



Groundwater level forecasting of data-scare areas using a deep learning long-short term memory (LSTM) model (Case study: Saadatabad study area, Fars province)

Mohammad Javad Aghaei¹ | Hamed Ketabchi²

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

Article Info

Article type:

Research Article

Article history:

Received 6 February 2025

Received in revised form

19 April 2025

Accepted 17 May 2025

Published online 11 October 2025

Keywords:

Bayesian optimization

Activation function

Simulation

Water resource management

ABSTRACT

Groundwater level forecasting is a crucial approach in water resource management and planning. This forecasting can assist in improving water resource management, especially in regions facing water crises. In recent years, the use of artificial intelligence for forecasting groundwater levels has gained significant attention. These models can simulate complex and nonlinear relationships between data and are widely used in areas where accurate and comprehensive hydrological data is not available. In this study, the Long Short-Term Memory (LSTM) model was used to forecast groundwater levels in the Saadat Abad area of the Tashk-Bakhtegan Basin in Fars Province. The main objective of this study was to evaluate the performance of the LSTM model compared to traditional models and to analyze the impact of different activation functions on the accuracy of groundwater level forecasting. Bayesian optimization was employed to optimize the model's hyperparameters, which significantly improved the forecasting accuracy and the simulation of long-term dependencies between input data. The results of this study showed that the LSTM model is capable of forecasting groundwater level fluctuations and long-term trends with high accuracy. Additionally, a comparison of different activation functions revealed that the ReLU activation function with NSE value of 0.99, an R^2 value of 0.97, and an RMSE of 0.67 m, simulated the changes in groundwater levels. Furthermore, it was observed that using GPU significantly reduced processing time. Specifically, the execution time with CPU was 31 minutes, while with GPU it was only 9 minutes. This model demonstrated a high ability to simulate complex temporal patterns and accurately forecast groundwater levels, making it an efficient tool for groundwater resource management in regions with limited data.

Cite this article: Aghaei, M. J., & Ketabchi, H. (2025). Groundwater level forecasting of data-scare areas using a deep learning long-short term memory (LSTM) model (Case study: Saadatabad study area, Fars province). *Journal of Water and Irrigation Management*, 15 (2), 279-299. DOI: <https://doi.org/10.22059/jwim.2025.389999.1208>



© The Author(s).

DOI: <https://doi.org/10.22059/jwim.2025.389999.1208>

Publisher: University of Tehran Press.



پیش‌بینی سطح آب زیرزمینی مناطق با کمبود داده با استفاده از مدل LSTM (مطالعه موردی: محدوده مطالعاتی سعادت آباد، استان فارس)

محمدجواد آقایی^۱ | حامد کتابچی^۲^۱. گروه مهندسی و مدیریت آب، دانشگاه تربیت مدرس، تهران، ایران. رایانامه: aghaei_m@modares.ac.ir^۲. نویسنده مسئول، گروه مهندسی و مدیریت آب، دانشگاه تربیت مدرس، تهران، ایران. رایانامه: h.ketabchi@modares.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۳/۱۱/۱۸ تاریخ بازنگری: ۱۴۰۴/۰۱/۳۰ تاریخ پذیرش: ۱۴۰۴/۰۲/۲۷ تاریخ انتشار: ۱۴۰۴/۰۷/۱۹	پیش‌بینی سطح آب زیرزمینی برای استفاده پایدار از منابع آب، اهمیت زیادی دارد. این پیش‌بینی می‌تواند در مناطقی که با بحران‌های آبی مواجه هستند، به بهبود مدیریت منابع آب کمک کند. در سال‌های اخیر، استفاده از هوش مصنوعی برای پیش‌بینی سطح آب زیرزمینی توجه بسیاری را به خود جلب کرده است. این مدل‌ها می‌توانند وابستگی‌های پیچیده و غیرخطی میان داده‌ها را شبیه‌سازی کنند و در مناطقی که داده‌های هیدرولوژیکی دقیق و جامع در دسترس نیست، کاربرد فراوانی دارند. در این مطالعه، از مدل Long Short-Term Memory (LSTM) برای پیش‌بینی سطح آب زیرزمینی در محدوده مطالعاتی سعادت‌آباد در حوضه آبریز طشک-بخندگان استان فارس استفاده شد. هدف اصلی این مطالعه، ارزیابی عملکرد مدل LSTM در مقایسه با مدل‌های سنتی و تحلیل تأثیر توابع فعال‌ساز مختلف بر دقت پیش‌بینی سطح آب زیرزمینی بود. برای بهینه‌سازی هاپرپارامترهای مدل از بهینه‌ساز بیزین (Bayesian optimization) بهره گرفته شد که باعث بهبود دقت پیش‌بینی و شبیه‌سازی وابستگی‌های بلندمدت میان داده‌های ورودی گردید. نتایج نشان داد که مدل LSTM قادر است نوسانات و روندهای بلندمدت سطح آب زیرزمینی را با دقت پیش‌بینی کند. همچنین، مقایسه عملکرد توابع فعال‌ساز مختلف نشان داد که تابع فعال‌ساز ReLU توانست با مقدار NSE برابر با ۰/۹۹، R^2 برابر با ۰/۹۷ و RMSE برابر با ۰/۶۷ متر، روند تغییرات سطح آب زیرزمینی را شبیه‌سازی کند. همچنین، مشاهده شد که استفاده از GPU به‌طور قابل توجهی زمان پردازش را کاهش داد. به‌طور خاص، زمان اجرا برای مدل با CPU برابر با ۳۱ دقیقه و با GPU برابر با ۹ دقیقه بود. این مدل توانایی بالایی در شبیه‌سازی الگوهای زمانی پیچیده و پیش‌بینی دقیق سطح آب زیرزمینی دارد و می‌تواند به‌عنوان ابزاری کارآمد برای مدیریت منابع آب زیرزمینی در مناطق مختلف با کمبود داده، استفاده شود.

کلیدواژه‌ها:

بهینه‌ساز بیزین
تابع فعال‌ساز
شبیه‌سازی
مدیریت منابع آب

استناد: آقایی، محمدجواد و کتابچی، حامد (۱۴۰۴). پیش‌بینی سطح آب زیرزمینی مناطق با کمبود داده با استفاده از مدل LSTM (مطالعه موردی: محدوده مطالعاتی

سعادت‌آباد، استان فارس). نشریه مدیریت آب و آبیاری، ۱۵ (۲)، ۲۷۹-۲۹۹. DOI: <https://doi.org/10.22059/jwim.2025.389999.1208>



۱. مقدمه

ارزیابی سطح آب زیرزمینی برای حفظ منابع آب زیرزمینی اهمیت زیادی دارد، زیرا یک‌سوم از نیازهای آبی جهان از این منابع تأمین می‌شود (Omar et al., 2019). این منابع در برخی مناطق جهان برای تأمین آب شرب و نیازهای آبیاری و صنعتی مورد استفاده قرار می‌گیرند. استخراج بی‌رویه و بدون برنامه‌ریزی از این منابع می‌تواند منجر به کاهش شدید سطح آب زیرزمینی و بروز مشکلات جدی در سطح جهانی، به‌ویژه در کشورهای کم‌آب شود. برای رفع این مشکل، پژوهش‌گران برای شبیه‌سازی سطح آب زیرزمینی، مدل‌ها و روش‌های متنوعی را توسعه داده‌اند که از رویکردهای مفهومی و عددی گرفته تا مدل‌های هوش مصنوعی (AI)^۱ را شامل می‌شود. در میان تکنیک‌های عددی، MODFLOW تا دهه گذشته یکی از پرکاربردترین ابزارها برای شبیه‌سازی سطح آب زیرزمینی بود. با این حال، دقت پیش‌بینی این روش‌ها به‌شدت به دسترسی به داده‌های جامع هیدروژئولوژیکی و مشخصات فیزیکی آبخوان‌ها وابسته است (Zeydalinejad, 2022).

