W/m ²	This scenario is typically considered a medium or relatively optimistic scenario.
SSP5-8.5	This scenario represents a world with rapid economic growth and high dependence on fossil fuels, where no effective policies are implemented to reduce greenhouse gas emissions.	8.5 W/m ²	This scenario is known as the pessimistic or high-emission scenario, representing conditions with the highest intensity of climate change.

¹ Radiative Forcing

با وجود کارایی مطلوب شبکه‌های عصبی پایه، پیشرفت‌های اخیر در زمینه یادگیری عمیق به توسعه مدل‌های پیشرفته‌تری منجر شده است. براساس مطالعات پیشین (از جمله مقایسه مدل‌های شبکه عصبی کلاسیک مانند NARX، شبکه‌های پیچشی CNN و حافظه طولانی کوتاه‌مدت LSTM)، مشخص شده است که اگرچه بیشتر روش‌های هوش مصنوعی در فاز آموزش عملکرد خوبی دارند، اما مدل LSTM در ارزیابی اثرات تغییر اقلیم بر منابع آب زیرزمینی برتری قابل توجهی دارد. شبکه CNN در برون‌یابی داده‌ها خارج از محدوده آموزش دچار محدودیت است و مدل NARX نیز به دلیل عدم برخورداری از ساختار یادگیری عمیق، دقت پایین‌تری در پیش‌بینی‌های بلندمدت دارد. در مقابل، شبکه LSTM به دلیل داشتن ساختار حافظه کوتاه‌مدت و بلندمدت، توانایی بالایی در حفظ اطلاعات سری‌های زمانی و تشخیص روندهای اقلیمی و هیدرولوژیکی دارد و ابزاری کارآمد برای پیش‌بینی رفتار الگوی ماهانه تراز آب زیرزمینی تحت شرایط اقلیمی آینده به شمار می‌رود (Secci et al., 2023).

مطابق فلوجارت روش‌شناسی ارائه شده در شکل ۲، به منظور توسعه مدل هوش مصنوعی (ماژول ۲)، ابتدا پیش‌پردازش و آماده‌سازی داده‌ها صورت گرفت. یکی از مهم‌ترین چالش‌ها در ارزیابی اثرات تغییر اقلیم بر آب‌های زیرزمینی، تفکیک اثرات اقلیمی از فعالیت‌های انسانی است. به‌دین منظور، چاه مشاهداتی مورد استفاده در این پژوهش به‌گونه‌ای انتخاب شد که در منطقه‌ای به دور از فعالیت‌های شدید انسانی و پمپاژهای بی‌رویه قرار داشته باشد تا مدل در درک تأثیر خالص تغییر اقلیم بر تراز آب زیرزمینی دچار خطا نشود.

در بخش آماده‌سازی داده‌ها، داده‌های مفقود هواشناسی شامل بارش از طریق مدل زنجیره مارکوف و دما از طریق فیلتر کالمن بازسازی گردید. همچنین با توجه به ماهیت تأخیردار پاسخ آبخوان به محرک‌های اقلیمی، در این مطالعه اثر دما و بارش بر تراز آب زیرزمینی با وقفه زمانی مدل‌سازی شد. توجیه فرایندی (نفوذ، انتقال در ناحیه غیراشباع، تغذیه تدریجی آبخوان و اثر دما بر تبخیر-تعرق و رطوبت خاک) نه تنها از نظر فیزیکی قابل انتظار است، بلکه در تحلیل آماری نیز مشاهده

از آن جایی که آینده اقلیم همواره با عدم قطعیت^۱ ذاتی همراه است، اتکا به خروجی یک مدل GCM منفرد می‌تواند خطای محاسباتی را افزایش دهد. به‌همین منظور، در این پژوهش خروجی‌های ریزمقیاس‌شده برای پارامترهای بارش، دمای حداقل و دمای حداکثر، تحت هر دو سناریوی SSP از هر ۵ مدل استخراج گردید. سپس جهت کاهش عدم قطعیت ساختاری مدل‌ها، از رویکرد میانگین چند مدل^۲ استفاده شد. به‌دین صورت که نسبت میانگین بلندمدت ماهانه دوره آتی به دوره پایه برای پارامتر بارش و اختلاف میانگین بلندمدت ماهانه دوره آتی و دوره پایه برای پارامترهای دما محاسبه گردید. ضریب به‌دست آمده در هر ماه، پارامتری است که از آن برای ایجاد سناریو در نرم‌افزار LARS-WG و تولید داده‌های ریزمقیاس‌نمایی شده خروجی مدل‌های گزارش ششم استفاده شد. این رویکرد ترکیبی، دامنه‌ای جامع از شرایط اقلیمی آینده را ارائه می‌دهد که به درک بهتر حساسیت سامانه هیدرولوژیکی نسبت به تغییرات اقلیمی کمک کرده و امکان ارزیابی دقیق‌تر ریسک‌های بالقوه برای منابع آب زیرزمینی دشت را فراهم می‌سازد.

