

Groundwater Level Forecasting using a Deep Learning Convolutional Neural Network (CNN) Model: Seidan-Farooq Study Area

M. J. Aghaei¹ and H. Ketabchi^{2*}

Abstract

Groundwater, as one of the vital resources for meeting human, agriculture, industry, and environment's needs, plays a key role in water resources management. Given the increasing challenges in water resources management, accurate forecasting of groundwater levels is crucial for the sustainable utilization of these resources. In this study, a deep learning model using Convolutional Neural Networks (CNN) is applied to forecast groundwater levels in the Seidan-Farooq area within the Tashk Bakhtegan Maharloo basin, Fars province. The proposed model uses meteorological data, including precipitation and temperature, evapotranspiration, and historical groundwater level data as inputs. The results show that incorporating past groundwater levels (with a one-month lag) into the model has increased forecasting accuracy. In the first scenario, the model achieved a Nash-Sutcliffe efficiency (NSE) of 0.99 and a coefficient of determination (R^2) of 0.98 using meteorological parameters. In the second scenario, where historical groundwater data was added, the RMSE decreased from 0.49 to 0.35 meters, and the model's stability index (PI) increased from 0.6 to 0.8. Additionally, error analysis and model accuracy on a seasonal and monthly basis indicated that the second scenario outperforms the first. These results demonstrate the model's high capability in simulating temporal changes and seasonal fluctuations in groundwater levels. This approach can serve as an effective tool for managing groundwater resources in regions facing a scarcity of observational data.

Keywords: Groundwater Modeling, Groundwater Level Forecasting, Deep Learning, Convolutional Neural Network.

Received: December 7, 2024

Accepted: February 16, 2025

پیش بینی سطح آب زیرزمینی با استفاده از مدل یادگیری عمیق شبکه عصبی کانولوشنی (CNN): محدوده مطالعاتی سیدان - فاروق

محمدجواد آقایی^۱ و حامد کتابچی^{۲*}

چکیده

آب زیرزمینی به عنوان یکی از منابع حیاتی برای تأمین نیازهای انسانی، کشاورزی، صنعتی و محیط زیستی، نقش مهمی در مدیریت منابع آبی ایفا می کند. با توجه به چالش های روزافزون در مدیریت منابع آب، پیش بینی دقیق سطح آب زیرزمینی، اهمیت بسیاری در بهره برداری پایدار از این منابع دارد. در این تحقیق، از مدل یادگیری عمیق شبکه عصبی کانولوشنی (CNN) برای پیش بینی سطح آب زیرزمینی در منطقه سیدان-فاروق در حوضه آبریز طشک بختگان مهارلو، استان فارس استفاده شده است. مدل پیشنهادی از داده های هواشناسی شامل بارش، دما، تبخیر تعرق و داده های تاریخی سطح آب زیرزمینی به عنوان ورودی استفاده می کند. نتایج نشان می دهد که افزودن داده های سطح آب زیرزمینی گذشته (با تأخیر یک ماهه) به مدل، دقت پیش بینی را افزایش داده است. در سناریوی اول، مدل با استفاده از پارامترهای هواشناسی به مقادیر نش 0.99 و ضریب تعیین 0.98 دست یافت. در سناریوی دوم که داده های تاریخی سطح آب زیرزمینی اضافه شد، مقدار RMSE از 0.49 متر به 0.35 متر کاهش یافته و شاخص پایداری مدل (PI) از 0.6 به 0.8 افزایش یافته است. همچنین تحلیل خطا و دقت مدل به طور فصلی و ماهانه نشان می دهد که سناریوی دوم عملکرد بهتری را نسبت به سناریوی اول داشته است. این نتایج نشان دهنده توانایی بالای مدل در شبیه سازی تغییرات زمانی سطح آب زیرزمینی و نوسانات فصلی آن است. این رویکرد می تواند به عنوان ابزاری مؤثر برای مدیریت منابع آب زیرزمینی در مناطقی که با کمبود داده های مشاهداتی مواجه هستند، مورد استفاده قرار گیرد.

کلمات کلیدی: مدل سازی آب زیرزمینی، پیش بینی سطح آب زیرزمینی، یادگیری عمیق، شبکه عصبی کانولوشنی.

تاریخ دریافت مقاله: ۱۴۰۳/۹/۱۷

تاریخ پذیرش مقاله: ۱۴۰۳/۱۱/۲۸

1- M.Sc. Student, Department of Water Engineering and Management, Tarbiat Modares University, Tehran, Iran. E-mail: aghaei_m@modares.ac.ir

2- Associate Professor, Department of Water Engineering and Management, Tarbiat Modares University, Tehran, Iran. E-mail: h.ketabchi@modares.ac.ir

*- Corresponding Author

Doi: [10.22034/iwrr.2025.492757.2805](https://doi.org/10.22034/iwrr.2025.492757.2805)

۱- دانشجوی کارشناسی ارشد گروه مهندسی و مدیریت آب، دانشگاه تربیت مدرس، تهران، ایران.

۲- دانشیار گروه مهندسی و مدیریت آب، دانشگاه تربیت مدرس، تهران، ایران.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان تابستان ۱۴۰۴ امکان پذیر است.

داده‌های محدودی در دسترس دارند، مفید باشد. محدودیت داده‌ها از یک سو و از سوی دیگر، دستیابی به پیش‌بینی‌های دقیق، مهم‌تر از درک رفتارهای زیربنایی است. از این رو مدل‌های هوش مصنوعی می‌توانند جایگزین مناسبی برای مدل‌های فیزیکی باشند. بسیاری از هیدرولوژیست‌ها و پژوهشگران حوزه آب توانایی بالقوه مدل‌های یادگیری ماشین را به ویژه برای استفاده از آن‌ها در شبیه‌سازی سطح آب زیرزمینی تشخیص داده‌اند (Bai and Tahmasebi, 2023).

مزیت اصلی مدل‌های هوش مصنوعی، مدل‌سازی پدیده‌های غیرخطی و پیچیده، بدون نیاز به درک کامل رفتارهای زیربنایی است (Rajaei et al., 2019). در دهه‌های اخیر، مدل‌های هوش مصنوعی به طور گسترده به عنوان مدلی مؤثر و توانا در پیش‌بینی سطح آب زیرزمینی در سیستم‌های هیدرولوژی پیشرفته به کار گرفته شده‌اند (Wunsch et al., 2021). قابلیت استفاده و اطمینان‌پذیر بودن مدل‌های هوش مصنوعی در برخورد با مسائل مهندسی پیچیده و با ابعاد بالا، در چند دهه اخیر ثابت شده است. در سال‌های اخیر، توجه بیشتری به استفاده موفق از هوش مصنوعی در زمینه‌های مختلف هیدرولوژیکی از جمله منابع آب (Yaseen et al., 2019)، هیدرولوژی آب‌های سطحی و زیرزمینی (Adnan et al., 2020)، آلودگی رسوبی (Bhagat et al., 2020) و هیدرولیک (Mahdavi-Meymand and Zounemat-Kermani, 2020) شده است. حجم زیادی از مطالعات قبلی، کاربرد هوش مصنوعی در مدل‌سازی سطح آب زیرزمینی را مورد بررسی قرار داده و گزارش کرده‌اند (Sit et al., 2020). بیشتر کارهای اولیه شامل روش‌های ساده و استاندارد هوش مصنوعی، مانند شبکه‌های عصبی مصنوعی پرسپترون (MLP³) است (Rogers and Dowla, 1994). شبکه عصبی مصنوعی ANN⁴ یک سیستم کامپیوتری است که برای پردازش و تجزیه و تحلیل اطلاعات با الگوبرداری از مغز انسان طراحی شده است (Tao et al., 2022). استفاده از مدل‌های هوش مصنوعی به‌ویژه شبکه‌های عصبی، منطق فازی و مدل‌های ترکیبی به عنوان ابزارهایی کارآمد در پیش‌بینی سطح آب زیرزمینی مطرح شده است. مطالعات مختلف نشان می‌دهند که استفاده از مدل‌های هوش مصنوعی، مانند جنگل تصادفی و منطق فازی، می‌تواند دقت پیش‌بینی سطح آب زیرزمینی را به طور قابل توجهی افزایش دهد و به تصمیم‌گیری‌های بهتر در مدیریت منابع آب کمک کند (Norozzi and Nadiri, 2018). همچنین، بر اساس تحقیقات انجام شده، مدل‌های یادگیری ماشین مانند شبکه‌های عصبی و مدل‌های فازی می‌توانند در پیش‌بینی سطح آب زیرزمینی در مناطق

آب زیرزمینی یکی از مهم‌ترین منابع آبی روی زمین است و برای مصارف مختلفی از جمله شرب، کشاورزی، صنعت و محیط‌زیست مورد استفاده قرار می‌گیرد. حداقل نیمی از جمعیت جهان از آب زیرزمینی برای تأمین آب شرب استفاده می‌کنند (WWAP, 2015). شناخت صحیح و بهره‌برداری اصولی از منابع آب زیرزمینی می‌تواند در توسعه پایدار فعالیت‌های اجتماعی و اقتصادی آن منطقه نقش بسزایی داشته باشد. عدم شناخت صحیح و بهره‌برداری بی‌رویه از منابع آب زیرزمینی آثار نامطلوبی مانند افت شدید سطح آب زیرزمینی (GWL¹)، کاهش کیفیت آب و فرونشست زمین را به دنبال خواهد داشت (Rajaei et al., 2019).

مدل‌سازی آب‌های زیرزمینی، ابزاری برای توسعه‌ی برنامه‌ریزی‌های مدیریتی قابل اجرا و حفاظت از این منبع حیاتی است (Nadiri et al., 2016; Ketabchi et al., 2024). پیش‌بینی سطح آب زیرزمینی یکی از چالش‌های مهم در مدیریت منابع آب است بطوریکه پیش‌بینی‌های دقیق و قابل اعتماد سطح آب زیرزمینی یک ابزار کلیدی در زمینه مدیریت پایدار این منابع است؛ زیرا اطلاعات مهمی در مورد میزان در دسترس بودن آب‌های زیرزمینی ارائه می‌کند. بنابراین می‌تواند مبنایی برای تصمیم‌گیری‌ها و راهبردهای مدیریتی باشد (Khan et al., 2023). با این حال، سطح آب زیرزمینی شامل یک پاسخ یکپارچه به چندین عامل اقلیمی، توپوگرافی، هیدروژئولوژیکی و تعاملات آن‌ها است که شبیه‌سازی سطح آب زیرزمینی را به یک کار چالش برانگیز تبدیل می‌کند (Nadiri et al., 2016).