برای غلبه بر محدودیت‌های روش‌های عددی، در دهه اخیر استفاده از مدل‌های هوش مصنوعی به شکل گسترده‌ای مورد توجه قرار گرفته است (Loh et al., 2022). این مدل‌ها برخلاف روش‌های عددی، نیازی به اطلاعات فیزیکی دقیق آبخوان‌ها برای شبیه‌سازی ندارند و همین امر، آن‌ها را به گزینه‌ای جذاب و کارآمد برای شبیه‌سازی سطح آب زیرزمینی تبدیل کرده است. مدل‌های هوش مصنوعی شامل انواع مختلفی از شبکه‌های عصبی هستند، از جمله ساده‌ترین آن‌ها، شبکه‌های عصبی مصنوعی (ANN)^۲ که به پرسپترون‌های چندلایه (MLP)^۳ معروفند و دارای دو یا بیش‌تر لایه مخفی هستند. همچنین شبکه‌های عصبی با یک لایه مخفی، که به نام شبکه‌های عصبی پیش‌خور (FFNN)^۴ شناخته می‌شوند، در مراحل اولیه تحقیقات مبتنی بر هوش مصنوعی در مطالعات هیدروژئولوژیکی بیش‌تر مورد استفاده قرار می‌گرفتند (Lallahem et al., 2005). از آنجایی که داده‌های سری زمانی سطح آب زیرزمینی معمولاً غیرخطی و غیرایستا هستند، توانایی مدل‌های ANN محدود به مجموعه خاصی از متغیرها می‌شود. برای حل این مشکل، سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)^۵ به‌عنوان یک رویکرد جدید برای تحلیل سیستم‌های پیچیده با استفاده از الگوریتم پس‌انتشار و منطق فازی توسعه یافت (Sreekanth et al., 2011). با وجود عملکرد چشمگیر مدل‌های ANN و ANFIS در پیش‌بینی دقیق سطح آب زیرزمینی (GWL)، این روش‌ها با محدودیت‌هایی مانند مشکل از بین رفتن و انفجار گرادیان مواجهند که باعث کاهش کارایی آن‌ها در پیش‌بینی سری‌های زمانی بلندمدت می‌شود. برای حل این چالش‌ها، شبکه عصبی بازگشتی (RNN)^۶ معرفی شد تا وابستگی‌های بلندمدت را در داده‌های سری زمانی مدیریت کند. با این حال، RNN معمولی نیز محدودیت‌هایی دارد، از جمله عدم توانایی در حفظ اطلاعات زمانی برای توالی‌های طولانی و نیاز به منابع محاسباتی بالا. برای غلبه بر این مشکلات، مدل حافظه بلندمدت-کوتاهمدت (LSTM) توسعه داده شد که قادر است اطلاعات را برای دوره‌های طولانی حفظ کند. این مدل به‌طور عمده برای داده‌های پیوسته، به‌ویژه داده‌های سری زمانی، طراحی شده است و در سال‌های اخیر در مطالعات مختلف مرتبط با سطح آب زیرزمینی مورد استفاده قرار گرفته است (Ren et al., 2022; Zhang et al., 2018).

در پژوهشی توسط Parck and Jong (2020) و Shin et al. (2020) قابلیت اطمینان مدل LSTM را در شبیه‌سازی سطح آب زیرزمینی در جنوب شرقی کره گزارش کردند. Shin et al. (2020) دریافتند که مدت زمان دوره آموزشی تأثیر قابل‌توجهی بر عملکرد مدل ندارد؛ برای مثال، اختلاف شاخص NSE بین دوره‌های آموزشی شش و ۱۹ ساله تنها ۰/۰۲ بود (Jeong et al., 2020; Shin et al., 2020). همچنین، پژوهش‌های متعددی برای بهبود چارچوب‌های شبیه‌سازی سطح آب زیرزمینی بر پایه یادگیری عمیق انجام شده است (Abdi et al., 2024; Feng et al., 2024). برای مثال، Bowes et al. (2019)، اثرات انتخاب

الگوریتم، نوع داده‌های آموزشی و ادغام داده‌های پیش‌بینی را بر دقت مدل پیش‌بینی سطح آب زیرزمینی در نورفولک، ویرجینیای ایالات متحده بررسی کردند. مدل پیشنهادی آن‌ها شامل پیش‌پردازش داده‌ها، فرایند یادگیری و پس‌پردازش نتایج بود. نتایج این پژوهش نشان داد که مدل LSTM عملکرد بهتری نسبت به شبکه عصبی بازگشتی (RNN) داشت. علاوه بر این، مشخص شد که مدلی که با داده‌های مربوط به رویدادهای طوفانی آموزش داده شده بود، در مقایسه با مدل‌هایی که با داده‌های مداوم یا پیش‌بینی‌شده از مجموعه داده‌های بوت‌استرپ هزارگانه^۷ آموزش دیده بودند، دقت بیشتری داشت (Bowes et al., 2019). Zhang et al. (2018) یک مدل LSTM دو لایه برای پیش‌بینی سطح آب زیرزمینی در منطقه آبیاری هتائو واقع در شمال غربی چین را طراحی کردند. نتایج این مطالعه نشان داد که مدل پیشنهادی توانست دقت بالاتری نسبت به شبکه عصبی پیش‌خور (FFNN) ارائه دهد، به‌طوری‌که مقادیر R^2 در مدل LSTM بین ۰/۷۹ تا ۰/۹۵ بود، درحالی‌که برای مدل FFNN مقادیر تنها در بازه صفر تا ۰/۵۰ قرار داشت. این اختلاف قابل توجه نشان‌دهنده توانایی بالای LSTM در مدل‌سازی نوسانات سطح آب زیرزمینی است (Zhang et al., 2018).

با توجه به توانایی بالای شبکه‌های عصبی بازگشتی مانند LSTM در مدل‌سازی سری‌های زمانی پیچیده و غیرخطی، این مطالعه به بررسی دقت مدل LSTM در پیش‌بینی سطح آب زیرزمینی در محدوده مطالعاتی سعادت‌آباد واقع در حوضه آبریز طشک-بختگان استان فارس می‌پردازد. در پژوهش‌های پیشین، تنظیم هایپرپارامترهای مدل با استفاده از روش آزمون و خطا و به‌طور اختصاصی برای محدوده مورد مطالعه انجام شده بود که این تنظیمات فقط برای آن منطقه خاص مناسب بود و قابلیت تعمیم به سایر مناطق جغرافیایی را نداشت. در مقابل، این مطالعه با استفاده از بهینه‌ساز بیزین برای تنظیم و بهینه‌سازی هایپرپارامترهای مدل، دقت پیش‌بینی را بهبود بخشیده و امکان تعمیم مدل به سایر حوضه‌ها و مناطق جغرافیایی را فراهم کرده است. علاوه بر این، این مطالعه به مقایسه عملکرد توابع فعال‌ساز مختلف در مدل LSTM پرداخته و تأثیر این توابع بر دقت پیش‌بینی را ارزیابی می‌کند. این نوع مقایسه با این گستردگی در مطالعات پیشین کمتر مورد توجه قرار گرفته است. مدل طراحی‌شده به‌عنوان یک چارچوب جامع و قابل تعمیم، قابلیت استفاده در مناطق جغرافیایی مختلف را دارد و می‌تواند به‌عنوان ابزاری مؤثر برای پیش‌بینی و مدیریت منابع آب زیرزمینی به کار رود.

۲. مواد و روش‌ها

۲.۱. منطقه مورد مطالعه

محدوده مطالعاتی سعادت‌آباد در حوضه آبریز طشک، بختگان و مهارلو در استان فارس قرار دارد. این منطقه در طول‌های جغرافیایی ۵۳ درجه و ۹ دقیقه تا ۵۲ درجه و ۴۴ دقیقه و عرض‌های جغرافیایی ۳۰ درجه و ۱ دقیقه و ۳۰ درجه و ۱۴ دقیقه واقع شده و مساحتی معادل ۷۲۶ کیلومترمربع را پوشش می‌دهد. بررسی مدل رقومی ارتفاع (DEM) منطقه نشان می‌دهد که ارتفاع محدوده از ۱۶۵۹ متر در بخش‌های جنوبی تا ۳۱۲۶ متر در نواحی غربی متغیر است و میانگین ارتفاع منطقه ۲۳۹۲/۵ متر ثبت شده است. این اختلاف ارتفاع بیانگر توپوگرافی متنوع و ساختار هیدرولوژیکی منطقه است.

این محدوده در بخش مرکزی حوضه آبریز دریاچه‌های طشک، بختگان و مهارلو واقع شده و از شرق به مرودشت-خرامه، از شمال به قادرآباد و مادر سلیمان و از جنوب به سیدان، فاروق و ارسنجان محدود می‌شود (شکل ۱). شرایط اقلیمی منطقه تحت تأثیر موقعیت جغرافیایی قرار دارد. به‌طور متوسط، میزان بارش سالانه بین ۲۰۰ تا ۲۵۰ میلی‌متر و دمای میانگین سالانه بین ۲- تا ۱۵ درجه سانتی‌گراد نوسان دارد. این ویژگی‌ها، همراه با تنوع ارتفاعی، از عوامل مؤثر بر نوسانات سطح آب زیرزمینی در این منطقه هستند. شکل (۱) موقعیت مکانی سعادت‌آباد و توزیع ارتفاعات را به‌وضوح نمایش می‌دهد. جدول (۱) به ارائه جزئیات بیشتری از ویژگی‌های اقلیمی و هیدرولوژیکی منطقه می‌پردازد.