مدل LSTM

امروزه شبکه‌های عصبی مصنوعی (ANN) در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارند (Nourani et al., 2011). ساختار یک شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی به‌عنوان یک لایه انتقال‌دهنده و وسیله‌ای برای تهیه‌کردن داده‌ها عمل می‌کند، لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند محل پردازش داده‌ها است و لایه خروجی شامل مقادیر پیش‌بینی‌شده توسط شبکه می‌باشد. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس‌انتشار خطا با سناریو شبکه پیش‌خور و تعداد سه‌لایه، به‌طور رضایت‌بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (Nourani et al., 2011).

² Multi-Model Ensemble

¹ Uncertainty

نتایج و بحث

ارزیابی عملکرد مدل LARS-WG

ارزیابی کارایی مدل LARS-WG در مقیاس ماهانه و فصلی، نشان‌دهنده دقت بسیار بالای این ابزار در شبیه‌سازی متغیرهای اقلیمی است. تحلیل نمودارهای پراکنش برای دمای حداقل و حداکثر، همگرایی کامل خروجی‌ها با مشاهدات ایستگاهی را نشان می‌دهد که با شاخص‌های آماری ایده‌آل (ضریب همبستگی بسیار بالا و مقادیر بسیار ناچیز ریشه میانگین مربعات خطا) تایید می‌گردد (شکل ۳-الف و ب). همچنین در شکل ۳-ج، علی‌رغم ماهیت پیچیده و تصادفی بارش، مدل توانسته است نوسانات فصلی این متغیر را نیز با همبستگی قوی و حداقل خطا شبیه‌سازی کند. در مجموع، انطباق چشمگیر داده‌های برآوردی با مشاهدات واقعی در هر سه پارامتر کلیدی، صلاحیت و قابلیت اطمینان کامل این مدل را برای تولید دقیق سناریوهای اقلیمی آینده در منطقه مورد مطالعه به اثبات می‌رساند.

شد. به‌طور مشخص، با اجرای تحلیل همبستگی متقابل^۱ بین سری زمانی تراز آب زیرزمینی و متغیرهای ورودی اقلیمی، بیشینه همبستگی در وقفه‌های چندماهه ظاهر شد؛ این نتیجه نشان می‌دهد که تغییرات اقلیمی با حافظه زمانی بر سطح ایستابی اثر می‌گذارند و پاسخ سیستم عمدتاً آنی نیست. براین اساس، داده‌های دمای حداقل (T_{min}) و دمای حداکثر (T_{max}) با تأخیر زمانی ۲ ماهه و داده‌های بارش (Prcp) به‌صورت تجمعی ۶ ماهه در نظر گرفته شدند. این متغیرهای اقلیمی تغییر یافته به همراه مقادیر مشاهداتی ماهانه تراز آب زیرزمینی، ساختار ورودی مدل را تشکیل دادند.

شبکه LSTM استفاده شده در این مطالعه دارای ۳ متغیر ورودی و ۱ خروجی (پیش‌بینی تراز آب زیرزمینی) است. ساختار داخلی این مدل از یک لایه پنهان با ۱۰۰ نورون و یک لایه خروجی از نوع رگرسیونی تشکیل شده است. در مرحله آموزش شبکه، از الگوریتم بهینه‌ساز Adam استفاده شد و مدل با تنظیم بر روی ۲۵۰ تکرار^۲ آموزش دید. خروجی این شبکه برای تولید نمودارهای ناهنجاری^۳ و پیش‌بینی تراز آب زیرزمینی در دو دوره آینده نزدیک و آینده دور، تحت سناریوهای SSP2-4.5 و SSP5-8.5 به کار گرفته می‌شود.

معیارهای ارزیابی عملکرد مدل‌های مورد بررسی


جهت ارزیابی و تحلیل عملکرد مدل‌های مورد بررسی شاخص‌های عملکردی مختلفی وجود دارد که در این پژوهش از شاخص‌های R^2 و RMSE استفاده شده است که براساس روابط زیر تعریف می‌شوند.

$$R^2 = \frac{[\sum_{i=1}^n (P_i - \bar{P})(O_i - \bar{O})]^2}{\sum_{i=1}^n (P_i - \bar{P})^2 \times \sum_{i=1}^n (O_i - \bar{O})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (2)$$


در روابط فوق O_i داده‌های مشاهداتی، P_i داده‌های شبیه‌سازی شده و n تعداد داده‌ها می‌باشد.

³ Anomaly plot¹ Cross-Correlation Analysis² Epoch



شکل ۲- فلوچارت روش شناسی.

Figure 2- Methodological flowchart.



شکل ۳- نمودارهای پراکنش ارزیابی عملکرد مدل: (الف) دمای حداقل، (ب) دمای حداکثر، (ج) بارش.


Figure 3- Scatter plots for model performance evaluation: (a) T_{min} ; (b) T_{max} ; (c) Prcp.