نداشتن سوابق سطح آب زیرزمینی یک مسئله رایج به ویژه در کشورهای در حال توسعه و توسعه نیافته است. عوامل انسانی، خرابی تجهیزات و نوسانات سطح آب از جمله عواملی هستند که در نبود یا از بین رفتن این سوابق نقش دارند. بنابراین، بازسازی مقادیر سطح آب زیرزمینی می‌تواند به درک بهتر سیستم‌های آبخوان کمک کند (Rajaei et al., 2019). مدل‌های مفهومی یا فیزیکی، ابزارهای اصلی برای مدل‌سازی سطح آب زیرزمینی به صورت سنتی هستند که دارای محدودیت‌هایی از جمله نیاز به مقادیر زیاد داده و پارامترهای ورودی هستند. در سال‌های اخیر، هوش مصنوعی (AI²) به عنوان یک ابزار قدرتمند برای پیش‌بینی سطح آب زیرزمینی مورد توجه قرار گرفته است. هوش مصنوعی می‌تواند با استفاده از الگوریتم‌های یادگیری ماشین، از داده‌های تاریخی برای پیش‌بینی آینده استفاده کند (Wunsch et al., 2021). این روش می‌تواند با استفاده از داده‌های کمتر از مدل‌های فیزیکی، پیش‌بینی‌های دقیقی انجام دهد. این امر می‌تواند برای مناطقی که

عمیق با بهره‌گیری از لایه‌های ورودی، پنهان و خروجی، توانایی تجزیه و تحلیل داده‌های پیچیده و با ابعاد بالا را با سرعت بیشتر و نیاز کمتر به نیروی انسانی در مقایسه با روش‌های سنتی فراهم می‌کند (Sengupta et al., 2020). در مطالعات هیدرولوژی، مدل‌های CNN⁵ و LSTM⁶ از پرکاربردترین مدل‌های یادگیری عمیق به شمار می‌روند (Sit et al., 2020).

با داده‌های محدود و غیرهمگن کارایی بالایی داشته باشند (Khatibi and Nadiri, 2021). از سوی دیگر، ترکیب مدل‌های مختلف هوش مصنوعی و روش‌های دسته‌بندی مانند SOM به‌ویژه در مناطق با ناهمگنی زیاد می‌تواند به بهبود دقت پیش‌بینی نوسانات سطح آب زیرزمینی کمک کند (Bagheri et al., 2018). یادگیری عمیق زیرشاخه‌ای از هوش مصنوعی و یادگیری ماشین است که در آن از شبکه‌های عصبی مصنوعی (با بیش از سه لایه) برای استخراج ویژگی استفاده می‌شود (شکل ۱). مدل‌های یادگیری

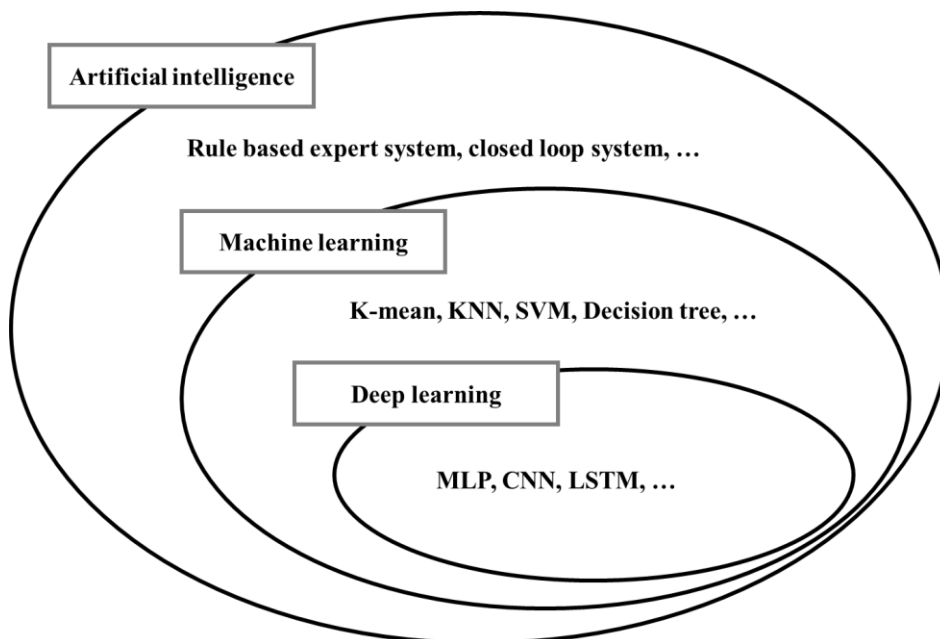


Fig. 1- Artificial intelligence and its subsets
شکل ۱- هوش مصنوعی و زیرمجموعه‌های آن

این رویکرد به منظور افزایش دقت پیش‌بینی‌های آب زیرزمینی طراحی شده است. در ادامه این مطالعه، به بررسی منطقه مورد مطالعه، داده‌های به کار رفته در تحقیق و جزئیات فنی مربوط به ساختار و واسنجی مدل پرداخته خواهد شد تا چگونگی اجرا و کاربرد مدل در شرایط مختلف مشخص شود. نوآوری اصلی این تحقیق، ارائه یک مدل یادگیری عمیق شبکه عصبی کانولوشنی (CNN) برای پیش‌بینی سطح آب زیرزمینی در منطقه‌ای واقعی است که قابلیت تعمیم به مناطق مختلف را دارد و به‌ویژه در مناطقی که با کمبود داده‌های مشاهداتی مواجه هستند، کاربردی است که از این منظر کمتر در مطالعات پیشین مورد توجه بوده است.

کاربرد یادگیری عمیق در آب‌های زیرزمینی می‌تواند به سه گروه عمده (۱) مقایسه عملکرد الگوریتم‌های مختلف یادگیری عمیق، (۲) پر کردن مقادیر داده از دست رفته و (۳) بهبود چارچوب شبیه‌سازی تقسیم شود (Peifeng Li and Krebs, 2022)، که در تحقیق حاضر بهبود چارچوب شبیه‌سازی مدنظر گرفته خواهد شد. با توجه به اهمیت پیش‌بینی دقیق و قابل اطمینان سطح آب زیرزمینی در مدیریت منابع آب و محدودیت‌های موجود در مدل‌های مفهومی و داده‌محور سنتی، این تحقیق با بهره‌گیری از مدل یادگیری عمیق شبکه‌های عصبی کانولوشنی (CNN)، در صدد است تا با استفاده از داده‌های هواشناسی و سطح آب زیرزمینی گذشته، یک مدل پیش‌بینی سازگار و قابل استفاده در مناطق مختلف حتی در مناطقی که با کمبود داده روبرو هستند، توسعه دهد.

۲- مواد و روش

۲-۱- منطقه مورد مطالعه

محدوده مطالعاتی سیدان- فاروق در حوضه آبریز طشک بختگان مهارلو واقع در استان فارس کشور ایران با گستره جغرافیایی بین طول‌های ۵۲ درجه و ۵۴ دقیقه تا ۵۳ درجه و ۱۵ دقیقه و عرض‌های ۲۹ درجه و ۴۷ دقیقه تا ۳۰ درجه و ۷ دقیقه و مساحت کلی ۳۶۹ کیلومتر مربع قرار دارد که از این مقدار حدود ۱۹۶/۷ کیلومتر مربع آن به ارتفاعات و ۱۷۲/۳ کیلومتر مربع به دشت اختصاص یافته است. ارتفاع متوسط این محدوده مطالعاتی ۱۷۰۲/۶ متر بالاتر از سطح دریا است و بیشترین ارتفاع منطقه به ۲۸۴۰ متر در ارتفاعات شمالی سیوند (کوه سیدان) می‌رسد. پایین‌ترین ارتفاع نیز در نقطه خروجی آب‌های سطحی در تنگ گلوآسیاب قرار دارد که ۱۶۲۰ متر از سطح دریا ارتفاع دارد. این منطقه در بخش مرکزی حوضه آبریز دریاچه‌های طشک- بختگان و مهارلو جای دارد و از سمت شرق به منطقه سعادت‌آباد محدود می‌شود (شکل ۲). متوسط بارندگی سالانه این محدوده بین ۳۲۶ تا ۴۳۴ میلی‌متر بوده و دمای میانگین آن نیز از ۳- تا ۱۷ درجه سانتی‌گراد متغیر است. این منطقه دارای ۱۵ چاه مشاهداتی برای پایش سطح آب زیرزمینی است که در نقاط مختلف توزیع شده‌اند (شکل ۲). این چاه‌ها به صورت منظم برای بررسی تغییرات سطح آب زیرزمینی مورد استفاده قرار گرفته‌اند. آبخوان این منطقه از نوع آبرفتی بوده و دارای مساحت تقریبی ۱۵۱/۴ کیلومتر مترمربع است. ضخامت متوسط آبخوان ۶۰ متر بوده که کمینه آن ۰/۹ و بیشینه آن ۷۵ متر از سطح زمین است و ضریب ذخیره متوسط آن ۵ درصد است. همچنین، ضریب قابلیت انتقال چاه‌های اکتشافی در این محدوده به طور میانگین ۸۶۸ مترمربع بر روز است. بیلان سالانه آبخوان نشان می‌دهد که تغذیه سالانه برابر با ۱۷۴ میلیون مترمکعب و برداشت کل سالانه از آب زیرزمینی برابر با ۱۸۴ میلیون مترمکعب است که نشان‌دهنده کاهش ذخیره سالانه است. این موضوع تأکید می‌کند که مدیریت منابع آب در این منطقه بسیار حیاتی است.

۲-۲- داده‌های مورد استفاده

یکی از مسائل کار با مدل‌های هوش مصنوعی، انتخاب داده‌های ورودی مناسب برای مدل است. (Tao et al., 2023) با توجه به مرور مطالعات پیشین در مورد پیش‌بینی سطح آب زیرزمینی با استفاده از یادگیری ماشین دریافتند که اکثر مطالعات قبلی مرتبط با GWL، بارش و تبخیر را به عنوان متغیرهای ورودی برای پیش‌بینی

GWL استفاده کرده‌اند. این که چه تعداد داده برای ساخت مدل-هایی که قادر به انجام محاسبات معقول هستند لازم است، هنوز یک سؤال باقی مانده است (Wunsch et al., 2021). پاسخ این سؤال به کاربرد مدل، ویژگی‌های داده (به عنوان مثال توزیع) و ویژگی‌های مدل وابسته است، زیرا عمق مدل (لایه‌های پنهان) گاهی اوقات می‌تواند نیاز به داده را به طور تصاعدی کاهش دهد (Goodfellow et al., 2017). در این مطالعه، از متغیرهای هواشناسی شامل بارش (P)، دما (T) و تبخیر تعرق (ET) به عنوان ورودی مدل استفاده شده است. انتخاب این متغیرها به دلیل دسترسی گسترده، قابلیت اطمینان و سهولت در اندازه‌گیری، انتقال‌پذیری این رویکرد را در مناطق مختلف فراهم می‌کند. بارش می‌تواند به عنوان نمایانگر تغذیه آب زیرزمینی عمل کند، دما و تبخیر تعرق نیز اطلاعات فصلی را به شبکه ارائه می‌دهند؛ زیرا این دو پارامتر معمولاً از یک چرخه سالانه منظم پیروی می‌کنند. به عنوان ورودی مصنوعی اضافی، یک سیگنال سینوسی تنظیم‌شده با منحنی دما (Tsin) می‌تواند اطلاعات فصلی بدون نویز را به مدل منتقل کند که اغلب موجب بهبود قابل توجه در پیش‌بینی‌ها می‌شود (Kong-A-Siou et al., 2014).