در این منطقه، آبخوانی از نوع آبرفتی گسترده شده که وسعتی در حدود ۱۴۱/۸ کیلومترمربع دارد. میانگین ضخامت این آبخوان به ۶۰ متر می‌رسد و ضریب ذخیره آن در حدود ۵ درصد برآورد شده است. بررسی‌های انجام‌شده بر روی چاه‌های اکتشافی نشان می‌دهد که قابلیت انتقال آب در این محدوده به‌طور میانگین ۸۰ مترمربع در روز است. براساس محاسبات بیلان سالانه، میزان تغذیه آبخوان ۱۴۷/۵۳ میلیون مترمکعب تخمین زده شده، درحالی‌که برداشت سالانه از منابع زیرزمینی منطقه به ۱۶۴/۴۸ میلیون مترمکعب می‌رسد. این اختلاف حاکی از افت سالانه ذخایر آب زیرزمینی است که اهمیت مدیریت بهینه و پایدار منابع آبی این ناحیه را بیش از پیش نمایان می‌سازد (گزارش بیلان آبخوان جلد ۵).

Table 1. Climatic and Hydrological Characteristics of the Region

Study Area	Area (km ²)	Perimeter (km)	Basin Elevation in Meters			Basin Slope (%)	Main Stream Length (km)
			min	max	average		
Saadatabad	723	152.4	1664	3125	2394.5	23.2	152.4




Figure 1. Geographical location of the Saadatabad study area

۲.۲. داده‌های مورد استفاده

در این مطالعه برای پیش‌بینی سطح آب زیرزمینی، از داده‌های بارش، دما و تبخیر-تعرق به‌عنوان متغیرهای اصلی استفاده شده است. انتخاب این داده‌ها به‌دلیل تأثیر مستقیم و قابل‌توجه آن‌ها بر سطح آب زیرزمینی است. بارش و تبخیر-تعرق به‌طور مستقیم در فرایندهای هیدرولوژیکی مؤثر هستند و تغییرات آن‌ها می‌تواند نوسانات قابل‌توجهی در سطح آب زیرزمینی ایجاد کند. همچنین، دما به‌عنوان یک عامل مهم در تبخیر-تعرق و تأثیرات آن بر روند نوسانات آب زیرزمینی در نظر گرفته شده است. این داده‌ها علاوه بر تأثیر مستقیم بر سطح آب، در بسیاری از مناطق جغرافیایی قابل‌دسترس هستند و به همین دلیل می‌توانند در مدل‌سازی‌های مشابه در مناطق مختلف مورد استفاده قرار گیرند. همچنین، داده‌های سطح آب زیرزمینی به‌عنوان مقادیر هدف (مشاهده‌ای) مورد استفاده قرار گرفتند. مشخصات این داده‌ها شامل منابع، تفکیک مکانی و زمانی همچنین بازه زمانی در دسترس، در جدول (۲) ارائه شده است.

Table 2. Data used in the model

Data	Resource Data	Spatial separation	Time separation	Time period
Precipitation	GPM (IMERG V6)	10 km	Monthly	June 2000 to April 2021
Temperature	MOD11A2 (MODIS)	1 km	Eight days	February 2000 to December 2021
Evapotranspiration	MOD16A2 (MODIS)	500 m	Eight days	February 2000 to December 2021
Aquifer Hydrograph	Water Resources Management Company	-	Monthly	September 2003 to March 2019

۱.۲.۲. هیدروگراف معرف آبخوان

برای تحلیل و بررسی تغییرات سطح آب زیرزمینی در محدوده مطالعاتی سعادت‌آباد، داده‌های مشاهداتی چاه‌های آب زیرزمینی به‌عنوان منبع اصلی استفاده شده است. این داده‌ها که شامل تراز آب در بازه‌های زمانی مختلف هستند، از طریق شبکه‌ای متراکم از چاه‌های مشاهده‌ای که موقعیت آن‌ها در شکل (۲) مشخص شده، جمع‌آوری شده‌اند. از بین ۲۲ چاه مشاهده‌ای در این آبخوان از ۱۰ چاه که داده‌های کامل‌تری داشتند برای به‌دست‌آوردن هیدروگراف معرف استفاده شد. بازه زمانی داده‌های مشاهداتی از سپتامبر ۲۰۰۲ تا مارس ۲۰۱۹ است و به‌عنوان مقادیر هدف (مشاهده‌ای) برای ارزیابی عملکرد مدل LSTM در نظر گرفته شد.




Figure 2. Location of observation wells in the Saadatabad study area

به‌منظور پردازش داده‌های سطح آب زیرزمینی و تولید هیدروگراف معرف آبخوان، از روش چندضلعی‌های تیسن استفاده شد. این روش به‌دلیل توزیع مناسب چاه‌های مشاهده‌ای و وجود گرادیان هیدرولیکی منظم در منطقه، دقت بالایی در تخمین تراز آب میانگین دارد (Masoumi *et al.*, 2019). در این فرایند، ابتدا مساحت تیسن تحت پوشش هر چاه براساس محدوده‌های تیسن محاسبه گردید. سپس وزن هر چاه برحسب درصد مساحت تیسن تعیین شد و مقادیر تراز آب به‌صورت میانگین‌وزنی برای کل منطقه محاسبه شدند. برای اطمینان از صحت و انسجام سری زمانی تولیدشده، اقداماتی نظیر رفع بازه‌های با فقدان داده با استفاده از میانگین‌گیری و همسان‌سازی مقادیر انجام شد. این فرایند باعث شد که یک سری زمانی منسجم و دقیق از سطح آب زیرزمینی منطقه در بازه مورد‌مطالعه به‌دست آید. هیدروگراف نهایی ترسیم‌شده براساس این داده‌ها، روند تغییرات سطح آب زیرزمینی را در طول زمان نشان می‌دهد (شکل ۳).




Figure 3. Hydrograph of the Saadatabad aquifer

۲.۲.۲. بارش

بسته سنجنده GPM^۱ توسعه‌یافته‌ی سنجنده TRMM^۲ است که از آرایه‌های دو فرکانسی بارش شامل رادار بارش (DPR)^۳ و مشاهدات میکروویو چندکاناله (GMI)^۴ استفاده می‌کند. DPR برای مشاهده ساختارهای داخلی طوفان‌ها و زیرلایه ابرها به‌کار می‌رود، درحالی‌که GMI که شدت، نوع و مقدار بارش را اندازه‌گیری می‌کند (Hou *et al.*, 2014; Tan & Duan, 2017). از ویژگی‌های کلیدی GPM می‌توان به پوشش مکانی گسترده‌تر، توان تفکیک زمانی و مکانی بهتر و دقت بالاتر در تخمین بارش (شامل باران و برف)، به‌ویژه در مناطق مرتفع و کوهستانی اشاره کرد (Wang *et al.*, 2017). داده‌های سری زمانی محصول GPM (IMERG V6)^۵ در مقیاس زمانی ماهانه از ژوئن ۲۰۰۰ تا آوریل ۲۰۲۱ قابل‌پردازش و استخراج هستند (شکل ۴).




Figure 4. Precipitation data used in the model

۲.۳.۲. دما

سری زمانی دما براساس محصول MOD11A2 سنجنده مادیس، شامل داده‌های دما در ساعات روز و شب، به‌صورت میانگین هشت‌روزه در بازه زمانی ۲۶ فوریه ۲۰۰۰ تا ۳۱ دسامبر ۲۰۲۱ در دسترس است. همچنین، باتوجه به تفکیک زمانی هشت‌روزه این محصول، میانگین داده‌های هشت‌روزه برای هر ماه محاسبه شده و به‌عنوان دمای ماهانه در نظر گرفته شد (شکل ۵).




Figure 5. Temperature data used in the model

۲.۴.۲. تبخیر تعرق

محصول MOD16A2 سنجنده مادیس که براساس معادله پنمن-مانتیث توسعه یافته، داده‌های بسیار ارزشمندی برای مطالعه الگوهای زمانی و مکانی تبخیر و تعرق ارائه می‌دهد. این محصول با توان تفکیک مکانی ۵۰۰ متر و تفکیک زمانی هشت‌روزه، امکان تحلیل‌های دقیق و کاربردی را فراهم می‌کند (Hu *et al.*, 2015). نتایج مطالعات مختلف نشان می‌دهد که این محصول در مناطق گوناگون جهان عملکرد قابل اعتمادی داشته است (Hu *et al.*, 2015; Trambauer *et al.*, 2017; Wambura *et al.*, 2014; *al.*) و به‌دلیل دقت بالای زمانی و مکانی آن، برای ارزیابی تبخیر و تعرق واقعی و پتانسیل در این پژوهش مورد استفاده قرار گرفته است که در شکل (۶) نشان داده شده است (Cheng *et al.*, 2020).

علاوه بر این، یافته‌های Ruhoff *et al.* (2013) نشان می‌دهد که ترکیب داده‌های MOD16A2 در مقیاس‌های زمانی ماهانه و سالانه می‌تواند دقت نتایج این محصول را بهبود بخشد. الگوریتم تولید این داده‌ها بر مبنای منطق معادله پنمن-مانتیث طراحی شده و از ترکیب داده‌های هواشناسی و ویژگی‌های محیطی استخراج شده از تصاویر ماهواره‌ای استفاده می‌کند. تبخیر و تعرق پتانسیل و واقعی نیز به‌طور هم‌زمان محاسبه و ارائه می‌شود. از آن جهت که این محصول به‌صورت هشت‌روزه ارائه شده است؛ به‌جهت تولید سری زمانی ماهانه تبدیل‌های لازم براساس زمان‌بندی داده‌های هر تصویر برای تولید سری زمانی با مقیاس زمانی ماهانه انجام شد.