مطالعه است که می‌تواند پیامدهای اکولوژیکی و هیدرولوژیکی قابل توجهی نظیر تشدید تبخیر و تعرق را در دهه‌های آتی به همراه داشته باشد.

در نقطه مقابل واکاوی نمودار تغییرات بارش نمایانگر تغییرات نوسانی، توزیع نامتقارن و پیچیدگی‌های دینامیکی بالاتر در رژیم بارندگی منطقه تحت سناریوهای تغییر اقلیم است. بر اساس خروجی‌های مدل، الگوی تغییرات بارش دارای ماهیتی دوگانه (افزایشی-کاهشی) در مقیاس ماهانه بوده، به عنوان نمونه، در حالی که برخی از ماه‌ها (همانند اواسط بهار و اواخر پاییز) تغییرات مثبت و افزایش میزان نزولات جوی را نسبت به دوره پایه تجربه می‌کنند، در ماه‌هایی نظیر اکتبر افت بسیار شدیدی در مقادیر بارش تحت تمامی سناریوها پیش‌بینی شده است (شکل ۴-ج). جهت شرح مختصری از تغییرات فصلی و سالانه بارش جدول ۴ ارائه گردیده است.

ارزیابی نتایج پیش‌بینی الگوی ماهانه اقلیم آینده توسط سناریوهای انتخابی

بررسی نتایج پیش‌بینی متغیرهای دمایی توسط مدل LARS-WG، حاکی از یک روند افزایشی و پیوسته در دماهای حداقل و حداکثر طی تمامی ماه‌های سال برای هر دو افق زمانی آینده نسبت به دوره پایه است. نمودارهای تغییرات دمایی نشان می‌دهد که این تغییرات افزایشی بوده و وابستگی مستقیمی به نوع سناریوی انتشار و افق زمانی دارد؛ به گونه‌ای که بیشترین میزان گرمایش در افق آینده دور و تحت سناریوی بدبینانه SSP5-8.5 برآورد شده است، در حالی که کمترین میزان انحراف از دوره پایه به سناریوی میانه‌رو SSP2-4.5 در آینده نزدیک اختصاص دارد (شکل ۴-الف و ب). تداوم و گستردگی این نوسانات مثبت دمایی در سراسر ماه‌های سال، گواه روشنی بر تغییرات بنیادین در رژیم حرارتی منطقه مورد



شکل ۴- نمودارهای تغییرات ماهانه متغیرهای اقلیمی: (الف) دمای حداقل، (ب) دمای حداکثر، (ج) بارش.

Figure 4- Monthly Anomaly plots for Climate variables: (a) T_{min} ; (b) T_{max} ; (c) Precip.

جدول ۴- خلاصه‌ای از پیش‌بینی تغییرات بارش در آینده نزدیک و آینده دور.

Table 4- Summary of projected precipitation changes for the near and far-future periods.

Indicator	Near Future	Far Future	Climate Interpretation
Winter Precipitation	Relative increase (approx. 2 mm)	Relative increase	Increased winter moisture/precipitation
Spring Precipitation	4 mm increase	Increase of more than 4 mm	Temporal shift in rainfall

Summer Precipitation	Slight increase	Slight increase	Probability of short-term intense rainfall
Autumn Precipitation	Significant decrease, especially in October	More severe decrease, especially in October	Delay in the onset of autumn rains
Annual Precipitation Changes	Limited change	Limited change	Greater change in temporal distribution

مقابل، در ماه‌های اواخر زمستان و اوایل بهار (نظیر فوریه و مارس)، انحراف معیار خروجی‌ها زیاد است که بیانگر عدم قطعیت بالای شبیه‌سازی دما در دوران گذار فصلی می‌باشد. با وجود این نوسانات ماهانه، دامنه بین‌چارکی در متغیرهای دمایی نسبتاً کوتاه است که نشان از همگرایی قابل قبول مدل‌های مختلف در برآورد روند کلی دما دارد. در ادامه به منظور ایجاد دید کلی به بازه تغییرات دمای حداکثر و حداقل و بررسی میزان عدم قطعیت، جدول ۵ ارائه گردیده است.

در شکل ۵ (الف و ب) نیز ارزیابی عدم قطعیت پیش‌بینی‌های اقلیمی از طریق محاسبه انحراف معیار خروجی‌های پنج مدل گردش عمومی جو (GCM) تحت سناریوهای مختلف به‌دست آمده است که نشان‌دهنده نوسانات معنادار در شبیه‌سازی الگوی ماهانه متغیرهای اقلیمی است. بررسی نمودارهای مربوط به انحراف معیار دماهای حداقل و حداکثر حاکی از آن است که میزان توافق بین مدل‌های GCM در ماه‌های گرم سال (به‌ویژه جولای و آگوست) به بالاترین حد خود می‌رسد و در نتیجه، عدم قطعیت در این ماه‌ها بسیار محدود است.


جدول ۵- خلاصه‌ای از پیش‌بینی تغییرات دما در آینده نزدیک و آینده دور.

