

Distributed groundwater level modeling using graph, convolutional, and long short-term memory neural networks

Negin Rashidi¹ and Vahid Moosavi^{2*}

¹ M.Sc. Graduate in Watershed Science and Engineering, Department of Watershed Engineering, Faculty of Natural Resources, Tarbiat Modares University, Noor, Iran

² Associate Professor, Department of Watershed Science and Engineering, Faculty of Natural Resources, Tarbiat Modares University, Noor, Iran

Received: 18 April 2026

Accepted: 21 June 2026

Extended abstract

Introduction

Groundwater level modeling has always been a major challenge in groundwater resource management due to its complex, nonlinear, and spatiotemporally dependent nature. The main objective of this study was to develop and evaluate a distributed deep learning-based modeling approach for the simultaneous prediction of groundwater levels in a network of piezometric wells within the Kouchesfahan aquifer located in the Sefidroud watershed. In this framework, each well was considered as a node in a graph network, and the model predicted groundwater levels for each well at the next monthly time step ($t+1$). By integrating graph neural networks with convolutional structures and long short-term memory architectures, the study aimed to identify the spatial and temporal dependencies governing aquifer behavior and improve prediction accuracy compared to conventional methods.

Materials and methods

In this study, four graph-based deep learning architectures, including Graph Neural Network (GNN), Graph Attention Network (GAT), Graph Convolutional Network (GCN), and the hybrid GCN-LSTM model, were employed. Here, GNN refers to the baseline GCN-based graph neural architecture using the standard graph convolution operator. Each piezometric well was represented as a graph node, and the adjacency matrix was constructed using inverse-distance weighting. Input data included hydroclimatic variables, geological information, pumping characteristics, and spatial distances related to hydrogeological factors. Model performance was evaluated using R^2 , RMSE, MAE, NSE, and KGE indices. In the proposed model, GCN layers were first applied to the spatial graph of wells to extract spatial features and hydraulic dependencies. The resulting hidden representations were then transferred to the LSTM network to model temporal dependencies and groundwater level dynamics.

Results and discussion

The results indicated that while the GNN model could partially reconstruct the general trends of groundwater level changes, it lacked accuracy in representing extreme behaviors and temporal dependencies. The GAT model showed a slight improvement over GNN but remained limited in extracting deep temporal patterns. In contrast, the GCN model demonstrated better performance in identifying spatial dependencies, leading to a significant improvement in evaluation metrics. The best performance was achieved by the GCN-LSTM model, which effectively represented both spatial and temporal features simultaneously, showing the highest overlap with observed data. This model reached an R^2 of 0.896, RMSE of 0.336, and MAE of 0.269, indicating its high accuracy in predicting groundwater levels.

Conclusion

Hybrid graph-sequential architectures, especially GCN-LSTM, are highly effective for modeling complex aquifer hydrodynamics. This model predicted groundwater levels with high accuracy and outperformed purely graph-based models. Therefore, it is recommended for operational groundwater prediction and sustainable water management, serving as a novel framework to support better decision-making in water resources.

Keywords: Adjacency Matrix, Aquifer, Artificial Intelligence, Prediction, Spatio-temporal Deep Learning

* Corresponding author: v.moosavi@modares.ac.ir

Cite this article: Rashidi, N., Moosavi, V., 2026. Distributed groundwater level modeling using graph, convolutional, and long short-term memory neural networks. Water. Eng. Manag.18(3), 378-399.

© 2026, The Author(s). Published by Soil Conservation and Watershed Management Research Institute (SCWMRI). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>)



مدلسازی توزیعی سطح آب زیرزمینی با ترکیب شبکه‌های عصبی ترسیمی، پیچشی و حافظه کوتاه-بلند مدت

نگین رشیدی^۱ و وحید موسوی^{۲*}

^۱ دانش‌آموخته کارشناسی ارشد علوم و مهندسی ابخیزداری، گروه مهندسی ابخیزداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس، نور، ایران

^۲ دانشیار گروه علوم و مهندسی ابخیزداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس، نور، ایران