مهم‌ترین پارامتر ورودی از بین این متغیرها، بارش (P) است؛ زیرا تغذیه آب زیرزمینی معمولاً بیشترین تأثیر را بر تغییرات سطح آب زیرزمینی دارد. به همین دلیل، بارش به عنوان ورودی اصلی مدل در نظر گرفته می‌شود. به دلیل همبستگی بالای سطح آب زیرزمینی در سری‌های زمانی، سطح آب زیرزمینی گذشته به عنوان داده‌ای مناسب برای پیش‌بینی مقادیر آینده در نظر گرفته می‌شود. در این مطالعه، تأثیر این پارامتر بر عملکرد مدل مورد بررسی قرار می‌گیرد. پارامترهای مورد استفاده در این مطالعه با استفاده از تصاویر و محصولات سنجنش‌ازدور تهیه شده است، لازم به ذکر است که کلیه پردازش‌های مربوط به تصاویر و محصولات ماهواره‌ای در این مطالعه در محیط بستر ابری GEE⁷ و در مقیاس مکانی محدوده مطالعاتی انجام شده است (Sadeghi-Jahani et al., 2024).

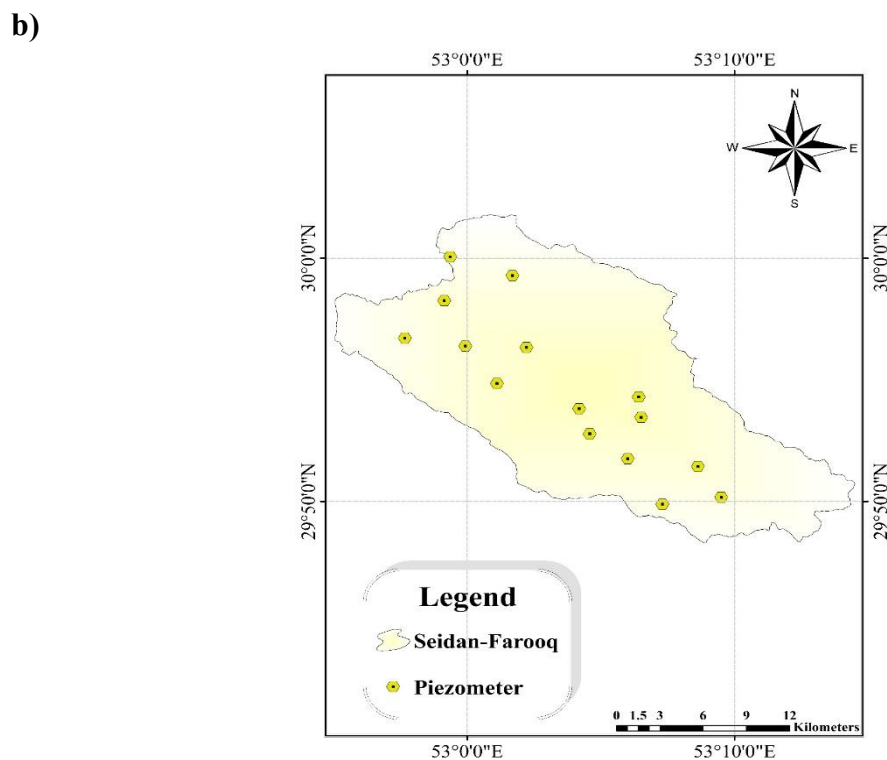
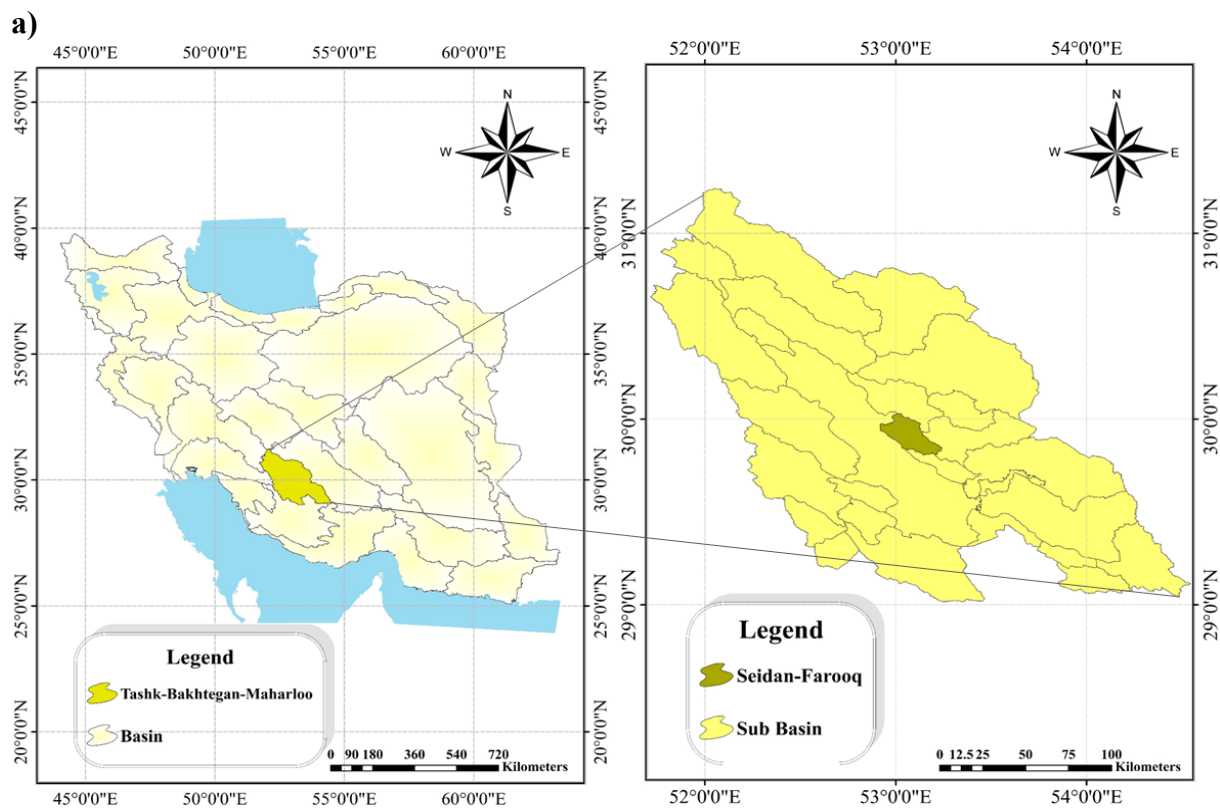


Fig. 2- Geographical location of Seidan-Farooq study area (a) and location of observation wells (b)
 شکل ۲- موقعیت جغرافیایی محدوده مطالعاتی سیدان- فاروق (الف) موقعیت چاه‌های مشاهداتی (ب)

۲-۲-۱- بارش

بسته سنجنده GPM⁸ توسعه یافته سنجنده TRMM⁹ است که از آرایه های دو فرکانسی بارش شامل رادار بارش (DPR¹⁰) و مشاهدات میکروویو چندکاناله (GMI) استفاده می کند. DPR برای مشاهده ساختارهای داخلی طوفان ها و زیرلایه های ابرها به کار می رود، در حالی که GMI¹¹ شدت، نوع و مقدار بارش را اندازه گیری می کند (Hou et al., 2014; Tan and Duan, 2017). از ویژگی های کلیدی GPM می توان به پوشش مکانی گسترده تر، توان تفکیک زمانی و مکانی بهتر، و دقت بالاتر در تخمین بارش (شامل باران و برف)، به ویژه در مناطق مرتفع و کوهستانی اشاره کرد (Wang et al., 2017). داده های سری زمانی محصول GPM (IMERG V6¹²) در مقیاس زمانی ماهانه از ژوئن ۲۰۰۰ تا آوریل ۲۰۲۱ قابل پردازش و استخراج هستند.

۲-۲-۲- دما

سری زمانی دما بر اساس محصول MOD11A2 سنجنده مادیس، شامل داده های دما در ساعات روز و شب، به صورت میانگین هشت روزه در بازه زمانی ۲۶ فوریه ۲۰۰۰ تا ۳۱ دسامبر ۲۰۲۱ در دسترس است. همچنین، باتوجه به تفکیک زمانی ۸ روزه این محصول، میانگین داده های هشت روزه برای هر ماه محاسبه شده و به عنوان دمای ماهانه در نظر گرفته شد (شکل ۳).

۲-۲-۳- تبخیر تعرق

محصول MOD16A2 سنجنده مادیس که بر اساس معادله پنمن-مانتیت توسعه یافته است، داده های مناسبی برای مطالعه الگوهای زمانی و مکانی تبخیر تعرق ارائه می دهد. این محصول با تفکیک مکانی ۵۰۰ متر و تفکیک زمانی ۸ روزه امکان تحلیل های دقیق تری را فراهم می سازد (Hu et al., 2015). MOD16A2 در مطالعات مختلف مناطق جهان نتایج قابل اعتمادی ارائه کرده (Trambauer et al., 2014; Hu et al., 2015; Wambura et al., 2017) و به دلیل دقت بالای زمانی و مکانی برای ارزیابی

تبخیر تعرق واقعی و پتانسیل در این تحقیق استفاده شده است (Ruhoff et al., 2021). همچنین، یافته های (Cheng et al., 2021) نشان می دهد که ترکیب داده های این محصول در مقیاس های زمانی ماهانه و سالانه می تواند به افزایش دقت آن کمک کند.

الگوریتم تولید MOD16A2 بر مبنای منطق معادله پنمن-مانتیت است و از داده های هواشناسی و تغییرات ویژگی های محیطی که از تصاویر ماهواره ای به دست آمده، برای تولید اطلاعات استفاده می کند. داده های تبخیر تعرق پتانسیل و واقعی نیز به طور هم زمان استخراج می شوند. از آنجا که این محصول به صورت هشت روزه ارائه می شود، برای تولید سری زمانی ماهانه لازم است که تبدیلی های مناسب بر اساس زمان بندی هر تصویر انجام شود.