Figure 6. Evapotranspiration data used in the model

۳.۲. شبکه‌های عصبی حافظه بلندمدت-کوتاهمدت

شبکه‌های حافظه بلندمدت-کوتاهمدت (LSTM) نوعی از شبکه‌های عصبی بازگشتی (RNN) هستند که به‌طور گسترده برای مدل‌سازی داده‌های ترتیبی مانند سری‌های زمانی یا زبان طبیعی به کار می‌روند (Chen et al., 2017). یکی از مشکلات اصلی RNN، ناپدید شدن گرادین در فرایند پس‌انتشار خطا است که باعث می‌شود حافظه این شبکه‌ها تنها به حدود ۱۰ گام زمانی قبلی محدود شود (Bengio et al., 1994)، اما LSTMها به‌طور خاص برای غلبه بر این محدودیت طراحی شده‌اند و توانایی ذخیره و استفاده از وابستگی‌های بلندمدت را دارند (Hochreiter and Schmidhuber, 1997; Hock, 1999).

برخلاف RNNهای ساده، LSTMها دارای یک حافظه سلولی یا وضعیت سلولی (شکل ۷) هستند که اطلاعات را ذخیره می‌کند و سه دروازه برای کنترل جریان اطلاعات دارند (Hochreiter and Schmidhuber, 1997). دروازه فراموشی (f_t) تعیین می‌کند که کدام اطلاعات و به چه میزان باید از حافظه سلولی حذف شوند (رابطه ۱) (Gers et al., 2000).

$$f_t = \sigma(W_f[h_{t-1}, X_t] + b_f) \quad \text{(رابطه ۱)}$$

دروازه ورودی (i_t) مشخص می‌کند که کدام ورودی‌ها برای به‌روزرسانی حافظه سلولی استفاده شوند، در این دروازه تابع فعال‌ساز سیگموئید مقدار جدید را به‌روزرسانی می‌کند و تابع تانژانت هایپربولیک ($\tanh$) مقادیر جدید را ایجاد می‌کند (رابطه‌های ۲ و ۳).

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i) \quad \text{(رابطه ۲)}$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, X_t] + b_c) \quad \text{(رابطه ۳)}$$

دروازه خروجی (O_t) کنترل می‌کند که کدام عناصر حافظه سلولی برای به‌روزرسانی حالت پنهان استفاده شوند، این مقدار به کمک تابع سیگموئید و تابع تانژانت هایپربولیک ($\tanh$) محاسبه می‌شوند (رابطه ۴) (Hochreiter and Schmidhuber, 1997).

$$o_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \quad \text{(رابطه ۴)}$$

سپس وضعیت سلولی جدید (C_t) با استفاده از دروازه‌های فراموشی و ورودی به‌روزرسانی می‌شود (رابطه ۵):

$$C_t = \sigma(f_t * C_{t-1} + i_t * \tilde{C}_t) \quad \text{(رابطه ۵)}$$

در نهایت، مقدار خروجی (h_t) از طریق تابع تانژانت هایپربولیک ($\tanh$) و دروازه خروجی محاسبه می‌شود (رابطه ۶):

$$h_t = \tanh(C_t) * o_t \quad \text{(رابطه ۶)}$$

ویژگی حافظه سلولی به LSTM امکان می‌دهد تا اطلاعات را برای مدت طولانی در حافظه نگه دارد و وابستگی‌های بلندمدت را مدیریت کند. این ویژگی، LSTM را به ابزاری قدرتمند برای حل مشکلاتی که نیازمند پردازش داده‌های طولانی‌مدت هستند، تبدیل کرده است.

در یک مدل LSTM، می‌توان چندین لایه LSTM را به‌صورت پشته‌ای روی هم قرار داد. با این حال، لایه آخر LSTM معمولاً به یک لایه تراکم‌یافته کامل (Fully Connected) متصل می‌شود که در اینجا شامل یک نورون خروجی است و سطح آب زیرزمینی را پیش‌بینی می‌کند.

برای پیاده‌سازی مدل LSTM، از نسخه Python 3.11.5 در ترکیب با کتابخانه‌های Numpy (Van der Walt) و Matplotlib (Hunter)، Scikit-learn (McKinney, 2010)، Pandas (and Aivazis, 011)، TensorFlow (Abadi et al., 2017) و Keras (Chollet, 2015) استفاده شده است. هم‌چنین، از چارچوب‌های یادگیری عمیق TensorFlow (Abadi et al., 2017) و Keras (Chollet, 2015) نیز بهره گرفته شده است.




Figure 7. The internal structure of LSTM

۴.۲. واسنجی مدل

مدل LSTM به گونه‌ای طراحی شده است که شامل یک لایه LSTM به دنبال آن یک لایه کاملاً متراکم با یک نورون خروجی واحد برای پیش‌بینی است (شکل ۸). برای بهینه‌سازی مدل از Adam-Optimizer با نرخ یادگیری اولیه (learning rate) ۰/۰۱ استفاده شد و برای جلوگیری از انفجار گرادیان‌ها (gradient explosion)، از تکنیک برش گرادیان (gradient clipping) بهره می‌بریم که به کنترل بزرگ‌شدن مقادیر گرادیان‌ها و جلوگیری از ناپایداری آموزش کمک می‌کند. هایپرپارامترهایی که توسط یک مدل بیزین (Bayesian Model) بهینه می‌شوند، شامل تعداد واحدهای لایه LSTM (یک تا ۲۵۶)، اندازه دسته‌ای (batch size) از یک تا ۲۵۶ و طول توالی (sequence length) از یک تا ۱۲ هستند. طول توالی معمولاً به عنوان تعداد ورودی‌ها شناخته می‌شود و این پارامتر به طور مستقیم بر میزان وابستگی زمانی مدل و توانایی آن در پردازش اطلاعات بلندمدت تأثیر می‌گذارد. به طور کلی، این تنظیم‌ها به مدل اجازه می‌دهند که بهترین عملکرد را در پیش‌بینی داده‌های زمان سری و شبیه‌سازی الگوهای پیچیده‌ای مانند پیش‌بینی سطح آب زیرزمینی داشته باشد.




Figure 8. Simplified schematic summary of the model and its structure

بهینه‌سازی هایپرپارامترها با استفاده از بهینه‌ساز بیزین و پیاده‌سازی آن توسط Nogueira (2014) در Python انجام شده است. این فرایند شامل حداقل ۵۰ گام بهینه‌سازی است؛ ابتدا ۲۵ گام به صورت 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 ۵۰ برسد، بهینه‌سازی متوقف می‌شود.

مدل حداکثر ۶۰ دوره (Epoch) برای آموزش دارد و برای جلوگیری از بیش‌برازش (Overfitting)، از توقف زودهنگام (Early Stopping) با تحمل پنج گام استفاده می‌شود. دوره ارزیابی مدل از سال ۲۰۱۲ تا ۲۰۱۹ بوده که به‌طور انحصاری برای تست مدل‌ها به‌کار رفته است. داده‌های قبل از ۲۰۱۲، به سه بخش تقسیم شده‌اند ۸۰ درصد برای آموزش، ۱۰ درصد برای توقف زودهنگام و ۱۰ درصد برای تست در بهینه‌سازی هایپرپارامتر. تابع هدف بهینه‌سازی هایپرپارامترها تنها بر روی داده‌های تست محاسبه می‌شود.

تابع هدف بهینه‌سازی نیز به‌عنوان مجموع معیارهای کارایی نش-ساتکلیف (NSE) و ضریب تعیین (R^2) در نظر گرفته شده است (جدول ۳). این دو معیار به‌دلیل اهمیت و کاربرد گسترده‌شان در ارزیابی دقت پیش‌بینی‌ها در زمینه‌های مرتبط با آب انتخاب شده‌اند.

در این مطالعه، تمامی داده‌ها با استفاده از روش StandardScaler مقیاس‌بندی شده‌اند، که یک تکنیک رایج در پیش‌پردازش داده‌ها است. این روش مقادیر هر ویژگی را طوری تبدیل می‌کند که میانگین آن صفر و انحراف معیار آن یک باشد. رابطه استانداردسازی داده‌ها به صورت زیر تعریف می‌شود:

$$X_{scaled} = \frac{X - \mu}{\sigma} \quad (\text{رابطه ۷})$$

که در آن، X مقدار اصلی داده، μ میانگین ویژگی موردنظر در کل مجموعه داده، σ انحراف معیار داده موردنظر و X_{scaled} مقدار مقیاس‌بندی‌شده پس از تبدیل داده‌هاست.