Table 5- Summary of projected temperature changes for the near and far-future periods.

Indicator	Near Future	Far Future	Climate Interpretation
Change (T_{min})	Approx. 2 ~ 3°C increase	Approx. 3 ~ 4.5°C increase	Approx. 2 to 4.5°C increase
Change (T_{max})	Approx. 1 ~ 2.5°C increase	Approx. 3 ~ 4.5°C increase	Daily temperature increase
Highest Temperature Increase	Winter and early Autumn	Winter and early Autumn	Shift in precipitation type from snow to rain
Lowest Temperature Increase	Spring	Spring	Probability of cold spells
Model Uncertainty Level	Higher in Spring and Autumn	Higher in Spring and Autumn	Higher model dispersion during transitional seasons
Highest Model Consensus	Summer	Summer	More reliable projections

پیچیده فرآیندهای بارش دارد که واکنش متفاوتی را در ساختار هر یک از مدل‌های GCM برمی‌انگیزد. وجود این سطح از نوسانات در بین خروجی مدل‌ها، ضرورت اجتناب از اتکا به یک مدل واحد و لزوم استفاده از رویکرد چند مدل GCM را جهت پوشش دادن عدم قطعیت‌ها و افزایش قابلیت اطمینان سناریوهای اقلیمی آینده برای برنامه‌ریزی‌های کلان و ارزیابی ریسک برجسته می‌سازد.

در حالیکه در شکل ۵-ج نمودار انحراف معیار بارش، عدم قطعیت به‌مراتب پیچیده‌تری را نسبت به متغیرهای دمایی به تصویر می‌کشد. پراکندگی خروجی مدل‌های GCM در تخمین بارش، به‌خصوص در ماه‌های آوریل و نوامبر، بسیار گسترده بوده و تفاوت معناداری میان سناریوهای انتشار SSP2-4.5 و SSP5-8.5 مشاهده می‌شود. این سطح بالای عدم قطعیت در متغیر بارش، ریشه در ماهیت تصادفی، غیرخطی و ماهیت



شکل ۵- نمودارهای جعبه‌ای ارزیابی عدم قطعیت: (الف) دمای حداقل، (ب) دمای حداکثر، (ج) بارش.

Figure 5- Box plots for uncertainty assessment: (a) T_{min}; (b) T_{max}; (c) Precp.


مختلف سال است. این سطح از همبستگی تایید می‌کند که معماری مبتنی بر حافظه در شبکه LSTM، به شکلی موثر وابستگی‌های زمانی و روندهای فصلی حاکم بر آبخوان را در دوره تاریخی شناسایی و مدل‌سازی کرده است. بررسی قابلیت تعمیم‌پذیری مدل در فاز آزمون توسط داده‌های جدید، بیانگر افت نسبی در شاخص‌های عملکردی است که در الگوریتم‌های داده‌محور پدیده‌ای مورد انتظار تلقی می‌شود. اگرچه ارزیابی شاخص‌های آماری در این فاز نشان‌دهنده کاهش ضریب همبستگی و افزایش خطای مدل نسبت به مرحله آموزش بوده، اما مدل همچنان توانسته است روند رفتار سیستم را به درستی شناسایی کند (شکل ۶-ب). توزیع فصلی داده‌ها نشان می‌دهد که شبکه در برآورد مقادیر حدی

ارزیابی عملکرد مدل LSTM

ارزیابی کارایی و دقت مدل یادگیری عمیق LSTM در شبیه‌سازی و پیش‌نمایی تراز آب زیرزمینی از طریق بررسی میزان انطباق مقادیر مشاهداتی و تولید شده در دو فاز آموزش و آزمون صورت پذیرفت. تحلیل ساختار پراکنش داده‌ها در مرحله آموزش، نشان‌دهنده توانمندی قابل‌توجه این شبکه عصبی در استخراج الگوهای پیچیده و دینامیک غیرخطی نوسانات آب زیرزمینی است (شکل ۶-الف). در این مرحله، تراکم بالای نقاط داده‌ای و حداقل میزان انحراف از حالت تطابق کامل، در کنار مقادیر بسیار مطلوب شاخص‌های ارزیابی (ضریب همبستگی و ریشه میانگین مربعات خطا)، گویای عملکرد بالای مدل در بازتولید مقادیر مشاهداتی طی فصول

برخوردار بوده و ظرفیت بالایی برای ادغام در سیستم‌های پشتیبان تصمیم‌گیری و مدیریت استراتژیک منابع آب زیرزمینی دارد.


(بیش‌برآورد در سطح ایستابی پاییزه و کم‌برآورد در سطح ایستابی بهاره) با عدم قطعیت بیشتری مواجه است. با این حال، حفظ توالی منطقی نوسانات تراز آب در فصول مختلف اثبات می‌کند که مدل LSTM از پایداری ساختاری قابل‌قبولی



شکل ۶- نمودارهای پراکنش ارزیابی عملکرد مدل برای تراز آب زیرزمینی: (الف) فاز آموزش، (ب) فاز آزمون.