۲-۲-۴- هیدروگراف معرف آبخوان

رایج ترین روش در ترسیم هیدروگراف آبخوان استفاده از چند ضلعی های تیسن است. روش چند ضلعی های تیسن نیازمند وجود شبکه متمرکز چاه مشاهداتی است و در آبخوان هایی که رفتار منظم گرادیان هیدرولیکی وجود دارد مناسب تر است (Masoumi et al., 2019). با در نظر داشتن اینکه شبکه چاه مشاهده ای متراکم و گسترده ای در منطقه وجود دارد، از این روش برای درونیابی و تولید هیدروگراف آب زیرزمینی استفاده می شود.

برای تولید هیدروگراف معرف، ابتدا داده های چاه های مشاهداتی موجود در منطقه بررسی شدند. از میان این داده ها، چهار چاه که دارای تعداد زیادی داده های گم شده بودند، حذف شدند. سپس، با استفاده از داده های باقی مانده از ۱۱ چاه مشاهداتی، چندضلعی های تیسن ترسیم شدند. پس از ترسیم چندضلعی تیسن مساحت تحت پوشش هر چاه مشاهداتی مشخص شده و بر این اساس وزن هر چاه مشاهداتی در محاسبه میانگین وزنی مشخص شده و هیدروگراف ترسیم می شود (شکل ۴).




Fig. 3- Precipitation, temperature, evapotranspiration data & Tsin
 شکل ۳- داده‌های بارش، دما، تبخیر تعرق و منحنی سینوسی بدون نویز منطبق بر دما




Fig. 4- Hydrograph of Seidan-Farooq aquifer
 شکل ۴- هیدروگراف آبخوان سیدان- فاروق

۳-۲- شبکه‌های عصبی کانولوشنی

شبکه‌های عصبی کانولوشنی (CNN) که توسط (LeCun et al., 2015) معرفی شدند، عمدتاً برای تشخیص و طبقه‌بندی تصاویر به کار می‌روند. با این حال، این شبکه‌ها در پردازش سیگنال و وظایف مرتبط با پردازش زبان طبیعی نیز عملکرد قابل توجهی از خود نشان داده‌اند. معماری شبکه‌های CNN معمولاً از سه لایه اصلی تشکیل شده است. لایه‌های کانولوشن، به‌عنوان اولین لایه‌ها در شبکه CNN، شامل فیلترها و نقشه‌های ویژگی هستند. فیلترها با ابعاد ثابت روی کل لایه قبلی حرکت کرده و خروجی این فرآیند به‌صورت یک نقشه ویژگی جمع‌آوری می‌شود. این لایه‌ها اغلب با لایه‌های Pooling دنبال می‌شوند که نمونه‌برداری کاهش‌یافته‌ای از نقشه ویژگی‌های قبلی انجام می‌دهند. در این لایه‌ها، یک میدان پذیرنده^{۱۳} روی نقشه ویژگی حرکت کرده و اطلاعات تجمیع شده؛

و عملیاتی ساده، مانند میانگین‌گیری یا انتخاب حداکثر، اعمال می‌شود. در معماری‌های عمیق‌تر CNN، لایه‌های کانولوشن و Pooling به‌صورت ترتیبی چیده می‌شوند. در نهایت، آخرین لایه به یک لایه متراکم کاملاً متصل ختم می‌شود که دارای یک یا چند نورون خروجی است (شکل ۵).

برای اجرای مدل CNN، از Python 3.11.5 (Van Rossum, 1995) در کنار کتابخانه‌های Numpy و Pandas و با استفاده از چارچوب‌های یادگیری عمیق TensorFlow و Keras بهره‌گرفته شده است. در این مطالعه از رویکرد "دنباله به مقدار"^{۱۴} استفاده شده است؛ به این معنا که مدل از مجموعه‌ای از داده‌های دنباله‌ای (مانند داده‌های دما، تبخیر تعرق و بارش) برای تولید یک مقدار خروجی استفاده می‌کند که به‌عنوان مقدار پیش‌بینی شده برای مرحله یا بازه زمانی بعدی در نظر گرفته می‌شود.




Fig. 5- A simple CNN structure for image classification

شکل ۵- ساختار ساده CNN برای طبقه‌بندی تصاویر

یک سال داده ماهانه است)، تعداد فیلترها (از ۱ تا ۲۵۶) در لایه کانولوشن، و تعداد نورون‌ها در اولین لایه متراکم (از ۱ تا ۲۵۶) با استفاده از مدل بهینه‌سازی بیزین تنظیم شده‌اند (شکل ۶). بهینه‌سازی هایپرپارامترها با استفاده از روش بهینه‌سازی بیزین و پیاده‌سازی آن توسط (Nogueira 2014) در Python انجام شده است. این فرایند شامل حداقل ۵۰ گام بهینه‌سازی است؛ ابتدا ۲۵ گام به‌صورت تصادفی برای اکتشاف و سپس ۲۵ گام با روش بهینه‌سازی بیزین. در صورتی که در ۱۰ گام متوالی بهبودی حاصل نشود یا تعداد کل گام‌ها به ۱۵۰ برسد، بهینه‌سازی متوقف می‌شود. مدل برای حداکثر ۳۰ دوره آموزشی^{۱۹} تنظیم شده است و به‌منظور جلوگیری از بیش‌برازش^{۲۰}، از تکنیک توقف زود هنگام^{۲۱} با انتظار

۴-۲- واسنجی مدل

مدل CNN به‌کارگرفته‌شده در این مطالعه شامل یک لایه کانولوشن، یک لایه حداکثر تجمیع^{۱۵} و دو لایه متراکم است (شکل ۶). از بهینه‌ساز Adam با نرخ یادگیری اولیه ۰/۰۰۱ استفاده شده و برای جلوگیری از انفجار گرادینت^{۱۶}، تکنیک برش گرادینت^{۱۷} اعمال شده است. در این تحقیق، بهینه‌سازی هایپرپارامترها^{۱۸} (HPs) از طریق یک مدل بیزین صورت گرفته است. برای مدل CNN، اندازه هسته کانولوشن برابر با ۳ انتخاب شده و هایپرپارامترهای بهینه‌شده شامل ورودی‌های دما (T)، تبخیر تعرق (ET)، تابع سینوسی دما (Tsin) (با مقدار ۰ یا ۱ به معنای خیر یا بله)، اندازه دسته (از ۱ تا ۲۵۶)، طول توالی (از ۱ تا ۱۲ که معادل

که به‌عنوان opt-set مشخص می‌شود (شکل ۷). در این راستا، تابع هدف در فرایند بهینه‌سازی هایپرپارامترها فقط بر روی opt-set محاسبه می‌شود.

پنج مرحله‌ای^{۲۲} استفاده می‌شود. دوره آزمایش یا ارزیابی این مطالعه شامل سال‌های ۲۰۱۳ تا ۲۰۱۹ است و به طور انحصاری برای آزمایش مدل در نظر گرفته شده است. داده‌های قبل از سال ۲۰۱۳ به سه بخش تقسیم می‌شوند: ۸۰٪ برای آموزش، ۱۰٪ برای توقف زود هنگام و ۱۰٪ برای آزمایش در حین بهینه‌سازی هایپرپارامترها

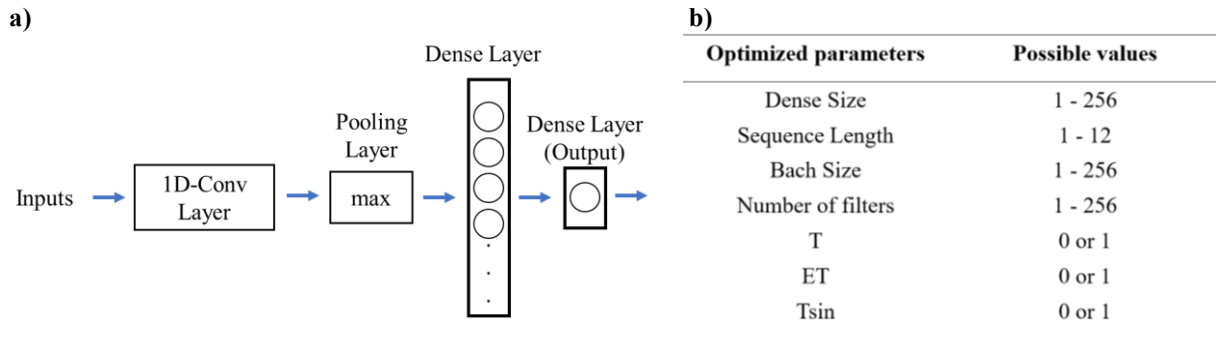


Fig. 6- Simplified schematic summary of the model and its structure (a) and hyperparameters (inputs) of the model in order to optimally adjust the model using the Bayesian optimization algorithm (b)
 شکل ۶- الف) خلاصه شماتیک ساده شده مدل و ساختار آن (ب) هایپرپارامترهای (ورودی‌های) مدل به منظور تنظیم بهینه مدل با استفاده از الگوریتم بهینه‌سازی بیزین

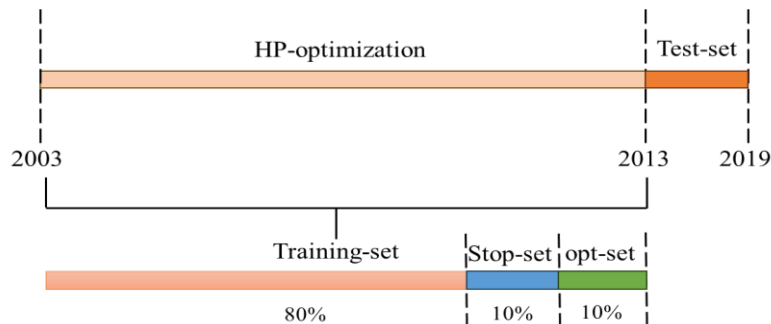


Fig. 7- Data splitting scheme
 شکل ۷- طرح تقسیم داده‌ها

می‌شوند. تابع کسب^{۲۴} برای مدل بر اساس بهبود مورد انتظار^{۲۵} تنظیم شده است. این تابع کمک می‌کند تا تصمیم‌گیری شود در کدام نقطه از فضای پارامترها آزمایش انجام شود. به بیان ساده، بهبود مورد انتظار، تخمین می‌زند که با بررسی یک مجموعه جدید از پارامترها، چقدر می‌توان عملکرد مدل را بهبود داد. تابع هدف بهینه‌سازی نیز به‌عنوان مجموع معیارهای کارایی نش- ساتکلیف^{۲۶} (NSE) و ضریب تعیین^{۲۷} (R^2) در نظر گرفته شده است (معادلات ۱ و ۲).