این نوع مقیاس‌بندی باعث می‌شود که تمامی ویژگی‌ها در یک محدوده با توزیع نرمال استاندارد قرار بگیرند، که می‌تواند عملکرد مدل‌های یادگیری ماشین، به‌ویژه مدل‌های مبتنی بر شبکه‌های عصبی مانند LSTM را بهبود بخشد. زیرا این مدل‌ها به ورودی‌هایی حساس هستند که مقیاس‌های بسیار متفاوت دارند.

تمامی مدل‌ها به‌صورت تصادفی مقداردهی اولیه (random initialization) می‌شوند، که این امر باعث ایجاد وابستگی به تولید اعداد تصادفی می‌شود. برای کاهش تأثیر مقداردهی اولیه و افزایش پایداری مدل، هر گام بهینه‌سازی، پنج بار تکرار و میانگین تابع هدف محاسبه می‌شود. در نهایت، برای ارزیابی مدل در دوره تست (۲۰۱۳ تا ۲۰۱۹)، از ۱۰ مقداردهی اولیه تصادفی استفاده شده و میانگین خطاهای پیش‌بینی محاسبه می‌شود. این روش ارزیابی باعث کاهش حساسیت مدل به مقداردهی اولیه تصادفی شده و دقت و تعمیم‌پذیری آن را افزایش می‌دهد.

در این مطالعه، مدل LSTM بر روی هر دو بستر GPU (NVIDIA GeForce RTX 3050) و CPU (Intel Iris Xe) اجرا شد تا عملکرد آن‌ها از نظر زمان اجرا و دقت پیش‌بینی مقایسه شود. نتایج نشان داد که اجرای مدل روی GPU به‌طور قابل‌توجهی سریع‌تر از CPU بود. این موضوع نشان‌دهنده مزیت پردازش موازی در GPU است که به‌ویژه برای مدل‌های مبتنی بر شبکه‌های عصبی بازگشتی مانند LSTM کارآمدتر عمل می‌کند.

۵.۲. ارزیابی مدل

برای ارزیابی دقت پیش‌بینی مدل، چندین معیار آماری محاسبه شد. این معیارها کیفیت پیش‌بینی‌ها را ارزیابی کرده و نقاط قوت و ضعف مدل در پیش‌بینی سطح آب زیرزمینی را برجسته می‌کنند. جدول (۳) معیارهای ارزیابی را همراه با توضیحات و فرمول‌های آن‌ها ارائه می‌دهد، که در روابط آن‌ها، O مقادیر مشاهده‌شده، P مقادیر پیش‌بینی‌شده و N تعداد نمونه‌هاست. در این مطالعه، فرایند پیش‌بینی سطح آب زیرزمینی با استفاده از مدل LSTM به‌طور گام‌به‌گام از داده‌های هواشناسی، پیش‌پردازش داده‌ها، بهینه‌سازی بیزین و ارزیابی عملکرد مدل شامل استفاده از توابع فعال‌ساز مختلف، انجام شده است. مراحل دقیق این فرایند در شکل (۹) نمایش داده شده است.

Table 3. Model evaluation criteria with explanations and formulas

Criteria	Explanations	Formula
Nash-Sutcliffe Efficiency (NSE)	Model Prediction Quality Relative to the Mean of Observed Data	$NSE = 1 - \frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n (o_i - \bar{o})^2}$
Coefficient of Determination (R^2)	Correlation between Predicted and Observed Values	$R^2 = \left(\frac{\sum_{i=1}^n (o_i - \bar{o})(p_i - \bar{p})}{\sqrt{\sum_{i=1}^n (o_i - \bar{o})^2} \sqrt{\sum_{i=1}^n (p_i - \bar{p})^2}} \right)^2$
Root Mean Square Error (RMSE)	Mean Deviation of Model Predictions from Actual Values	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (o_i - p_i)^2}$
Relative Root Mean Square Error (rRMSE)	Normalizes the RMSE relative to the range of observed data	$rRMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n \left(\frac{o_i - p_i}{o_{max} - o_{min}} \right)^2}$
Absolute Bias (Bias)	Mean Deviation of Predictions from Observed Data	$Bias = \frac{1}{N} \sum_{i=1}^n (o_i - p_i)$
Relative Bias (rBias)	Normalizes the bias as a percentage relative to the mean of the data	$rBias = \frac{1}{N} \sum_{i=1}^n \left(\frac{o_i - p_i}{o_{max} - o_{min}} \right)$
Performance Index (PI)	Evaluates the model's ability to maintain prediction stability and provide similar patterns	$PI = 1 - \frac{\sum_{i=1}^n (o_i - p_i)^2}{\sum_{i=1}^n (o_i - o_{last})^2}$




Figure 9. Methodology of groundwater level prediction using the LSTM model

۶.۲. توابع فعال‌ساز در شبکه‌های عصبی مصنوعی

واحدهای محاسباتی در شبکه‌های عصبی مصنوعی (ANNs یا Artificial Neural Networks) به نام نورون‌ها، برای ایجاد غیرخطی بودن و توانایی مدل‌سازی داده‌های پیچیده از توابع فعال‌ساز استفاده می‌کنند. نورون‌ها معمولاً در لایه‌هایی سازماندهی می‌شوند و به نورون‌های لایه‌های قبلی و بعدی متصل هستند، اما ارتباطی با نورون‌های همان لایه ندارند (شکل ۱۰). وزن هر اتصال در طی فرایند یادگیری تنظیم می‌شود تا خروجی مطلوب حاصل شود.




Figure 10. The structure of the classical ANN model

این توابع نقش مهمی در تنظیم خروجی هر نورون دارند. برخی از توابع فعال‌ساز غیرخطی رایج در جدول (۴) آمده است.

Table 4. Frequently used functions of neural networks

Activation Function	Formula	Output Range	Graph
ReLU	$f(x) = \max(0, x)$	$[0, +\infty)$	
Linear	$f(x) = x$	$(-\infty, +\infty)$	
Sigmoid	$f(x) = \frac{1}{e^{-x} + 1}$	$(0, 1)$	
Tanh	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1, 1)$	

در این مرحله، تحلیل تأثیر توابع فعال ساز مختلف بر عملکرد مدل انجام خواهد شد. این تحلیل این امکان را می دهد که اثرات هر تابع را بر دقت پیش بینی و تطابق مدل با داده های واقعی ارزیابی کرده و بهترین گزینه را برای بهینه سازی عملکرد مدل انتخاب نمود.

۳. نتایج و بحث

در این مطالعه، داده های مختلفی برای پیش بینی سطح آب زیرزمینی جمع آوری شد که شامل بارش، دما، تبخیر و تعرق و سطح آب زیرزمینی از منابع گوناگون می باشند. داده های دما، بارش و تبخیر و تعرق از تصاویر و محصولات سنجنش از دور به دست آمده و کلیه پردازش های مربوط به این داده ها در محیط بستر ابری GEE^{۱۳} و در مقیاس مکانی محدوده مطالعاتی انجام شده است. این داده ها از سال ۲۰۰۰ تا ۲۰۲۴ در دسترس بودند. پیش از استفاده در مدل، تمامی داده ها تحت پیش پردازش قرار گرفتند تا تمامی ویژگی ها در مقیاس های یکنواخت قرار گیرند. لازم به ذکر است که داده های سطح آب زیرزمینی تا سال ۲۰۱۹ جمع آوری شدند. برای اطمینان از این که مقیاس های مختلف داده ها تأثیری بر عملکرد مدل نگذارند، از روش استانداردسازی برای مقیاس بندی داده ها استفاده گردید. در مرحله بعدی، داده ها به دو بخش آموزش و تست تقسیم شدند (بخش ۴-۲) تا ارزیابی دقیق تری از مدل حاصل شود.

تحلیل داده های بارندگی منطقه طی سال های ۲۰۰۴ و ۲۰۰۵ نشان می دهد که میزان بارش در این دوره به بیش از ۲۰۰ میلی متر رسیده است. این افزایش بارش به طور مستقیم موجب افزایش تغذیه آبخوان و روند صعودی هیدروگراف آن شده است. علاوه بر این، میزان تبخیر و تعرق نیز در این سال ها نسبت به دوره های بعدی در سطح بالاتری قرار داشته که نشان دهنده تأثیر متقابل فرایندهای هیدرولوژیکی بر چرخه آب در محدوده است. با این حال، از سال ۲۰۰۶ به بعد، روندی کاهشی در میزان بارندگی مشاهده می شود که به کاهش تغذیه آبخوان و در نتیجه افت سطح آب زیرزمینی منجر شده است. با وجود این کاهش در میزان بارندگی، داده ها نشان می دهند که میزان تبخیر و تعرق و دمای منطقه تغییر قابل توجهی را تجربه نکرده اند. این عدم تطابق می تواند بیانگر افزایش میزان برداشت از منابع آب زیرزمینی باشد، زیرا کاهش بارش احتمالاً با افزایش بهره برداری از این منابع برای تأمین نیازهای کشاورزی جبران شده است.