Figure 6- Scatter plots of model performance evaluation for GWL: (a) Train; (b) Test.

سناریوها (به‌ویژه SSP2-4.5 آینده نزدیک و دور) یک روند افزایشی نسبی در پایان تابستان و اوایل پاییز دیده می‌شود که اوج آن در ماه سپتامبر با تغییرات مثبت حدود ۰.۵ متر برای آینده نزدیک (SSP2-4.5) است. این تضاد بین افت شدید تراز در آینده دور تحت سناریوی بدبینانه و بهبودهای مقطعی در سناریوی میانه‌رو، بیانگر پیچیدگی پاسخ سیستم‌های زیرزمینی به مولفه‌های اقلیمی است و ضرورت اتخاذ استراتژی‌های مدیریت انطباقی منابع آب را برای مقابله با تنش‌های شدید در افق‌های زمانی دورتر تحت سناریوهای سخت‌گیرانه اقلیمی تأکید می‌کند.



شکل ۷- نمودار تغییرات ماهانه تراز آب زیرزمینی.

Figure 7- Monthly Anomaly plot for GWL.


ارزیابی نتایج پیشنمایی الگوی ماهانه تراز آب زیرزمینی آینده توسط سناریوهای انتخابی

تحلیل نتایج حاصل از مدل‌سازی LSTM برای پیشنمایی الگوی تغییرات ماهانه تراز آب زیرزمینی نشان‌دهنده تفاوت‌های معنادار در پاسخ هیدرولوژیکی آبخوان تحت سناریوهای مختلف اقلیمی است. تحت سناریوی بدبینانه SSP5-8.5، روند کاهشی تراز آب زیرزمینی در دوره آینده دور کاملاً مشهود است، به‌طوری که در تمامی ماه‌های سال، افت تراز نسبت به دوره پایه مشاهده می‌شود؛ این افت در ماه‌های ابتدایی و انتهایی سال به بیش از ۰/۶ متر می‌رسد (شکل ۷). در مقابل، سناریوی میانه‌رو SSP2-4.5 در دوره آینده نزدیک، رفتاری متفاوت را نشان می‌دهد و برخلاف انتظارات اولیه، تغییرات مثبتی را به‌ویژه در نیمه دوم سال به ثبت رسانده است که می‌تواند ناشی از تغییر در الگوهای بارش فصلی یا کاهش برداشت در آن بازه زمانی خاص باشد که توسط مدل LSTM شناسایی شده است.

از منظر نوسانات فصلی، بیشترین حساسیت تراز آب زیرزمینی به تغییرات اقلیمی در ماه‌های سپتامبر تا نوامبر مشاهده می‌شود، جایی که شکاف بین سناریوها به بیشترین حد خود می‌رسد. در حالی که در سناریوی SSP5-8.5 آینده دور، تراز آب همچنان در وضعیت بحرانی و منفی قرار دارد، در سایر

توزیع فصلی عدم قطعیت‌ها نیز حاکی از آن است که بیشترین میزان پراکندگی و نوسان در نتایج پیش‌بینی، در ماه‌های آوریل و می (فصل بهار) رخ می‌دهد، جایی که تداخل الگوهای بارشی و ذوب برف می‌تواند خروجی‌های متفاوتی را از مدل‌های GCM استخراج کند. وجود نقاط دورافتاده در ماه‌های نیمه دوم سال، به‌ویژه در سپتامبر و اکتبر، نشان‌دهنده واکنش‌های حدی آبخوان به سناریوهای اقلیمی خاص است که توسط برخی از مدل‌های GCM شبیه‌سازی شده‌اند. در مجموع، هم‌پوشانی بخش‌هایی از جعبه‌ها در سناریوهای مختلف نشان می‌دهد که اگرچه عدم قطعیت ساختاری مدل‌های اقلیمی بر پیش‌بینی‌های آب زیرزمینی سایه افکنده است، اما روند کلی تغییرات در آینده دور تحت سناریوی SSP5-8.5 به شکلی معنادار از سایر حالت‌ها متمایز و در سطحی پایین‌تر قرار می‌گیرد، که این امر لزوم در نظر گرفتن سناریوهای محتمل مختلف در برنامه‌ریزی منابع آب را دوچندان می‌کند.