تاریخ پذیرش: ۱۴۰۵/۰۳/۳۱

تاریخ دریافت: ۱۴۰۵/۰۱/۲۹

چکیده مبسوط

مقدمه

مدلسازی سطح آب زیرزمینی به دلیل ماهیت پیچیده، غیرخطی و وابسته به عوامل مکانی-زمانی، همواره چالشی اساسی در مدیریت منابع آب زیرزمینی بوده است. در این پژوهش، هدف اصلی ارائه و ارزیابی یک رویکرد مدلسازی توزیعی مبتنی بر یادگیری عمیق برای پیش‌بینی همزمان تراز آب زیرزمینی در مجموعه چاه‌های پیژومتری آبخوان کوجصفهان در آبخیز سفیدرود است. در این چارچوب، هر چاه به عنوان یک گره در شبکه ترسیمی در نظر گرفته شد و مدل، تراز آب زیرزمینی هر چاه را در گام زمانی ماهانه بعدی ($t+1$) پیش‌بینی می‌کند. با بهره‌گیری از شبکه‌های عصبی ترسیمی ترکیب‌شده با ساختارهای پیچشی و حافظه کوتاه‌مدت-بلندمدت، تلاش می‌شود وابستگی‌های مکانی و زمانی رفتار آبخوان شناسایی شده و دقت پیش‌بینی نسبت به روش‌های متداول افزایش یابد.

مواد و روش‌ها

در این پژوهش، چهار ساختار یادگیری عمیق مبتنی بر گراف شامل شبکه عصبی ترسیمی (GNN)، شبکه توجه گرافی (GAT)، شبکه پیچشی گرافی (GCN) و مدل ترکیبی GCN-LSTM به کار رفت. منظور از GNN معماری پایه Graph Convolutional Network (GCN-based GNN) مبتنی بر عملگر کانولوشن گرافی استاندارد است. هر چاه پیژومتری به عنوان یک گره در نظر گرفته شد و ماتریس مجاورت با وزن‌دهی معکوس فاصله تشکیل شد. داده‌های ورودی شامل متغیرهای هیدرواقليمی، اطلاعات زمین‌شناسی، ویژگی‌های پمپاژ و فواصل مکانی از عوامل هیدروژئولوژیک بودند. ارزیابی با شاخص‌های R^2 ، RMSE، MAE، NSE و KGE انجام شد. در مدل پیشنهادی، در هر گام زمانی ابتدا لایه‌های GCN بر روی گراف مکانی چاه‌ها اعمال شدند تا ویژگی‌های فضایی و وابستگی‌های هیدرولیکی استخراج شوند. سپس بردارهای پنهان حاصل به شبکه LSTM منتقل شدند تا وابستگی‌های زمانی و پویایی سطح آب زیرزمینی مدلسازی شود.

نتایج و بحث

نتایج نشان داد که مدل GNN اگرچه توانست روندهای کلی تغییرات سطح آب زیرزمینی را تا حدودی بازسازی کند، اما در نمایش رفتارهای حادی و وابستگی‌های زمانی دقت کافی نداشت. مدل GAT نیز نسبت به GNN بهبود نسبی نشان داد، اما همچنان در استخراج الگوهای عمیق زمانی محدود بود. در مقابل، مدل GCN عملکرد بهتری در شناسایی

* مسئول مکاتبات: v.moosavi@modares.ac.ir

وابستگی‌های مکانی از خود نشان داد و موجب بهبود قابل توجه شاخص‌های ارزیابی شد. بهترین عملکرد مربوط به مدل GCN-LSTM بود که توانست هم‌زمان ویژگی‌های مکانی و زمانی را به‌صورت مؤثرتری بازنمایی کند و بیشترین همپوشانی را با داده‌های مشاهده‌ای داشته باشد. بر اساس نتایج گزارش‌شده، این مدل به مقادیر $R^2=0.896$ ، $MAE=0.269$ و $RMSE=0.336$ دست یافت که نشان‌دهنده دقت بالای آن در پیش‌بینی سطح آب زیرزمینی است.

نتیجه‌گیری

یافته‌های این پژوهش نشان می‌دهد که بهره‌گیری از معماری‌های ترکیبی مبتنی بر گراف و توالی، به‌ویژه مدل GCN-LSTM، می‌تواند ابزار بسیار مؤثری برای مدل‌سازی رفتار هیدرودینامیکی آبخوان‌های پیچیده باشد. این مدل توانست با دقت بالا رفتار سطح آب زیرزمینی را پیش‌بینی کرده و برتری خود را نسبت به مدل‌های صرفاً گراف‌ی نشان دهد. در نتیجه، استفاده از این رویکرد برای پیش‌بینی عملیاتی سطح آب زیرزمینی و مدیریت پایدار منابع آب توصیه می‌شود. این روش می‌تواند به‌عنوان یک چارچوب نوین در تحلیل و مدیریت آبخوان‌ها، به تصمیم‌گیری بهتر در حوزه منابع آب کمک کند.