نتایج این بررسی بر اهمیت مدیریت جامع و پایدار منابع آب تأکید دارد. با توجه به تأثیر تغییرات اقلیمی و کاهش میزان بارندگی بر پایداری آبخوان، ضروری است که سیاست های مدیریتی به سمت راه کارهای کارآمدتر در تخصیص و بهره برداری از منابع آب سوق داده شوند. توسعه روش های نوین ذخیره سازی آب، بهینه سازی الگوهای مصرف، و استفاده از فناوری های پیش دقیق می تواند نقشی کلیدی در حفظ تعادل منابع آب زیرزمینی و کاهش تأثیرات منفی خشکسالی های آتی ایفا کند.

هدف اصلی این مطالعه، ارزیابی عملکرد مدل و بررسی تأثیر توابع فعال ساز مختلف بر دقت پیش بینی بود. همچنین، بهینه سازی بیزین برای تنظیم پارامترهای مدل به کار گرفته شد تا بهترین مقدار برای هر یک از هائیرپارامترهای مدل انتخاب شود. مدل طراحی شده در این پژوهش توانست به طور قابل توجهی نوسانات و روندهای بلندمدت سطح آب زیرزمینی را شبیه سازی کند و نتایج حاصل، دقت بالای این روش را در مقایسه با مدل های سنتی نشان داد. در فرایند بهینه سازی مدل، سه هائیرپارامتر کلیدی شامل تعداد واحدهای لایه LSTM، طول توالی و اندازه دسته موردبررسی قرار گرفتند. بهینه سازی بیزین نقش مهمی در یافتن ترکیب های بهینه این پارامترها ایفا کرد. نتایج نشان داد که افزایش تعداد واحدهای LSTM باعث بهبود عملکرد مدل در شناسایی وابستگی های بلندمدت در داده ها می شود، اما در عین حال، مقدار بیش از حد این پارامتر می تواند منجر به بیش برآزش مدل شود. طول توالی نیز تأثیر مستقیمی بر عملکرد مدل داشت، به طوری که انتخاب مناسب این مقدار باعث شد تا مدل بتواند روندهای کلی و نوسانات کوتاه مدت را با دقت بیش تری شبیه سازی کند. اندازه دسته نیز نقش مهمی در همگرایی مدل ایفا کرد و بهینه سازی این مقدار باعث کاهش خطای پیش بینی شد.

مقایسه عملکرد توابع فعال‌ساز مختلف نشان داد که ReLU بهترین نتایج را در پیش‌بینی سطح آب زیرزمینی ارائه داد (شکل ۱۱). این تابع با مقدار نش-ساتکلیف (NSE) برابر با ۰/۹۹، ضریب تعیین (R^2) برابر با ۰/۹۷ و خطای جذر میانگین مربعات (RMSE) برابر با ۰/۶۷ متر توانست روند تغییرات سطح آب زیرزمینی را با دقت بالایی شبیه‌سازی کند. در مقایسه با سایر توابع، ReLU توانست حداکثر و حداقل‌های سطح آب را بهتر مدل‌سازی کند و نوسانات بزرگ را با دقت بیشتری شبیه‌سازی نماید. همچنین، مقدار rBias برابر با ۰/۳۸ و شاخص پایداری (PI) برابر با ۰/۵۳ نشان‌دهنده دقت و پایداری مناسب این تابع فعال‌ساز بود.




Figure 11. LSTM model forecasts with activation functions: (a) ReLU, (b) Tanh, (c) Linear, (d) Sigmoid

تابع تانزانت هایپربولیک (Tanh) نیز عملکرد نسبتاً خوبی داشت، اما کمی از دقت مدل با ReLU کمتر بود. مقدار NSE برابر با ۰/۹۸ و R^2 برابر با ۰/۹۶ بود و مقدار RMSE برابر با ۰/۷۷ نشان‌دهنده افزایش جزئی خطا نسبت به ReLU بود. این تابع در مقایسه با ReLU حساسیت بیشتری به اشباع داشت که می‌توانست در برخی نقاط دقت مدل را کاهش دهد. مقدار rBias برابر با -۰/۴۲ و شاخص پایداری PI برابر با ۰/۴۴ نشان می‌دهد که این تابع در مقایسه با ReLU پایداری کمتری در پیش‌بینی‌های بلندمدت داشت.

مدل با استفاده از تابع فعال‌ساز خطی (Linear) نیز مورد بررسی قرار گرفت و نشان داد که دقت پایین‌تری نسبت به توابع غیرخطی دارد. مقدار NSE برابر با ۰/۹۶، R^2 برابر با ۰/۹۴ و RMSE برابر با ۱/۰۵ بود. مقدار rBias برابر با ۲/۷۴ و شاخص پایداری (PI) برابر با -۰/۱۴ نشان داد که این تابع نسبت به داده‌های سری زمانی حساسیت کمتری دارد و در شبیه‌سازی نوسانات شدید عملکرد ضعیف‌تری دارد. در این مدل، خطای بایاس مثبت بود که نشان‌دهنده بیش‌برازش در برخی نقاط پیش‌بینی بود.

تابع سیگموئید (Sigmoid) نیز نتایج ضعیف‌تری نسبت به سایر توابع ارائه داد. مقدار NSE برابر با ۰/۹۶، R^2 برابر با ۰/۹۴ و RMSE برابر با ۱/۰۷ محاسبه شد. مقدار rBias برابر با ۲/۸۰ و PI برابر با -۰/۱۹ نشان‌دهنده ناپایداری بیش‌تر در پیش‌بینی‌ها و دقت کم‌تر نسبت به سایر مدل‌ها بود. این تابع به دلیل دامنه خروجی محدود خود در بازه [۰،۱]، توانایی مدل‌سازی نوسانات بزرگ را نداشت و در برخی نقاط دچار بیش‌برازش شد.

برای ارزیابی دقیق‌تر پیش‌بینی‌های مدل LSTM، نقشه خطوط هم‌تراز سطح آب زیرزمینی در محدوده سعادت‌آباد، همان‌طور که در شکل (۱۲) نشان داده شده است، ارائه شده است. این نقشه به وضوح توزیع تغییرات سطح آب در نقاط مختلف منطقه را نمایش می‌دهد و کمک می‌کند تا الگوهای زمانی و مکانی سطح آب در طول دوره بررسی شده، تحلیل شود. خطوط هم‌تراز در این نقشه نمایانگر تغییرات تدریجی سطح آب در آبخوان منطقه هستند که می‌توان آن‌ها را با پیش‌بینی‌های مدل مقایسه کرد.

یکی دیگر از نکات مهم، تعداد داده‌های مورد استفاده و تأثیر آن بر عملکرد مدل بود. تعداد داده‌های ورودی به‌طور مستقیم بر عمق مدل تأثیر گذاشته و با توجه به محدود بودن داده‌ها، افزایش بیش‌از حد واحدهای LSTM می‌توانست منجر به بیش‌برازش شود. استفاده از بهینه‌سازی بیزین کمک کرد تا مقدار بهینه این پارامترها انتخاب شود و از بیش‌برازش مدل جلوگیری گردد. همچنین، مشخص شد که برای دستیابی به دقت بیش‌تر، افزایش حجم داده‌های آموزشی می‌تواند عملکرد مدل را بهبود دهد و دقت پیش‌بینی را در بازه‌های زمانی طولانی‌تر افزایش دهد. نتایج در جدول (۵) خلاصه شده است.

جدول (۵) نتایج بهینه‌سازی بیزین را برای انتخاب بهترین ترکیب‌های پارامترهای مدل LSTM نشان می‌دهد. در این جدول، داده‌های مختلف شامل بارش، تبخیر، تعرق و دما به‌طور متفاوتی در فرایند بهینه‌سازی مدل استفاده شده‌اند. مدل LSTM با ترکیب این داده‌ها، تأثیر آن‌ها را بر دقت پیش‌بینی اندازه‌گیری کرده و به بهترین ترکیب با بالاترین مقدار تابع هدف رسید. این فرایند به‌طور خودکار تعیین کرد که کدام داده‌ها بر بهبود تابع هدف تأثیرگذار بوده و داده‌هایی که تأثیر منفی داشتند، از مدل حذف شدند. علاوه بر این، جدول شامل اطلاعاتی است درباره بیش‌ترین تعداد تکرار (max iteration) و بهترین تکرار (best iteration) برای هر تابع فعال‌ساز. این مقادیر نشان‌دهنده تعداد گام‌هایی هستند که بهینه‌ساز برای یافتن بهترین ترکیب‌های پارامترها طی کرده است. همچنین، مدت زمان اجرای مدل با استفاده از CPU و GPU در این جدول آمده است که زمان‌های اجرای مدل را در دو حالت مختلف پردازشی نشان می‌دهد.