تحلیل نمودارهای جعبه‌ای حاصل از پیش‌بینی الگوی ماهانه تراز آب زیرزمینی توسط مدل LSTM نشان‌دهنده بازه گسترده عدم قطعیت در پیش‌بینی تراز آب زیرزمینی تحت تأثیر خروجی‌های مختلف مدل‌های گردش عمومی جو است (شکل ۸). بر اساس نتایج، انحراف معیار تراز آب زیرزمینی در تمامی ماه‌ها و سناریوها، نوسانی بین ۱۲۹۷.۵ تا ۱۳۰۰ متر را تجربه می‌کند که بیانگر حساسیت بالای پاسخ هیدرولوژیکی آبخوان به عدم قطعیت بالا در شبیه‌سازی بارش و دما (به‌ویژه در ماه‌های بهار و اوایل پاییز) است. نکته حائز اهمیت، تمرکز پایین‌تر مقادیر و فشردگی بیشتر جعبه‌ها در سناریوی SSP5-8.5 برای آینده دور است که نشان می‌دهد با وجود شدت تغییر اقلیم در این سناریو، مدل‌های GCM بر روی روند کاهشی تراز آب توافق بیشتری دارند. در مقابل، سناریوی SSP2-4.5 در آینده نزدیک نه تنها بالاترین سطح تراز را نشان می‌دهد، بلکه با داشتن جعبه‌های کشیده‌تر و خطوط امتداد بلندتر، حاکی از وجود عدم قطعیت و پراکندگی بیشتر در داده‌های ورودی مدل‌های اقلیمی منتخب در این بازه زمانی است.



شکل ۸- نمودار جعبه‌ای ارزیابی عدم قطعیت تراز آب زیرزمینی.

Figure 8- Box plot for uncertainty assessment of GWL.

نتایج اعتبارسنجی مدل LARS-WG در دوره مشاهداتی، عملکرد بسیار مطلوب آن را در شبیه‌سازی متغیرهای دمای حداقل، دمای حداکثر و بارش روزانه تأیید کرد. پیش‌بینی‌های اقلیمی برای دوره‌های آینده (۲۰۳۰-۲۰۵۰ و ۲۰۷۰-۲۰۸۰) حاکی از یک روند افزایشی معنادار در دمای حداقل و حداکثر در تمامی ماه‌های سال است. این افزایش دما، به‌ویژه در ماه‌های گرم سال، منجر به تشدید تبخیر و تعرق، کاهش منابع آب سطحی و در نتیجه، کاهش تغذیه طبیعی آبخوان خواهد شد. علاوه بر این، گرمایش در فصول سرد، الگوی بارش را از برف به باران تغییر داده و با کاهش ذخیره برفی در ارتفاعات

نتیجه‌گیری

این پژوهش با هدف ارزیابی تأثیر تغییرات اقلیمی بر تراز آب زیرزمینی در چاه نمونه از دشت مراغه-بناب با استفاده از یک رویکرد ترکیبی شامل ریزمقیاس‌سازی آماری داده‌های مدل‌های گردش عمومی جو (GCMs) و شبیه‌سازی با مدل هوش مصنوعی انجام شد. برای این منظور، از مدل LARS-WG جهت ریزمقیاس‌سازی داده‌های اقلیمی پنج مدل منتخب از پروژه CMIP6 تحت سناریوهای SSP2-4.5 و SSP5-8.5 و از شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM) برای پیش‌بینی تراز آب زیرزمینی استفاده گردید.

خارا، س.، صادقی لاری، ع.، سامانی، س.، ۱۴۰۴. شبیه‌سازی عددی آب زیرزمینی با استفاده از مدل ریاضی (مطالعه موردی: آبخوان کهورستان، استان هرمزگان). هیدروژئولوژی، ۱۰(۱): ۵۰-۶۰.

خیاط، ا.، امیرآبادی‌زاده، م.، پوررضا بیلندی، م.، خزیمه‌نژاد، ح.، ۱۴۰۰. پیش‌بینی سطح آب زیرزمینی دشت بیرجند با استفاده از شبکه عصبی- فازی تحت تأثیر تغییر اقلیم. مجله آبخوان و قنات، ۳(۱): ۵۱-۳۸.

سمیعی دستجردی، ر.، حیات‌زاده، م.، فتح‌الله‌زاده، ع.، فتوحی فیروزآباد، ف.، ۱۴۰۳. شبیه‌سازی آب زیرزمینی با استفاده از سیستم هوش مصنوعی (مطالعه موردی: حوزه آبخیز کمه استان اصفهان). هیدروژئولوژی، ۹(۲): ۶۵-۷۶.

Reference

Afruzi, A., Zare Abyaneh, H., Abdolabadi, H., 2021. Local strategies to manage groundwater depletion under climate change scenarios—a case study: Hamedan-Bahar Plain (Iran). *Arabian Journal of Geosciences*, 14: 1548.

Al Atawneh, D., Cartwright, N., Bertone, E., 2021. Climate change and its impact on the projected values of groundwater recharge: A review. *Journal of Hydrology*, 601: 126602.

Al-Gamal, S., 2021. The potential impacts of climate change on groundwater management in west Africa. *Water Productivity Journal (WPJ)*, 1(3).

Allen, M., Antwi-Agyei, P., Aragon-Durand, F., Babiker, M., Bertoldi, P., Bind, M., et al., 2019. Technical Summary: Global warming of 1.5 °C. In: An IPCC Special Report on the impacts of global warming of 1.5 °C above pre-industrial levels... IPCC.