همه داده‌ها بین ۱- و ۱ مقیاس‌بندی می‌شوند و مدل به صورت تصادفی مقداردهی اولیه می‌شود؛ بنابراین، عملکرد مدل تا حدی به نحوه تولیدکننده اعداد تصادفی وابسته است که چطور دنباله‌ای از اعداد تصادفی و تکرارپذیر ایجاد کند. این ویژگی باعث می‌شود هر بار که کد اجرا می‌شود، همان دنباله اعداد تصادفی تولید شود و به این ترتیب، تکرارپذیری و قابلیت بازتولید نتایج مدل بهبود یابد. برای کاهش تأثیر مقداردهی اولیه تصادفی، هر مرحله از بهینه‌سازی پنج بار تکرار می‌شود و میانگین تابع هدف به دست می‌آید. در ارزیابی نهایی مدل در دوره آزمون (۲۰۱۳-۲۰۱۹)، از ۱۰ مقدار اولیه شبه تصادفی استفاده شده و خطاهای پیش‌بینی میانه^{۲۳} محاسبه

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (o_i - p_i)^2} \quad (3)$$

خطای جذر میانگین مربعات نسبی (rRMSE): این معیار شبیه به RMSE است؛ اما با تقسیم بر میانگین مقادیر مشاهده شده به صورت درصدی از خطا ارائه می‌شود. این ویژگی، امکان مقایسه بین مجموعه داده‌هایی با مقیاس‌های مختلف را فراهم می‌کند و به درک میزان نسبی خطا نسبت به مقادیر مشاهده شده کمک می‌کند.

$$rRMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{o_i - p_i}{o_{\max} - o_{\min}} \right)^2} \quad (4)$$

بایاس مطلق (Bias): بایاس مطلق میانگین انحراف پیش‌بینی‌های مدل از داده‌های مشاهده شده را اندازه‌گیری می‌کند. مقدار بایاس می‌تواند مثبت یا منفی باشد و نشان می‌دهد که مدل به طور متوسط، مقادیر را بیشتر (مثبت) یا کمتر (منفی) از واقعیت پیش‌بینی می‌کند. بایاس صفر نشان‌دهنده عدم انحراف مدل است.

$$Bias = \frac{1}{N} \sum_{i=1}^N (o_i - p_i) \quad (5)$$

بایاس نسبی (rBias): بایاس نسبی مشابه بایاس مطلق است، اما با تقسیم بر میانگین مقادیر مشاهده شده به صورت درصدی ارائه می‌شود. این معیار نشان می‌دهد که مدل به چه میزان و در چه جهتی از واقعیت منحرف شده است. بایاس نسبی صفر نشان می‌دهد که مدل هیچ انحرافی نسبت به واقعیت ندارد، درحالی‌که مقادیر مثبت یا منفی به ترتیب بیانگر بیش پیش‌بینی یا کم پیش‌بینی مدل هستند.

$$rBias = \frac{1}{N} \sum_{i=1}^N \left(\frac{o_i - p_i}{o_{\max} - o_{\min}} \right) \quad (6)$$

شاخص پایداری (PI): شاخص پایداری به ارزیابی قابلیت مدل در حفظ پایداری پیش‌بینی‌ها و ارائه الگوهای مشابه در طول زمان می‌پردازد. این معیار کمک می‌کند تا مشخص شود که آیا مدل قادر است به طور پیوسته، تغییرات دینامیکی سطح آب زیرزمینی را با دقت پیش‌بینی کند یا خیر. در این رابطه، O_{last} آخرین مقدار مشاهداتی است.

$$PI = 1 - \frac{\sum_{i=1}^N (o_i - p_i)^2}{\sum_{i=1}^N (o_i - o_{last})^2} \quad (7)$$

این دو معیار به دلیل اهمیت و کاربرد گسترده‌شان در ارزیابی دقت پیش‌بینی‌ها در زمینه‌های مرتبط با آب انتخاب شده‌اند. محاسبات مدل هم بر روی CPU و هم بر روی GPU انجام شد، اما محاسبات بر روی CPU به‌طور قابل توجهی سریع‌تر (۲ تا ۳ برابر سریع‌تر) بود و از نظر دقت هم تفاوت چندانی نداشت، بنابراین این گزینه ترجیح داده شد.

۲-۵- ارزیابی مدل

برای ارزیابی دقت پیش‌بینی، چندین معیار محاسبه می‌شود که در روابط آنها، O مقادیر مشاهده شده، P مقادیر پیش‌بینی شده و N تعداد نمونه‌ها است.

کارایی نش- ساتکلیف (NSE): این معیار به بررسی کیفیت پیش‌بینی مدل نسبت به میانگین داده‌های مشاهده شده می‌پردازد. مقدار آن می‌تواند بین منفی بی‌نهایت و ۱ باشد که ۱ نشان‌دهنده پیش‌بینی کامل مدل است. اگر مقدار NSE نزدیک به صفر باشد، پیش‌بینی مدل تنها به اندازه میانگین داده‌های مشاهده شده دقت دارد و اگر مقدار آن منفی باشد، مدل حتی بدتر از میانگین رفتار کرده است. به‌طور کلی، هر چه مقدار NSE به ۱ نزدیک‌تر باشد، دقت مدل بالاتر است.

$$NSE = 1 - \frac{\sum_{i=1}^N (o_i - p_i)^2}{\sum_{i=1}^N (o_i - \bar{o})^2} \quad (1)$$

ضریب تعیین (R^2): این معیار، میزان ارتباط و تطابق بین مقادیر پیش‌بینی شده و مقادیر مشاهده شده را اندازه‌گیری می‌کند. مقدار ضریب تعیین بین ۰ و ۱ است؛ نزدیک به ۱ بودن آن نشان‌دهنده همبستگی قوی میان داده‌ها و پیش‌بینی‌های مدل است. این معیار به‌ویژه در سنجش دقت مدل‌ها در بازتولید الگوهای زمانی و نوسانات داده‌ها کاربرد دارد.

$$R^2 = \left(\frac{\sum_{i=1}^N (o_i - \bar{o})(p_i - \bar{p})}{\sqrt{\sum_{i=1}^N (o_i - \bar{o})^2} \sqrt{\sum_{i=1}^N (p_i - \bar{p})^2}} \right)^2 \quad (2)$$


خطای جذر میانگین مربعات مطلق (RMSE)^{۲۸}: این معیار میانگین انحرافات پیش‌بینی مدل از مقادیر واقعی را به صورت مطلق و بدون توجه به جهت خطا محاسبه می‌کند. مقدار RMSE هرچه کمتر باشد، نشان می‌دهد که پیش‌بینی‌های مدل دقیق‌تر هستند. به دلیل مربع‌گیری، RMSE خطاهای بزرگ‌تر را بیشتر از خطاهای کوچک‌تر در نظر می‌گیرد که می‌تواند برای ارزیابی مدل‌هایی که حساسیت بالایی به انحرافات بزرگ دارند مفید باشد.

۳- نتایج و بحث

زیرزمینی گذشته با تأخیر یک ماهه (GWLt-1)، به‌عنوان ورودی بهبود یافت. این تغییر نه‌تنها باعث افزایش دقت پیش‌بینی‌ها شد، بلکه کاهش قابل‌توجهی در مقادیر خطاها ایجاد کرد. برای مثال، مقدار RMSE که در سناریوی اول برابر با ۰/۴۹ متر بود، در سناریوی دوم به ۰/۳۵ متر کاهش یافت. علاوه بر این، شاخص پایداری مدل (PI) نیز از ۰/۶ به ۰/۸ افزایش پیدا کرد. این افزایش نشان‌دهنده توانایی بالاتر مدل در حفظ دقت و پایداری پیش‌بینی‌ها در طول زمان است. یکی از نقاط قوت مدل CNN در این مطالعه، توانایی آن در شبیه‌سازی دقیق حداکثرها و حداقل‌های محلی سطح آب زیرزمینی است که بیانگر انطباق مناسب مدل با نوسانات شدید و تغییرات حدی است. این ویژگی، به‌ویژه در پیش‌بینی دوره‌هایی که کاهش قابل‌توجه در سطح آب زیرزمینی رخ می‌دهد، اهمیت ویژه‌ای دارد. مدل با استفاده از داده‌های ورودی، به‌ویژه داده‌های تاریخی، توانست رفتار دینامیکی سیستم آبخوان را به‌طور موثری بازتولید کند. اضافه شدن این داده‌ها به مدل موجب شد تا الگوهای غیرخطی و پیچیده تغییرات سطح آب بهتر شناسایی شوند و پیش‌بینی‌ها حتی در شرایطی که تغییرات ناگهانی یا شدید رخ می‌دهد، دقیق‌تر باشند. نتایج نشان می‌دهد که مدل توانسته است به‌خوبی حداقل‌های محلی را شبیه‌سازی کند و به دلیل کاهش خطاهای مطلق و نسبی، تطابق بیشتری با داده‌های مشاهده‌ای در این بازه‌ها داشته باشد.

در شکل ۳، می‌توان مشاهده کرد که در سال‌های ۲۰۰۴ و ۲۰۰۵ در برخی ماه‌ها بارش‌های بیش از ۲۰۰ میلی‌متر رخ داده است. با این حال، از سال ۲۰۰۵ به بعد کاهش محسوس در بارش دیده می‌شود. به‌طوری‌که، به‌جز سال ۲۰۱۶، مقدار حداکثر بارش سالانه از ۱۰۰ میلی‌متر فراتر نرفته است. این موضوع نشان‌دهنده تغییر در الگوی بارش منطقه پس از سال ۲۰۰۵ است. داده‌های دما نیز رفتار منظمی را نشان می‌دهند و در یک چرخه فصلی بین صفر تا ۳۰ درجه سانتی‌گراد در نوسان هستند. تبخیر تعرق در این محدوده مطالعاتی، نوساناتی وابسته به دما و بارش را نشان می‌دهد. در ماه‌های گرم سال، به دلیل افزایش دما و تابش خورشید، تبخیر تعرق به حداکثر می‌رسد. همچنین، در دوره‌های پربارش، مقادیر تبخیر تعرق نیز افزایش یافته که این امر ناشی از تأمین رطوبت کافی برای فرآیند تبخیر و جذب آب توسط گیاهان است. همبستگی قوی میان دما و تبخیر تعرق در این سری زمانی به وضوح قابل مشاهده است. با این وجود، علی‌رغم کاهش بارش‌ها از سال ۲۰۰۶، کاهش چشمگیری در داده‌های تبخیر تعرق مشاهده نمی‌شود. این امر احتمالاً ناشی از افزایش برداشت آب زیرزمینی برای آبیاری و گسترش سطح زیر کشت در منطقه مطالعاتی است. به بیان دیگر، کاهش بارش با افزایش بهره‌برداری از منابع آب زیرزمینی جبران شده است، که این موضوع خود می‌تواند در بلندمدت تأثیرات مخربی بر ذخایر آب زیرزمینی منطقه داشته باشد. با توجه به شکل ۴، می‌توان دریافت که سطح آب زیرزمینی در دوره زمانی ۲۰۰۳ تا ۲۰۱۹ روندی کاهشی همراه با نوسانات فصلی داشته است. این روند کاهشی به‌طور عمده ناشی از افزایش برداشت آب زیرزمینی برای مصارف مختلف، به‌ویژه کشاورزی، بوده و نوسانات فصلی آن به دلیل افزایش تغذیه آب زیرزمینی در ماه‌های پربارش سال رخ داده است. عملکرد مدل CNN در این مطالعه نشان‌دهنده توانایی بالای آن در شبیه‌سازی و پیش‌بینی روند زمانی سطح آب زیرزمینی است. این عملکرد با استفاده از دو سناریو متفاوت مورد ارزیابی قرار گرفت. در سناریوی اول، مدل تنها با استفاده از داده‌های ورودی اصلی شامل پارامترهای هواشناسی مانند بارش، دما و تبخیر تعرق، مورد آزمایش قرار گرفت. نتایج این سناریو نشان داد که مدل توانسته است به‌خوبی الگوهای زمانی را شبیه‌سازی کند و مقادیر نش - ساتکلیف (NSE) و ضریب تعیین (R^2) به ترتیب ۰/۹۹ و ۰/۹۸ برآورد شد (شکل ۸) که این امر بیانگر تطابق بالای پیش‌بینی‌های مدل با مقادیر مشاهده شده است. در سناریوی دوم، مدل با اضافه کردن داده‌های سطح آب

a)



b)