Figure 12. Map of groundwater level, Saadatabad area

Table 5. Bayesian optimizer results

Activation Function	P	ET	T	best iteration	Max iteration	Run time (min)	
						CPU	GPU
ReLU	✓	✓	✓	15	26	31	9
Tanh	✓	✓	✓	14	26	30	9
Linear	✓	✗	✗	19	29	37	11
Sigmoid	✓	✗	✓	24	34	43	15

برای مثال، مدل با تابع فعال‌ساز ReLU از تمامی داده‌ها استفاده کرده و برای رسیدن به بهترین ترکیب، ۲۶ گام را در طول فرایند بهینه‌سازی طی کرده است. در این فرایند، مدت زمان اجرا با CPU برابر با ۳۱ دقیقه و با GPU برابر با ۹ دقیقه بوده است. این نشان می‌دهد که استفاده از GPU به‌طور قابل‌توجهی مدت زمان اجرای مدل را کاهش می‌دهد. در مقایسه، مدل با تابع فعال‌ساز Sigmoid نیاز به ۳۴ گام برای بهینه‌سازی داشت و مدت زمان اجرای آن با CPU برابر با ۴۳ دقیقه و با GPU برابر با ۱۵ دقیقه بود. دلیل اصلی این بهبود سرعت، معماری

پردازشی موازی و برداری در GPU است که امکان انجام چندین محاسبه را به صورت همزمان فراهم می‌کند. در مقابل، GPUها دارای تعداد محدودی هسته پردازشی هستند که باعث می‌شود پردازش‌های سنگین شامل ماتریس‌های بزرگ، مانند آنچه در LSTM رخ می‌دهد، به زمان بیشتری نیاز داشته باشند. همچنین، کتابخانه‌های یادگیری عمیق مانند TensorFlow و keras به طور خاص برای استفاده بهینه از GPU بهینه‌سازی شده‌اند که این موضوع نیز در کاهش زمان اجرا نقش داشته است. علاوه بر این، مشاهده می‌شود که توابع ReLU و Tanh از تمامی داده‌ها بهره برده‌اند، درحالی که در تابع فعال‌ساز Linear، داده‌های تبخیر-تعرق و دما باعث کاهش دقت مدل شدند. همچنین، در تابع Sigmoid، داده‌های تبخیر تعرق تأثیر منفی بر عملکرد مدل گذاشته‌اند. از آنجایی که تأثیر این داده‌ها بر سطح آب زیرزمینی مشخص است، می‌توان نتیجه گرفت که توابع ReLU و Tanh بهتر عمل کرده‌اند و گزینه‌های مناسب‌تری برای پیش‌بینی سطح آب زیرزمینی هستند.

نتایج این بررسی نشان می‌دهند که مدل LSTM می‌تواند در زمان‌های کوتاه‌تری با استفاده از GPU بهینه‌سازی شود که در مطالعاتی با داده‌های بزرگ‌تر و پیچیده‌تر اهمیت بیشتری پیدا خواهد کرد. همچنین، مشاهده می‌شود که انتخاب تابع فعال‌ساز مناسب نه تنها بر دقت مدل تأثیر می‌گذارد، بلکه زمان اجرای آن را نیز تحت تأثیر قرار می‌دهد. تعداد تکرارهای انتخاب‌شده برای مدل با این ابعاد، مناسب بوده و در هیچ کدام از خروجی‌ها از تعداد تکرار حداکثر (۵۰ تکرار) تجاوز نکرده است. در مجموع، استفاده از مدل LSTM همراه با بهینه‌سازی بیزین توانست نتایج دقیقی در پیش‌بینی سطح آب زیرزمینی ارائه دهد. تابع ReLU به عنوان بهترین تابع فعال‌ساز در این پژوهش شناخته شد و عملکرد بهتری در مقایسه با سایر توابع ارائه داد. این تابع توانست با استفاده از تمامی ورودی‌های مدل روندهای کلی و نوسانات شدید تراز آب را به خوبی و در مدت زمان کمتر نسبت به سایر توابع شبیه‌سازی کند و دقت بالایی در پیش‌بینی‌های کوتاه‌مدت و بلندمدت داشته باشد. با توجه به نتایج به دست آمده، پیشنهاد می‌شود که برای کاربردهای مشابه، استفاده از توابع فعال‌ساز غیرخطی مانند ReLU یا Tanh در مدل‌های LSTM مورد توجه قرار گیرد، زیرا این توابع دقت و پایداری بهتری در پیش‌بینی‌های سری زمانی ارائه می‌دهند.

۴. نتیجه‌گیری

پیش‌بینی سطح آب زیرزمینی به عنوان یکی از مسائل اساسی در مدیریت منابع آب و برنامه‌ریزی برای استفاده پایدار از منابع آبی، به ویژه در مناطق با کمبود داده، از اهمیت ویژه‌ای برخوردار است. در این پژوهش، مدل Long Short-Term Memory برای پیش‌بینی سطح آب زیرزمینی در محدوده سعادت‌آباد، واقع در حوضه آبریز طشک-بختگان استان فارس، استفاده شد. نتایج به دست آمده نشان داد که مدل LSTM به طور مؤثر توانسته است نوسانات و روندهای بلندمدت سطح آب زیرزمینی را پیش‌بینی کند و عملکرد بالاتری در مقایسه با مدل‌های سنتی ارائه دهد. یکی از مهم‌ترین نتایج این پژوهش، توانایی مدل LSTM در شبیه‌سازی وابستگی‌های بلندمدت و پیچیده در داده‌های سری زمانی سطح آب زیرزمینی است. این مدل با استفاده از داده‌های بارش، تبخیر تعرق و دما توانست تغییرات و نوسانات سطح آب زیرزمینی را شبیه‌سازی کند. به ویژه، نتایج نشان داد که مدل LSTM به خوبی قادر به شبیه‌سازی تأثیر بارش‌های زیاد و دوره‌های خشکسالی بر سطح آب زیرزمینی بوده است. همچنین، انتخاب تابع فعال‌ساز مناسب تأثیر زیادی بر دقت پیش‌بینی‌ها داشت و تابع ReLU به عنوان بهترین تابع فعال‌ساز شناخته شد. این تابع توانست روندهای بلندمدت و نوسانات شدید سطح آب را با دقت بالایی شبیه‌سازی کند. در فرایند بهینه‌سازی مدل، بهینه‌ساز بیزین نقش بسیار مهمی در انتخاب ترکیب‌های بهینه پارامترها ایفا کرد. به ویژه، نتایج نشان داد که افزایش تعداد واحدهای LSTM و طول توالی داده‌ها

به‌طور قابل‌توجهی دقت مدل را افزایش داد. در عین‌حال، استفاده از بهینه‌سازی بیزین از بروز مشکل بیش‌برازش جلوگیری کرد و باعث شد که مدل به بهترین ترکیب از هاپرپارامترها دست یابد. این امر نشان‌دهنده اهمیت استفاده از بهینه‌ساز بیزین در مدل‌های پیچیده و داده‌های محدود است.

مقایسه مدل LSTM با سایر مدل‌های سنتی مانند شبکه عصبی مصنوعی و شبکه عصبی پیش‌خور نشان داد که مدل LSTM دقت بالاتری در پیش‌بینی سطح آب زیرزمینی داشت. به‌ویژه، مدل LSTM با استفاده از GPU توانست در مدت زمان کم‌تری به نتیجه برسد که این موضوع نشان‌دهنده مزیت پردازش موازی در GPU برای مدل‌های مبتنی بر شبکه‌های عصبی است. این مسئله به‌ویژه در مطالعاتی با داده‌های بزرگ‌تر و پیچیده‌تر دارای اهمیت است. با این‌حال، این پژوهش با محدودیت‌هایی نیز مواجه بود. یکی از محدودیت‌های اصلی این پژوهش، کمبود داده‌های با تفکیک زمانی و مکانی بالا بود. داده‌های تبخیر-تعرق و دما در برخی از مدل‌ها تأثیر منفی بر دقت پیش‌بینی‌ها گذاشتند و این موضوع به‌ویژه در توابع فعال‌ساز Linear و Sigmoid مشاهده شد. این مشکل ممکن است ناشی از پیچیدگی‌های مدل یا ارتباطات غیرخطی پیچیده بین داده‌ها باشد. بنابراین، در آینده می‌توان با استفاده از داده‌های دقیق‌تر و بیش‌تر، عملکرد مدل را بهبود بخشید. همچنین، داده‌های مربوط به ویژگی‌های زمین‌شناسی و آب‌خوان می‌تواند تأثیر زیادی بر دقت مدل داشته باشد و در پژوهش‌های آینده باید این داده‌ها را نیز در مدل گنجانند تا شبیه‌سازی دقیق‌تری از وضعیت آب‌خوان‌ها ارائه شود. پیشنهاد می‌شود که در پژوهش‌های آتی، استفاده از داده‌های حس‌گری دقیق‌تر، مدل‌های هیبریدی شامل ترکیب LSTM با دیگر مدل‌های یادگیری ماشین و تحلیل تأثیر متغیرهای محیطی دیگر مانند ویژگی‌های آب‌خوان و ساختارهای زمین‌شناسی نیز در نظر گرفته شوند.