Anderson, M.P., Woessner, W.W., Hunt, R.J., 2015b. Chapter 6 – More on Sources and Sinks. In: Anderson, M.P., Woessner, W.W., Hunt, R.J. (Eds.), *Applied Groundwater Modeling (Second Edition)*. Academic Press, San Diego, pp. 257–301.

Aryasadr, M., Rahimi, D., Amiri, H., Zand, M., 2024. Impact of Climate Change on Groundwater in Cham Anjir Aquifer. *Spatial Planning*, 14(4): 53–80.

Epting, J., Michel, A., Affolter, A., Huggenberger, P., 2021. Climate change effects on groundwater recharge and temperatures in Swiss alluvial aquifers. *Journal of Hydrology X*, 11: 100071.

Gemitzi, A., Ajami, H., Richnow, H.H., 2017. Developing empirical monthly groundwater recharge

که منبع اصلی تغذیه در فصول ذوب هستند، پایداری منابع آب زیرزمینی را تهدید می‌کند.

یکی از یافته‌های کلیدی این مطالعه، تغییر در توزیع زمانی الگوی بارش بود. در حالی که میانگین بارش سالانه تغییرات چشمگیری نشان نمی‌دهد، وقوع بارش‌ها به سمت ماه‌های انتهایی پاییز و ابتدای زمستان سوق داده شده است. این پدیده به معنای طولانی‌تر شدن فصول خشک (تابستان) و تأخیر در شروع سال آبی است که تنش قابل‌توجهی را بر بخش کشاورزی و پوشش گیاهی منطقه تحمیل خواهد کرد. این تغییر در رژیم بارش، لزوم بازنگری در استراتژی‌های مدیریت منابع آب و الگوهای کشت را برای سازگاری با شرایط جدید اقلیمی دوچندان می‌سازد.

مدل LSTM با موفقیت توانست ارتباط غیرخطی پیچیده میان متغیرهای اقلیمی و تراز آب زیرزمینی را شبیه‌سازی کند. نتایج پیش‌نمایی نشان داد که تحت هر دو سناریوی SSP2-4.5 و SSP5-8.5، تراز آب زیرزمینی با افت قابل‌توجهی مواجه خواهد شد. همانطور که انتظار می‌رفت، شدت این افت در سناریوی بدبینانه (SSP5-8.5) به مراتب بیشتر است. این کاهش تراز، پیامد مستقیم اثرات ترکیبی کاهش تغذیه (ناشی از افزایش دما و تغییر رژیم بارش) و افزایش تقاضا است. با خشک‌تر شدن اقلیم و کاهش دسترسی به آب‌های سطحی، فشار بر منابع آب زیرزمینی به‌عنوان یک منبع پایدارتر افزایش یافته و این امر به تشدید بحران آبخوان منجر خواهد شد.

در مجموع، نتایج این تحقیق نشان می‌دهد که منابع آب زیرزمینی منطقه مورد مطالعه در برابر تغییرات اقلیمی بسیار آسیب‌پذیر هستند. یافته‌های ارائه شده می‌تواند به‌عنوان یک هشدار جدی برای مدیران و سیاست‌گذاران بخش آب عمل کرده و مبنایی علمی برای تدوین راهکارهای مدیریتی پیشگیرانه و سازگارانه، از جمله مدیریت تقاضا، افزایش بهره‌وری آب در بخش کشاورزی و اجرای طرح‌های تغذیه مصنوعی، فراهم آورد. پیشنهاد می‌شود در مطالعات آتی، اثرات توأمان تغییر اقلیم و تغییرات الگوهای برداشت انسانی (تحت سناریوهای مختلف اجتماعی-اقتصادی) بر وضعیت آبخوان مورد بررسی قرار گیرد.

منابع

abstraction scenarios. *Hydrology and Earth System Sciences*, 23: 2279–2303.

Nohani, E., Babaali, H., Dehghani, R., 2025. The Impact of Climate Change Parameters on Groundwater Level Decline (Case Study: Kuhdasht-Lorestan). *Journal of Aquifer and Qanat*, 6(1): 87–106.

Nourani, V., Kisi, Ö., Komasi, M., 2011. Two hybrid artificial intelligence approaches for modeling rainfall–runoff process. *Journal of Hydrology*, 402(2): 41–59.

Osman, A. I. A., Latif, S. D., Boo, K. B. W., Ahmed, A. N., Huang, Y. F., El-Shafie, A., 2024. Advanced machine learning algorithm to predict the implication of climate change on groundwater level for protecting aquifer from depletion. *Groundwater for Sustainable Development*, 25: 101152.

Ouyang, Y., Wan, Y., Jin, W., Leininger, T.D., Feng, G., Han, Y., 2021. Impact of climate change on groundwater resource in a region with a fast depletion rate: the Mississippi Embayment. *Journal of Water and Climate Change*, 12(6): 2245.

Parmesan, C., Morecroft, M.D., Trisurat, Y., 2022. Climate change 2022: Impacts, adaptation and vulnerability. Ph.D. dissertation, GIEC.