واژه‌های کلیدی: آبخوان، ماتریس مجاورت، یادگیری عمیق مکانی-زمانی، پیش‌بینی، هوش مصنوعی

مقدمه

مدل به‌طور صریح از معادلات حاکمی که فرایند فیزیکی را مقید می‌کنند، تبعیت کند (Raissi et al., 2019). با وجود پیشرفت قابل توجه در حوزه یادگیری ماشین برای مدل‌سازی GWL، باید توجه داشت که روش‌های داده‌محور پیشین رابطه مکانی موجود در داده‌های GWL را نادیده گرفته‌اند، زیرا آرایش فضایی چاه‌های پایش معمولاً نامنظم است و در نتیجه، مدل‌های سنتی یادگیری ماشین نمی‌توانند به‌راحتی داده‌های نامنظم و غیرساختاریافته را پردازش کنند (Bai and Tahmasebi, 2021).

از آنجا که رفتار آبخوان‌ها ماهیتی مکانی-زمانی دارد و نقاط مختلف در شبکه هیدروژئولوژیکی به‌طور فضایی به یکدیگر وابسته‌اند، نیاز به مدل‌هایی وجود دارد که قادر باشند این وابستگی‌ها را به شکل هوشمندانه استخراج کنند (Homayounpour et al., 2022). بنابراین، برای پردازش چنین داده‌هایی و هنگامی که وابستگی مکانی بین آنها وجود دارد، شبکه‌های عصبی ترسیمی^۳ توسعه داده شده‌اند تا الگوهای فضایی-زمانی را از داده‌هایی با ساختارهای پیچیده استخراج کنند. در سال‌های اخیر، ظهور مدل‌های مبتنی بر گراف نظیر شبکه‌های عصبی ترسیمی، شبکه توجه-ترسیمی^۴ و

سطح آب زیرزمینی یکی از مهم‌ترین مؤلفه‌های چرخه هیدروژئولوژیکی و از ارکان اساسی مدیریت پایدار منابع آب به شمار می‌رود (Chamanpira et al., 2014). کاهش سطح آب زیرزمینی در اثر برداشت بی‌رویه، تغییرات اقلیمی، رشد جمعیت و شهرنشینی سریع شدت یافته و این عوامل تأثیرات جدی بر میزان دسترس‌پذیری آن گذاشته‌اند (Minnig et al., 2018). از این‌رو، توانایی پیش‌بینی و مدل‌سازی تراز آب زیرزمینی^۱ نقش مهمی در برنامه‌ریزی و مدیریت پایدار منابع آب زیرزمینی ایفا می‌کند (Famiglietti, 2014). در سال‌های اخیر، مدل‌های داده‌محور و یادگیری ماشین برای این منظور مورد توجه قرار گرفته‌اند (Marufinia et al., 2025).

مدل‌های یادگیری ماشین کلاسیک نظیر درخت تصمیم، ماشین بردار پشتیبان، رگرسیون بردار پشتیبان، سامانه‌های استنتاج عصبی-فازی تطبیقی، جنگل تصادفی و شبکه‌های عصبی پرسپترون چندلایه (MLP) برای پیش‌بینی سطح آب زیرزمینی به‌کار رفته‌اند و در بسیاری از موارد توانسته‌اند دقت قابل‌قبولی ارائه دهند (Tang et al., 2019). ظهور شبکه‌های عصبی فیزیک آگاه^۲ حتی این امکان را فراهم کرده است که

³ Graph Neural Networks

⁴ Graph Attention Neural Networks

¹ Groundwater Level

² physics-informed neural networks

همان‌طور که پژوهش‌ها نشان می‌دهد، ترکیب مدلسازی فضایی مبتنی بر گراف و مدلسازی زمانی با استفاده از LSTM، باعث ایجاد رویکردهای نوینی شده است که قابلیت بازنمایی همزمان ویژگی‌های مکانی و زمانی را دارند (Wu et al., 2021).