در نهایت، این پژوهش نشان می‌دهد که مدل LSTM با بهینه‌سازی بیزین و استفاده از توابع فعال‌ساز غیرخطی مانند ReLU و Tanh، به‌عنوان یک ابزار قدرتمند در پیش‌بینی سطح آب زیرزمینی، به‌ویژه در مناطق با کمبود داده‌های هیدرولوژیکی، معرفی می‌شود. استفاده از این مدل‌ها می‌تواند در برنامه‌ریزی و مدیریت منابع آب زیرزمینی در مناطق مختلف جغرافیایی بسیار مفید باشد. همچنین، استفاده از پردازش موازی با GPU می‌تواند به‌طور قابل‌توجهی زمان پردازش مدل را کاهش دهد و در پژوهش‌های آتی با داده‌های پیچیده‌تر و حجم بالاتر بسیار مؤثر واقع شود.

۵. پی‌نوشت‌ها

1. Artificial Intelligence
2. Artificial Neural Networks
3. Multilayer Perceptron
4. Feedforward Neural Network
5. Adaptive Neuro-Fuzzy Inference System
6. Residual Network Structure
7. Gated Recurrent Units
8. Long Short-Term Memory
9. Convolutional Neural Networks
10. Recurrent Neural Network

۱۱. بوت‌استرپ یک روش نمونه‌گیری مجدد است که برای برآورد توزیع آماری یک نمونه داده استفاده می‌شود. در این روش، با جایگذاری نمونه‌های متعددی از داده‌های اولیه گرفته می‌شود و آماره‌های موردنظر روی این نمونه‌ها محاسبه می‌شوند.

12. Global Precipitation Measurement
13. Tropical Rainfall Measuring Mission
14. Dual-frequency Precipitation Radar
15. GPM Microwave Imager
16. Integrated Multi-satellitE Retrievals for GPM
17. Google Earth Engine

۶. تعارض منافع

هیچ گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷. منابع

- Abadi, M., Barhum, P., & Mishra, A. K. (2017). A machine learning approach to radar sea clutter suppression. *2017 IEEE Radar Conference, RadarConf 2017*, 1222-1227. <https://doi.org/10.1109/RADAR.2017.7944391>
- Abdi, E., Ali, M., Santos, C. A. G., Olusola, A., & Ghorbani, M. A. (2024). Enhancing groundwater level prediction accuracy using interpolation techniques in deep learning models. *Groundwater for Sustainable Development*, 26(June). <https://doi.org/10.1016/j.gsd.2024.101213>
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157-166. <https://doi.org/10.1109/72.279181>
- Benielli, D., Capponi, C., Koço, S., Kadri, H., Huusari, R., Bauvin, B., & Laviolette, F. (2022). Toolbox for Multimodal Learn (scikit-multimodallearn). *Journal of Machine Learning Research*, 23, 1-7.
- Bowes, B. D., Sadler, J. M., Morsy, M. M., Behl, M., & Goodall, J. L. (2019). Forecasting groundwater table in a flood prone coastal city with long short-term memory and recurrent neural networks. *Water (Switzerland)*, 11(5). <https://doi.org/10.3390/w11051098>
- Chen, Q., Ling, Z., Jiang, H., Zhu, X., Wei, S., & Inkpen, D. (2017). Enhanced LSTM for natural language inference. *ACL 2017-55th Annual Meeting of the Association for Computational Linguistics, Proceedings of the Conference (Long Papers)*, 1(2008), 1657-1668. <https://doi.org/10.18653/v1/P17-1152>
- Chollet, F. (2015). *No Title*. Keras. <https://github.com/keras-team/keras>
- Feng, F., Ghorbani, H., & Radwan, A. E. (2024). Predicting groundwater level using traditional and deep machine learning algorithms. *Frontiers in Environmental Science*, 12(February). <https://doi.org/10.3389/fenvs.2024.1291327>
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to Forget: Continual Prediction with LSTM. *Neural Computation*, 12(10), 2451-2471. <https://doi.org/10.1162/089976600300015015>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hock, R. (1999). A distributed temperature-index ice- and snowmelt model including potential direct solar radiation. *Journal of Glaciology*, 45(149), 101-111. <https://doi.org/DOI: 10.3189/S0022143000003087>
- Hou, A. Y., Kakar, R. K., Neeck, S., Azarbarzin, A. A., Kummerow, C. D., Kojima, M., Oki, R., Nakamura, K., & Iguchi, T. (2014). The global precipitation measurement mission. *Bulletin of the American Meteorological Society*, 95(5), 701-722. <https://doi.org/10.1175/BAMS-D-13-00164.1>
- Hunter, J. D. (2007). Matplotlib: A 2D Graphics Environment. *Computing in Science & Engineering*, 9(3), 90-95. <https://doi.org/10.1109/MCSE.2007.55>
- Jeong, J., Park, E., Chen, H., Kim, K. Y., Shik Han, W., & Suk, H. (2020). Estimation of groundwater level based on the robust training of recurrent neural networks using corrupted data. *Journal of Hydrology*, 582(December 2019), 124512. <https://doi.org/10.1016/j.jhydrol.2019.124512>
- Lallahem, S., Mania, J., Hani, A., & Najjar, Y. (2005). On the use of neural networks to evaluate groundwater levels in fractured media. *Journal of Hydrology*, 307(1), 92-111. <https://doi.org/https://doi.org/10.1016/j.jhydrol.2004.10.005>
- Loh, H. W., Ooi, C. P., Seoni, S., Barua, P. D., Molinari, F., & Acharya, U. R. (2022). Application of explainable artificial intelligence for healthcare: A systematic review of the last decade (2011–2022). *Computer Methods and Programs in Biomedicine*, 226, 107161. <https://doi.org/https://doi.org/10.1016/j.cmpb.2022.107161>
- Masoumi, Z., Rezaei, A., & Maleki, J. (2019). Improvement of water table interpolation and groundwater storage volume using fuzzy computations. *Environmental Monitoring and Assessment*, 191(6), 1-15. <https://doi.org/10.1007/s10661-019-7513-1>
- McKinney, W. (2010). Data Structures for Statistical Computing in Python. *Proceedings of the 9th Python in Science Conference*, 1(Scipy), 56-61. <https://doi.org/10.25080/majora-92bf1922-00a>

- Omar, P. J., Gaur, S., Dwivedi, S. B., & Dikshit, P. K. S. (2019). Groundwater modelling using an analytic element method and finite difference method: An insight into Lower Ganga river basin. *Journal of Earth System Science*, 128(7), 195. <https://doi.org/10.1007/s12040-019-1225-3>
- Ren, H., Cromwell, E., Kravitz, B., & Chen, X. (2022). Technical note: Using long short-term memory models to fill data gaps in hydrological monitoring networks. *Hydrol. Earth Syst. Sci.*, 26(7), 1727-1743. <https://doi.org/10.5194/hess-26-1727-2022>
- Shin, M. J., Moon, S. H., Kang, K. G., Moon, D. C., & Koh, H. J. (2020). Analysis of groundwater level variations caused by the changes in groundwater withdrawals using long short-term memory network. *Hydrology*, 7(3). <https://doi.org/10.3390/HYDROLOGY7030064>
- Sreekanth, P. D., Sreedevi, P. D., Ahmed, S., & Geethanjali, N. (2011). Comparison of FFNN and ANFIS models for estimating groundwater level. *Environmental Earth Sciences*, 62(6), 1301-1310. <https://doi.org/10.1007/s12665-010-0617-0>
- Tan, M. L., & Duan, Z. (2017). Assessment of GPM and TRMM precipitation products over Singapore. *Remote Sensing*, 9(7), 1-16. <https://doi.org/10.3390/rs9070720>
- Van der Walt, S., & Aivazis, M. (2011). The NumPy Array: A Structure for Efficient Numerical Computation, Computing in Science & Engineering. *Computing in Science and Engineering*, 13(2), 22-30. <http://aip.scitation.org/doi/abs/10.1109/MCSE.2011.37>
- Wang, Z., Zhong, R., Lai, C., & Chen, J. (2017). Evaluation of the GPM IMERG satellite-based precipitation products and the hydrological utility. *Atmospheric Research*, 196(May), 151-163. <https://doi.org/10.1016/j.atmosres.2017.06.020>
- Zeydaliinejad, N. (2022). Artificial neural networks vis-à-vis MODFLOW in the simulation of groundwater: a review. *Modeling Earth Systems and Environment*, 8(3), 2911-2932. <https://doi.org/10.1007/s40808-022-01365-y>
- Zhang, J., Zhu, Y., Zhang, X., Ye, M., & Yang, J. (2018). Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas. *Journal of Hydrology*, 561, 918-929. <https://doi.org/10.1016/j.jhydrol.2018.04.065>