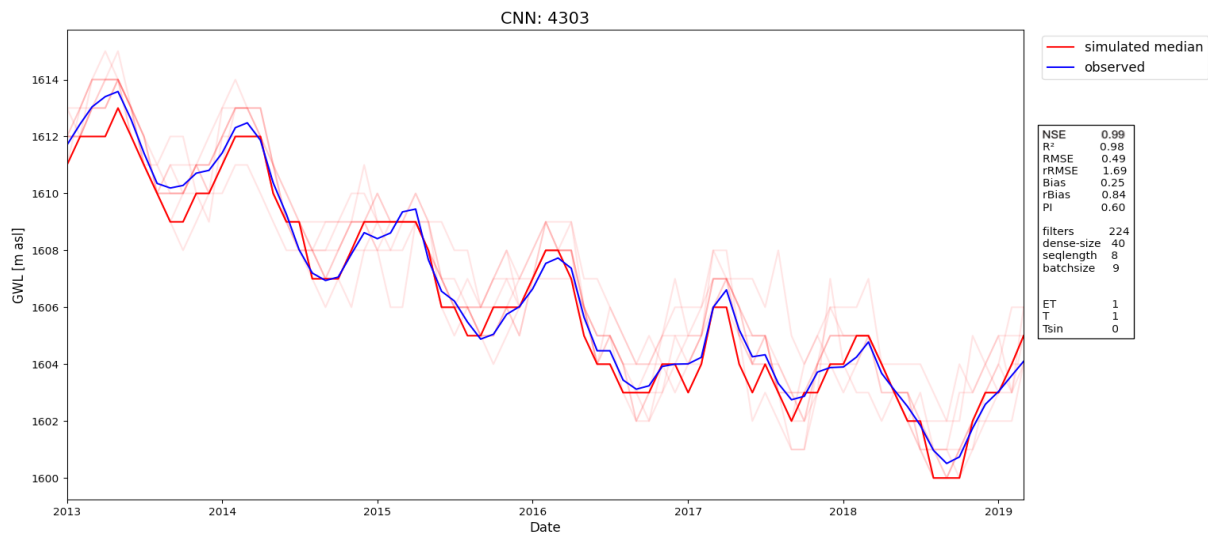


Fig. 8- CNN model Forecasts (a) without past groundwater level (b) with past groundwater level
شکل ۸- پیش‌بینی‌های مدل CNN (الف) بدون سطح آب زیرزمینی گذشته (ب) همراه با سطح آب زیرزمینی گذشته

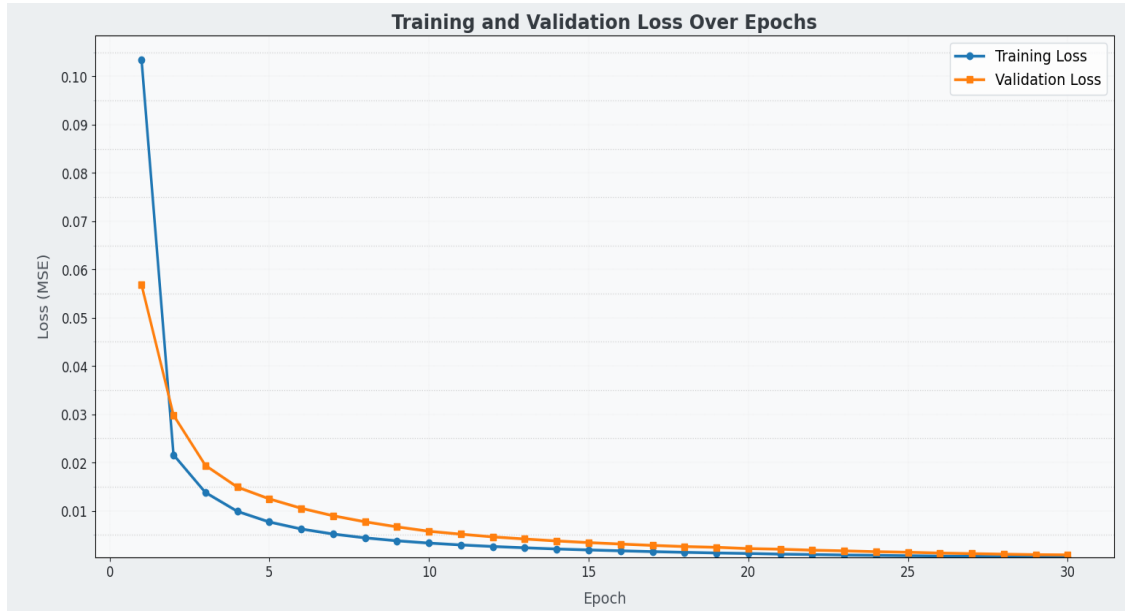
که مدل توانسته است الگوهای زمانی و ساختارهای پیچیده موجود در داده‌ها را با گذشت زمان بهتر شبیه‌سازی کند. شکل ۹ (ب) نیز تغییرات خطای آموزش و اعتبارسنجی مدل را با افزودن داده‌های سطح آب زیرزمینی گذشته نمایش می‌دهد. در این حالت، خطاها به‌طور قابل‌توجهی کاهش یافته‌اند و روند کاهشی آن‌ها بیانگر بهره‌وری بیشتر مدل از داده‌های تاریخی است. کاهش خطاها در مراحل پایانی آموزش نشان می‌دهد که داده‌های تاریخی نقشی کلیدی در بهبود دقت پیش‌بینی‌ها و تعمیم‌پذیری مدل ایفا می‌کنند.

شکل ۹ (الف) نشان‌دهنده تغییرات خطای آموزش و اعتبارسنجی (MSE²⁹) مدل در غیاب داده‌های تاریخی سطح آب زیرزمینی است. در این نمودار، کاهش تدریجی خطاها با افزایش تعداد تکرارها مشاهده می‌شود که بیانگر بهبود مستمر توانایی مدل در شناسایی الگوهای موجود در داده‌ها است. در مراحل اولیه آموزش، خطای اعتبارسنجی از خطای آموزش بالاتر است، که این مسئله به تدریج کاهش می‌یابد و نشان‌دهنده بهبود مدل در یادگیری و همگام شدن پیش‌بینی‌ها با داده‌های واقعی است. این روند به‌وضوح نشان می‌دهد

است. انتخاب تعداد تکرار بیشتر از ۳۰ می‌توانست هزینه محاسباتی و زمان اجرای مدل را به میزان قابل توجهی افزایش دهد، در حالی که انتظار نمی‌رود تفاوت معناداری در دقت مدل مشاهده شود.

مقایسه این دو نمودار نشان می‌دهد که اضافه کردن داده‌های تاریخی به مدل نه تنها موجب افزایش دقت پیش‌بینی‌ها شده، بلکه در کاهش خطاها و بهبود عملکرد کلی مدل نیز تأثیرگذار بوده است، علاوه بر این، تعداد تکرارها نیز در هر دو شکل به درستی تعیین شده

a)



b)



Fig. 9- Training and Validation Loss Over Epochs (a) without past groundwater level (b) with past groundwater level

شکل ۹- خطای آموزش و اعتبارسنجی بر اساس تکرار (الف) بدون سطح آب زیرزمینی گذشته (ب) همراه با سطح آب زیرزمینی گذشته

بر اساس شکل ۱۰، پایین‌ترین دقت مدل در فصل بهار مشاهده شده است که به دلیل وجود حداکثرهای محلی و تغییرات ناگهانی اقلیمی در این دوره است. در مقابل، فصل پاییز بهترین عملکرد را نشان داده است، زیرا در این فصل تغییرات تراز آب زیرزمینی حداقل بوده و شرایط پایدارتری بر منطقه حاکم است. این یافته‌ها بر اهمیت تطابق مدل با الگوهای فصلی تأکید دارند و نشان می‌دهند که استفاده از داده‌های دقیق‌تر می‌تواند در فصل‌های با نوسانات زیاد، کارایی مدل را بهبود بخشد.

برای ارزیابی دقیق‌تر عملکرد مدل در بازه زمانی تست مدل (۲۰۱۹-۲۰۲۳)، معیارهای مختلفی مانند R^2 ، Bias، RMSE، و NSE برای هر فصل و ماه سال محاسبه شده‌اند. این تحلیل‌ها به منظور مقایسه عملکرد دو سناریوی مختلف انجام گرفته است. نتایج نشان می‌دهند که سناریوی استفاده از داده‌های سطح آب زیرزمینی گذشته، در تمامی معیارها به جز Bias عملکرد بهتری داشته است. اضافه کردن داده‌های تاریخی به مدل باعث بهبود دقت پیش‌بینی و کاهش خطاها شده و توانایی مدل در بازتولید تغییرات زمانی سطح آب زیرزمینی را افزایش داده است.