Patra, S.R., Chu, H-J., Aman, M.A., 2024. Utilizing deep learning to investigate the impacts of climate change on groundwater dynamics and pumping variability. *Science of the Total Environment*, 957: 177784.

Rouhani, A., Ben-Salem, N., D’Oria, M., Chávez García Silva, R., Viglione, A., Coptý, N.K., Rode, M., Barry, D.A., Gómez-Hernández, J.J., Jomaa, S., 2025. Direct impact of climate change on groundwater levels in the Iberian Peninsula. *Science of the Total Environment*, 970: 179009.

Ryter, D.W., Alzraiee, A.H., Niswonger, R.G., 2025. Simulation of the impacts of projected climate change on groundwater resources in the Urban, Semiarid Yucaipa Valley Watershed, Southern California using an integrated hydrologic model. *Journal of Hydrology: Regional Studies*, 60: 102461.

Samiei Dastjerdi, R., Hayat-Zadeh, M., Fathollah-Zadeh, A., Fotouhi Firouzabad, F., 2024. Simulation of groundwater using artificial intelligence system (Case study: Komeh Basin of Isfahan province). *Hydrogeology*, 9(2): 65–76. [In Persian]

Secci, D., Tanda, M.G., D’Oria, M., Todaro, V., 2023. Artificial intelligence models to evaluate the impact of climate change on groundwater resources. *Journal of Hydrology*, 627: 130359.

equations based on modeling and remote sensing data – Modeling future groundwater recharge to predict potential climate change impacts. *Journal of Hydrology*, 546: 1–13.

Goderniaux, P., Brouyère, S., Blenkinsop, S., Burton, A., Fowler, H.J., Orban, P., Dassargues, A., 2011. Modeling climate change impacts on groundwater resources using transient stochastic climatic scenarios. *Water Resources Research*, 47: W12516.

Green, T.R., Taniguchi, M., Kooi, H., Gurdak, J.J., Allen, D.M., Hiscock, K.M., Treidel, H., Aureli, A., 2011. Beneath the surface of global change: Impacts of climate change on groundwater. *Journal of Hydrology*, 405: 532–560.

Hashemi, H., Uvo, C.B., Berndtsson, R., 2015. Coupled modeling approach to assess climate change impacts on groundwater recharge and adaptation in arid areas. *Hydrology and Earth System Sciences*, 19(10): 4165–4181.

Hughes, A., Mansour, M., Ward, R., Kieboom, N., Allen, S., Seccombe, D., Charlton, M., Prudhomme, C., 2021. The impact of climate change on groundwater recharge: National-scale assessment for the British mainland. *Journal of Hydrology*, 598: 126336.

Hughes, J.D., Langevin, C.D., Banta, E.R., 2017. Documentation for the MODFLOW 6 Framework. US Geological Survey, Reston, Virginia, 2328-7055.

Jahangir, M.H., Haghighi, P., Danehkar, S.H., 2022. Downscaling climate parameters in Fars province using models of the fifth report and RCP scenarios. *Ecological Informatics*, 68(4): 558–562.

Jakeman, A.J., Barreteau, O., Hunt, R.J., Rinaudo, J.D., Ross, A., 2016. *Integrated Groundwater Management*. Springer Nature, 762 p.

Khara, S., Sadeghi Lari, A., Samani, S., 2025. Numerical Simulation of Groundwater Using Mathematical Model (Case Study: Kahorestan Aquifer, Hormozgan Province, Southern Iran). *Hydrogeology*, 10(1): 50–60. [In Persian]

Khayyat, E., Amirabadi-Zadeh, M., Pourreza Bilandi, M., Khozimeh-Nezhad, H., 2021. Prediction of groundwater level in Birjand Plain using the Fuzzy Artificial Neural network under the effects of climate change, 3(1): 38–51. [In Persian]

Mustafa, S.M.T., Hasan, M.M., Saha, A.K., Rannu, R.P., Van Uytven, E., Willems, P., Huysmans, M., 2019. Multi-model approach to quantify groundwater-level prediction uncertainty using an ensemble of global climate models and multiple

Semenov, M.A., 2008. Simulation of extreme weather events by a stochastic weather generator. *Climate Research*, 35(3): 203–212.

Semenov, M.A., Stratonovitch, P., 2015. Adapting wheat ideotypes for climate change: Accounting for uncertainties in CMIP5 climate projections. *Climate Research*, 65: 123–139.

Wei, A., Li, X., Yan, L., Wang, Z., Yu, X., 2023. Machine learning models combined with wavelet transform and phase space reconstruction for groundwater level forecasting. *Computers & Geosciences*, 177: 105386.

Zhang, Q., Li, P., Ren, X., Ning, J., Li, J., Liu, C., Wang, Y., Wang, G., 2023. A new real-time groundwater level forecasting strategy: coupling hybrid data-driven models with remote sensing data. *Journal of Hydrology*, 625: 129962.