در پژوهش حاضر، از ترکیب شبکه کانولوشنی گراف (GCN) و حافظه بلندمدت کوتاه‌مدت (LSTM) برای مدلسازی و پیش‌بینی سطح آب زیرزمینی استفاده شده است. در این چارچوب، لایه‌های GCN به‌منظور استخراج وابستگی‌ها و روابط مکانی میان چاه‌های مشاهده‌ای و نمایش ساختار فضایی آبخوان به‌کار گرفته می‌شوند، در حالی که بخش LSTM وظیفه مدلسازی وابستگی‌های زمانی و روند تغییرات سطح آب زیرزمینی را بر عهده دارد. بدین‌ترتیب، مدل پیشنهادی تلاش می‌کند اطلاعات مکانی و زمانی را به‌صورت هم‌زمان در فرایند یادگیری لحاظ کند. اگرچه مطالعات متعددی در سال‌های اخیر از روش‌های یادگیری عمیق در مسائل هیدرولوژی و منابع آب استفاده کرده‌اند، به‌کارگیری ساختارهای مبتنی بر گراف برای مدلسازی هم‌زمان روابط مکانی و زمانی آب زیرزمینی همچنان محدود است.

از این‌رو، نوآوری این پژوهش نه در معرفی یک معماری کاملاً جدید، بلکه در ارزیابی و به‌کارگیری ترکیب GCN-LSTM برای شبیه‌سازی رفتار سطح آب زیرزمینی در آبخوان مورد مطالعه و مقایسه آن با چند معماری گراف‌محور دیگر نهفته است. در این مطالعه، عملکرد مدل پیشنهادی با سه ساختار دیگر شامل GNN پایه، GAT و GCN مقایسه شده است.

در اینجا، منظور از GNN پایه، شبکه عصبی گرافی ساده‌ای است که تنها از لایه‌های انتشار اطلاعات گراف بدون مکانیزم توجه (Attention) یا حافظه زمانی استفاده می‌کند. همچنین، مدل GCN صرفاً وابستگی‌های مکانی را مدلسازی می‌کند و مدل GAT با بهره‌گیری از مکانیزم توجه، اهمیت نسبی ارتباط میان گره‌ها را تعیین می‌کند.

شبکه ترسیمی-پیچشی^۱ امکان مدلسازی ساختارهای پیچیده مکانی را فراهم کرده است (Wunsch et al., 2021). این مدل‌ها قادرند وابستگی‌ها و روابط بین چاه‌ها، لایه‌های آبخوان و نواحی مختلف را در قالب یک گراف توصیف کرده و الگوهای فضایی را استخراج کنند (Kamrava et al., 2021). از سوی دیگر، مدل‌های یادگیری عمیق ویژه سری‌های زمانی مانند شبکه‌های بازگشتی^۲، شبکه‌های بلند مدت-کوتاه^۳ و مدل‌های مبتنی بر توجه، توانسته‌اند به‌طور مؤثری الگوهای زمانی را در داده‌های هیدرولوژیکی شناسایی کنند. در همین راستا Bai et al., (2023) به توسعه یک مدل شبکه عصبی ترسیمی برای پیش‌بینی دقیق و هم‌زمان سطح آب زیرزمینی در همه چاه‌ها، با در نظر گرفتن روابط فضایی بین آنها پرداختند، نتایج نشان داد که مدل پیشنهادی عملکردی بهتر از LSTM^۴ و GRU^۵ دارد، حتی با وجود ناشناخته بودن وابستگی‌های فضایی و می‌تواند این وابستگی‌ها را از داده‌ها به‌طور مؤثر یاد بگیرد.

علاوه‌براین Taccari et al., (2024) در مطالعه خود با هدف به‌کارگیری شبکه‌های عصبی ترسیمی فضایی-زمانی برای پیش‌بینی دقیق سطح آب زیرزمینی با در نظر گرفتن تعاملات پیچیده فضایی و زمانی در سامانه آب زیرزمینی منطقه Overbetuwe هلند پرداختند، نتایج نشان داد مدل ST-GNN^۶ پیشنهادی در مدیریت داده‌های ناقص و پیش‌بینی بلندمدت سطح آب زیرزمینی عملکردی دقیق‌تر، باثبات‌تر و کم‌سوگیرتر از مدل‌های عددی و روش‌های سنتی دارد. همچنین Liang et al., (2025) در پژوهشی به ارائه یک چارچوب مبتنی بر شبکه‌های عصبی ترسیمی برای پیش‌بینی سریع و دقیق سطح آب زیرزمینی به‌عنوان جایگزینی کارآمد برای مدل‌های عددی پیچیده پرداختند، نتایج نشان داد که این چارچوب قادر است، پیش‌بینی‌های سریع و قابل‌اعتمادی ارائه دهد و یک جایگزین محاسباتی بسیار کارآمد برای مدیریت آب زیرزمینی در محیط‌های هیدروژئولوژیکی پیچیده محسوب می‌شود.