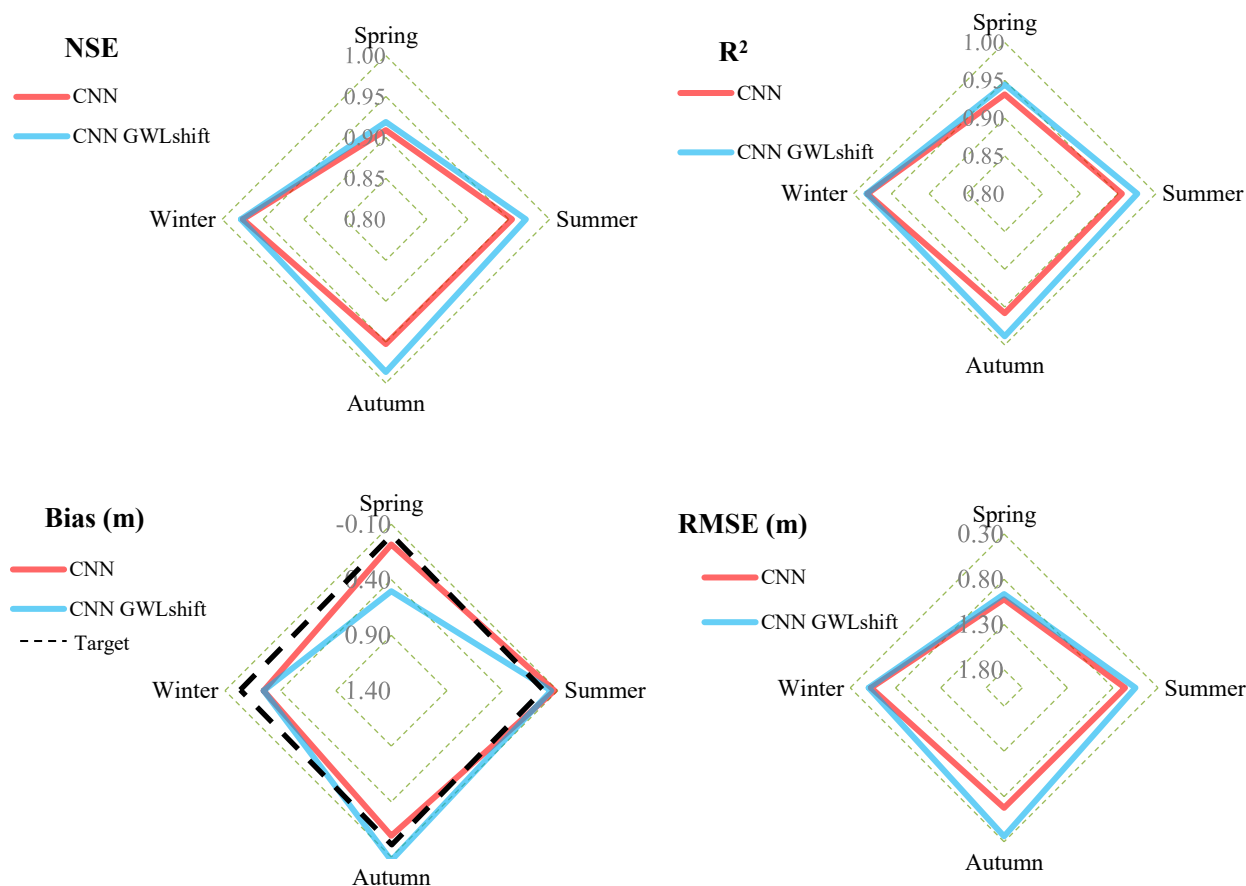


Fig. 10- Model accuracy and seasonal error criteria for the 6-year test period

شکل ۱۰- معیارهای دقت و خطای فصلی مدل برای دوره ۶ ساله تست

اقلیمی و تغذیه مناسب آبخوان در این ماه‌ها است. از سوی دیگر، ماه مارس بیشترین خطا را نشان داده است، که این امر ناشی از نوسانات زیاد اقلیمی و تغییرات ناگهانی بارش است. همچنین،

در تحلیل ماهانه که در شکل ۱۱ ارائه شده است، معیارهای NSE و R^2 نشان می‌دهند که مدل در ماه‌های ژانویه، نوامبر و دسامبر بهترین عملکرد را داشته است. این موضوع به دلیل پایداری شرایط

کاهش بایاس به تنهایی نشان‌دهنده بهبود عملکرد کلی مدل نیست و باید در کنار سایر معیارها مانند RMSE، NSE و R^2 مورد ارزیابی قرار گیرد تا دیدگاه جامع‌تری از دقت و قابلیت اعتماد مدل به دست آید.

مقادیر RMSE در ماه‌های تابستانی مانند جولای و آگوست به دلیل کاهش بارش و افزایش تبخیر و تعرق افزایش یافته است. در مقابل، معیار بایاس در سناریوی بدون داده‌های سطح آب زیرزمینی گذشته عملکرد بهتری نشان داده است. این موضوع می‌تواند به دلیل افزایش داده‌های ورودی به مدل باشد. به طور کلی،

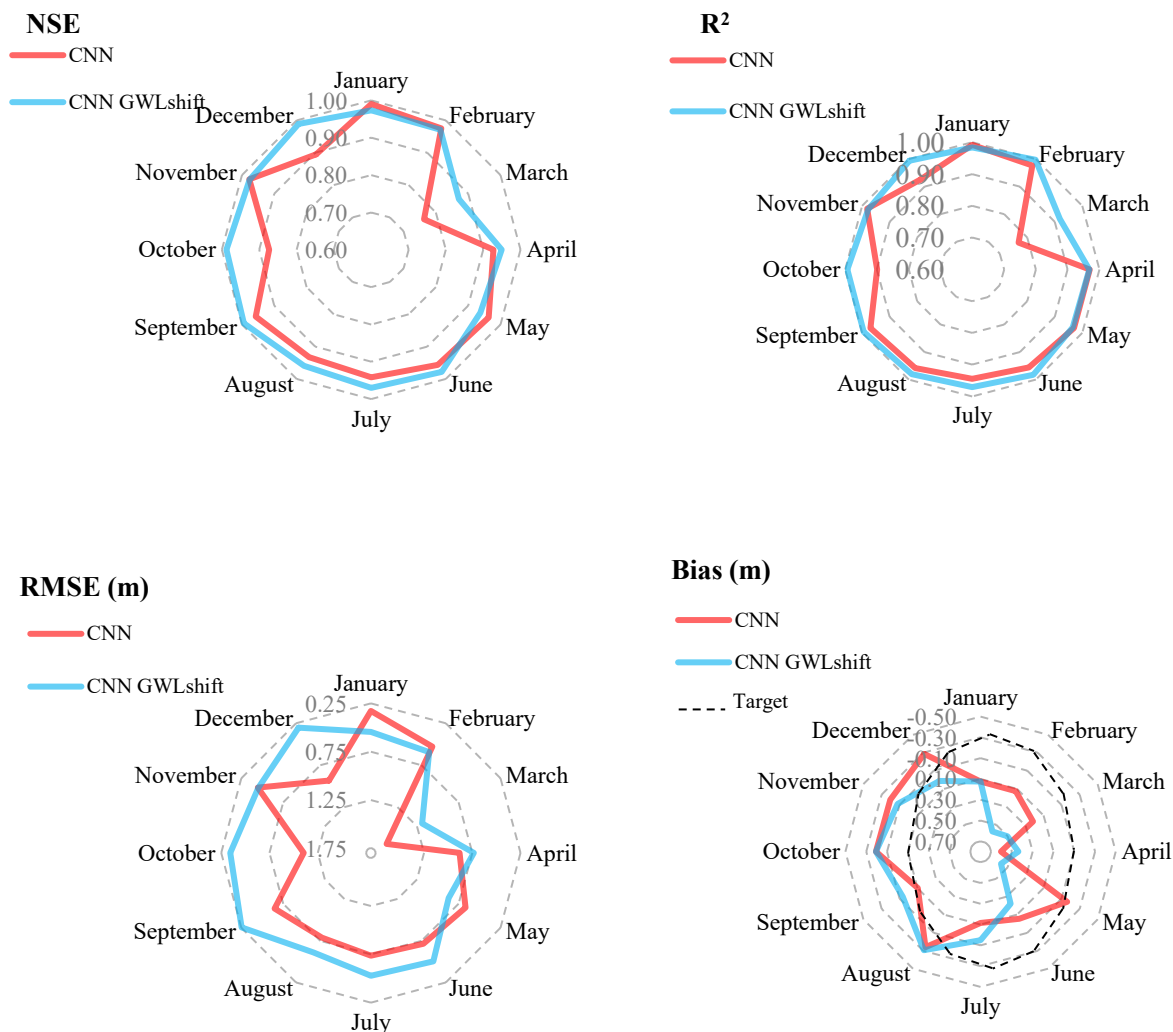


Fig. 11- Model accuracy and monthly error criteria for the 6-year test period
 شکل ۱۱- معیارهای دقت و خطای ماهانه مدل برای دوره ۶ ساله تست

اضافه کردن سطح آب زیرزمینی گذشته به مدل، اطلاعات مفیدی درباره رفتار گذشته سیستم آبخوان فراهم کرد و به مدل کمک کرد تا با تغییرات پیچیده‌تر و الگوهای غیرخطی بهتر تطابق پیدا کند. این ویژگی، به‌ویژه در مناطقی که تغییرات زمانی سطح آب زیرزمینی شدید است، اهمیت دارد. در واقع، داده‌های تاریخی نقش یک مرجع اساسی برای مدل ایفا می‌کنند و به آن اجازه می‌دهند تا با الگوهای گذشته هماهنگ شده و درک بهتری از نوسانات زمانی پیدا کند. این یافته‌ها نشان می‌دهد که استفاده از داده‌های گذشته در مدل‌های پیش‌بینی می‌تواند راهکاری عملی و مؤثر برای بهبود دقت پیش‌بینی‌ها باشد. از منظر کاربردی، نتایج این پژوهش نشان می‌دهد که مدل CNN به دلیل دقت بالا و پایداری مناسب، می‌تواند به‌عنوان ابزاری مؤثر در مدیریت منابع آب زیرزمینی به کار رود. پیش‌بینی‌های دقیق و پایدار سطح آب زیرزمینی می‌تواند اطلاعات ارزشمندی برای تصمیم‌گیران و برنامه‌ریزان فراهم کند. از منظر کاربردی، نتایج این پژوهش نشان می‌دهد که مدل CNN به دلیل دقت بالا و پایداری مناسب، می‌تواند به‌عنوان ابزاری مؤثر در مدیریت منابع آب زیرزمینی به کار رود. پیش‌بینی‌های دقیق و پایدار سطح آب زیرزمینی می‌تواند اطلاعات ارزشمندی برای تصمیم‌گیران و برنامه‌ریزان فراهم کند. به‌عنوان نمونه، این پیش‌بینی‌ها می‌توانند در تعیین سیاست‌های بهره‌برداری پایدار از منابع آب، برنامه‌ریزی برای مقابله با خشکسالی و کاهش اثرات منفی برداشت بی‌رویه آب زیرزمینی نقش داشته باشند.

تغییرات مکانی و زمانی سطح آب زیرزمینی را فراهم می‌کنند و به شناسایی مناطق بحرانی آبخوان کمک می‌نمایند. نتایج این مطالعه نشان‌دهنده اهمیت استفاده از داده‌های تاریخی در مدل‌های پیش‌بینی است، زیرا این داده‌ها به مدل کمک می‌کنند تا الگوهای پیچیده و غیرخطی تغییرات سطح آب را بهتر شبیه‌سازی کند و پیش‌بینی‌های دقیق‌تری ارائه دهد. از جنبه کاربردی، پیش‌بینی‌های دقیق و پایدار سطح آب زیرزمینی می‌تواند نقش کلیدی در سیاست‌گذاری‌های بهره‌برداری پایدار از منابع آب، مقابله با خشکسالی‌ها و مدیریت بهینه منابع آبی ایفا کند. به‌طور کلی، مدل CNN در این پژوهش به‌عنوان یک ابزار مؤثر در مدیریت منابع آب زیرزمینی شناخته شده و نتایج آن می‌تواند به‌عنوان مبنای تصمیم‌گیری‌های آینده بخصوص در محدوده‌های با کمبود یا فقدان داده در این زمینه مورد استفاده قرار گیرد. برای تحقیقات آینده، پیشنهاد می‌شود مدل‌سازی‌های ترکیبی با بهره‌گیری از سایر تکنیک‌های هوش مصنوعی انجام گیرد تا دقت پیش‌بینی‌ها و پایداری مدل بهبود یابد همچنین، با پیاده‌سازی در مناطق مختلف با روندهای متفاوت سطح آب زیرزمینی می‌تواند قابلیت تعمیم مدل را ارزیابی کند. همچنین، تحلیل تأثیرات تغییرات اقلیمی و فشارهای انسانی بر ذخایر آب زیرزمینی می‌تواند به شناسایی راهبردهای مدیریتی مؤثرتر کمک کند. این تلاش‌ها می‌توانند پایه‌ای علمی و داده‌محور برای مدیریت پایدار منابع آب زیرزمینی در شرایط اقلیمی متغیر فراهم کنند.

۴- نتیجه‌گیری

نتیجه‌گیری این پژوهش نشان می‌دهد که مدل CNN به‌عنوان یک ابزار قدرتمند و دقیق در پیش‌بینی سطح آب زیرزمینی، توانسته است به‌خوبی روند زمانی سطح آب و نوسانات فصلی آن را شبیه‌سازی کند. استفاده از داده‌های گذشته سطح آب زیرزمینی به‌عنوان ورودی به مدل، دقت پیش‌بینی‌ها را افزایش داده و توانایی مدل در شبیه‌سازی حداکثرها و حداقل‌های محلی سطح آب زیرزمینی را تقویت کرده است. این ویژگی‌ها، به‌ویژه در شرایطی که تغییرات ناگهانی و شدید در سطح آب زیرزمینی رخ می‌دهد، کاربردهای مدیریتی مدل را برجسته می‌کند. پیش‌بینی سطح آب زیرزمینی با استفاده از هیدروگراف معرف به‌ویژه در مدیریت پایدار منابع آبی، با نقاط قوت و ضعفی همراه است. هیدروگراف معرف به‌عنوان یک ابزار تحلیلی، قابلیت ساده‌سازی رفتار کلی آبخوان و ارائه تصویری کلان از نوسانات سطح آب را دارد و برای شناسایی الگوهای طولانی‌مدت مفید است. با این حال، ممکن است اطلاعات جزئی مربوط به تغییرات مکانی و اثرات محلی را به‌درستی منعکس نکند. در مقابل، داده‌های چاه‌های مشاهداتی امکان پایش دقیق

پی‌نوشت‌ها

- 1- Groundwater Level
- 2- Artificial Intelligence
- 3- Multilayer Perceptron
- 4- Artificial Neural Networks
- 5- Convolutional Neural Networks
- 6- Long Short-Term Memory
- 7- Google Earth Engine
- 8- Global Precipitation Measurement
- 9- Tropical Rainfall Measuring Mission
- 10- Dual-frequency Precipitation Radar
- 11- GPM Microwave Imager
- 12- Integrated Multi-satellite Retrievals for GPM
- 13- Receptive Field
- 14- Sequence to Value
- 15- Max Pooling
- 16- Gradient Exploding
- 17- Gradient Clipping
- 18- Hyperparameters
- 19- Epochs
- 20- Overfitting
- 21- Early Stopping
- 22- Patience
- 23- Median
- 24- Acquisition Function
- 25- Expected Improvement
- 26- Nash-Sutcliffe
- 27- Coefficient of Determination
- 28- Root-Mean-Square Deviation
- 29- Mean Squared Error

۵- منابع

- Adnan RM, Liang Z, Heddami S, Zounemat-Kermani M, Kisi O and Li B (2020) Least square support vector machine and multivariate adaptive regression splines for streamflow prediction in mountainous basin using hydro-meteorological data as inputs. *Journal of Hydrology* 586:124371
- Bagheri Y, Abas novin pour E, Nadiri AA and Naderi K (2018) Forecasting of groundwater level fluctuations in Baruq aquifer using the SOM-AI model. *Scientific Quarterly Journal* 28(112):157-166 (In Persian)
- Bai T and Tahmasebi P (2023) Graph neural network for groundwater level forecasting. *Journal of Hydrology* 616:128792
- Bhagat SK, Tung TM, and Yaseen ZM (2020) Development of artificial intelligence for modeling wastewater heavy metal removal: State of the art, application assessment and possible future research. *Journal of Cleaner Production* 250:119473
- Cheng M, Jiao X, Jin X, Li B, Liu K, and Shi L (2021) Satellite time series data reveal interannual and seasonal spatiotemporal evapotranspiration patterns in China in response to effect factors. *Agricultural Water Management* 255:107046
- Goodfellow I, Bengio Y, and Courville A (2017) *Deep Learning*. MIT Press 521(7553):785
- Hou AY, Kakar RK, Neeck S, Azarbarzin AA, Kummerow CD, Kojima M, Oki R, Nakamura K, and Iguchi T (2014) The global precipitation measurement mission. *Bulletin of the American Meteorological Society* 95(5):701-722
- Hu G, Jia L and Menenti M (2015) Comparison of MOD16 and LSA-SAF MSG evapotranspiration products over Europe for 2011. *Remote Sensing of Environment* 156:510-526
- Ketabchi, H, Mahmoodzadeh D, Valipour E, and Saadi T (2024) Uncertainty-based analysis of water balance components: A semi-arid groundwater-dependent and data-scarce area, Iran. *Environment, Development and Sustainability* 26:31511-31537
- Khan J, Lee E, Balobaid AS, and Kim K (2023) A comprehensive review of conventional, machine learning, and deep learning models for Groundwater Level (GWL) Forecasting. *Applied Sciences (Switzerland)* 13(4):2743
- Khatibi R and Nadiri AA (2021) Inclusive Multiple Models (IMM) for predicting groundwater levels and treating heterogeneity. *Geoscience Frontiers* 12(2):713-724
- Kong-A-Siou L, Fleury P, Johannet A, Borrell Estupina V, Pistre S, and Dörfli N (2014) Performance and complementarity of two systemic models (reservoir and neural networks) used to simulate spring discharge and piezometry for a karst aquifer. *Journal of Hydrology* 519(PD):3178-3192
- LeCun Y, Bengio Y, and Hinton G (2015) Deep learning. *Nature* 521(7553):436-444
- Mahdavi-Meymand A and Zounemat-Kermani M (2020) A new integrated model of the group method of data handling and the firefly algorithm (GMDH-FA): Application to aeration modelling on spillways. *Artificial Intelligence Review* 53(4):2549-2569
- Masoumi Z, Rezaei A, and Maleki J (2019) Improvement of water table interpolation and groundwater storage volume using fuzzy computations. *Environmental Monitoring and Assessment* 191(6):1-15
- Nadiri AA, Vahedi F, Asghari Moghaddam A, and Kadkhodaie A (2016) Supervised intelligent committee machine method for groundwater level prediction. *Journal of Civil and Environmental Engineering, Faculty of Natural Science, University of Tabriz* 46(3):101-112 (In Persian)
- Norozi H and Nadiri AA (2018) Predicting groundwater levels in the Bukan Plain using fuzzy logic, random forest and neural network models. *Journal of Iranian Natural Resources* 71(3):846-829 (In Persian)
- Peifeng Li JZ and Krebs P (2022) Prediction of flow based on a CNN-LSTM combined deep. *Water* 14(6):993
- Rajaei T, Ebrahimi H, and Nourani V (2019) A review of the artificial intelligence methods in groundwater level modeling. *Journal of Hydrology* 572:336-351
- Rogers LL and Dowla FU (1994) Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling has been successfully applied to a variety of optimization. *Water Resources Research* 30(2):457-481
- Ruhoff A, de Andrade BC, Laipelt L, Fleischmann AS, Siqueira VA, et al. (2022) Global evapotranspiration datasets assessment using water balance in South America. *Remote Sensing* 14(11):2526

- Sadeghi-Jahani H, Ketabchi H, and Shafizadeh-Moghadam H (2024) Spatiotemporal assessment of sustainable groundwater management using process-based and remote sensing indices: A novel approach. *Science of the Total Environment* 918:170828
- Sengupta S, Basak S, Saikia P, Paul S, Tsalavoutis V, Atiah F, Ravi V, and Peters A (2020) A review of deep learning with special emphasis on architectures, applications and recent trends. *Knowledge-Based Systems* 194:105596
- Sit M, Demiray BZ, Xiang Z, Ewing GJ, Sermet Y, and Demir I (2020) A comprehensive review of deep learning applications in hydrology and water resources. *Water Science and Technology* 82(12):2635–2670
- Tan ML and Duan Z (2017) Assessment of GPM and TRMM precipitation products over Singapore. *Remote Sensing* 9(7):1–16
- Tao H, Hameed MM, Marhoon HA, Zounemat-Kermani M, Heddami S, et al. (2022) Groundwater level prediction using machine learning models: A comprehensive review. *Neurocomputing* 489:271–308
- Trambauer P, Dutra E, Maskey S, Werner M, Pappenberger F, Van Beek LPH, and Uhlenbrook S (2014) Comparison of different evaporation estimates over the African continent. *Hydrology and Earth System Sciences* 18(1):193–212
- Van Rossum G (1995) No Title. Available at: <https://www.python.org/>
- Wambura FJ, Dietrich O, and Lischeid G (2017) Evaluation of spatio-temporal patterns of remotely sensed evapotranspiration to infer information about hydrological behaviour in a data-scarce region. *Water (Switzerland)* 9(5):333
- Wang Z, Zhong R, Lai C, and Chen J (2017) Evaluation of the GPM IMERG satellite-based precipitation products and the hydrological utility. *Atmospheric Research* 196(May):151–163
- Wunsch A, Liesch T, and Broda S (2021) Groundwater level forecasting with artificial neural networks: A comparison of long short-term memory (LSTM), convolutional neural networks (CNNs), and non-linear autoregressive networks with exogenous input (NARX). *Hydrology and Earth System Sciences* 25(3):1671–1687
- Yaseen ZM, Sulaiman SO, Deo RC, and Chau KW (2019) An enhanced extreme learning machine model for river flow forecasting: State-of-the-art, practical applications in water resource engineering area and future research direction. *Journal of Hydrology* 569:387–408