^۴ Long Short Term Memory

^۵ gated recurrent units

^۶ spatial-temporal graph neural networks

^۱ Graph convolution Neural Networks

^۲ Recurrent Neural Network

^۳ Long Short-Term Memory

تحلیل و پیش‌بینی رفتار سامانه‌های آب زیرزمینی مورد توجه قرار گیرد.

مواد و روش‌ها


منطقه مورد مطالعه: منطقه مورد بررسی در این پژوهش، آبخوان کوچصفهان از آبخیز سفیدرود است. دشت آستانه-کوچصفهان در استان گیلان واقع شده و یکی از منابع مهم تأمین آب در استان گیلان به شمار می‌رود که بر روی مخروط افکنه رودخانه سفیدرود شکل گرفته است. مساحت این دشت حدود ۱۱۰۰ کیلومتر مربع برآورد شده است. این منطقه از جمله نواحی پرباران ایران محسوب می‌شود. به گونه‌ای که میانگین بارندگی سالانه آن بر اساس آمار ۴۰ ساله حدود ۱۴۳۰ میلی‌متر گزارش شده است.

میزان برداشت از منابع آب زیرزمینی این دشت حدود ۴۴/۲ میلیون مترمکعب در سال برآورد شده است (Khorramdel et al., 2008). مهم‌ترین رودخانه این حوضه، رودخانه سفیدرود با طول تقریبی ۶۷۰ کیلومتر است که میانگین آبدهی سالانه آن حدود ۳۹۹۸/۴ میلیون مترمکعب گزارش شده است (Mirmoshtaghi et al., 2012). شکل ۱، موقعیت منطقه مورد مطالعه در داخل کشور و آبخوان مورد مطالعه را نشان می‌دهد.

این مقایسه امکان بررسی تأثیر هر یک از سازوکارهای مکانی و زمانی را بر دقت پیش‌بینی فراهم می‌سازد. نتایج حاصل از ارزیابی مدل‌ها نشان می‌دهد که ترکیب اطلاعات مکانی و زمانی می‌تواند دقت پیش‌بینی سطح آب زیرزمینی را نسبت به برخی مدل‌های صرفاً مکانی بهبود دهد. با این حال، میزان این بهبود به کیفیت داده‌ها، نحوه تعریف ساختار گراف، تعداد چاه‌های مشاهده‌ای و ویژگی‌های هیدروژئولوژیکی منطقه وابسته است.

همچنین، در این پژوهش مقایسه مستقیمی با مدل‌های غیرگرافی کلاسیک یا مدل‌های فیزیکی انجام نشده است. بنابراین، تعمیم نتایج به تمامی شرایط هیدروژئولوژیکی نیازمند مطالعات تکمیلی است. از دیگر محدودیت‌های این رویکرد می‌توان به وابستگی عملکرد مدل به حجم و کیفیت داده‌های آموزشی، حساسیت به نحوه تعریف یال‌ها و وزن‌های گراف و کاهش قابلیت تفسیرپذیری مدل‌های یادگیری عمیق نسبت به مدل‌های مفهومی فیزیکی اشاره کرد.

با وجود این محدودیت‌ها، نتایج پژوهش نشان می‌دهد که استفاده از مدل‌های یادگیری عمیق مبتنی بر گراف می‌تواند به عنوان یک ابزار داده‌محور مکمل در



شکل ۱- موقعیت آبخوان مورد مطالعه
Fig. 1. Location of the studied aquifer

دبی^۱، شاخص پوشش گیاهی نرمال‌شده، بارش، دما، درصد شن، سیلت و رس، ضریب انتقال‌پذیری^۲، کاربری/پوشش اراضی، فاصله تا قنات، فاصله تا چشمه، فاصله تا رودخانه، فاصله تا گسل و میزان برداشت از

روش انجام پژوهش: در این پژوهش، تراز آب زیرزمینی با استفاده از مجموعه‌ای از متغیرهای هیدرو-اقلیمی، زمین‌شناسی و انسانی مربوط به چاه‌های مشاهده‌ای مدل‌سازی شد. متغیرهای ورودی شامل

² Transmissivity

¹ Discharge

قدیمی‌تر برای آموزش مدل و بخش زمانی متأخرتر برای اعتبارسنجی به کار رفتند. در این چارچوب، مدل در هر مرحله تنها با استفاده از اطلاعات گذشته آموزش دیده و سپس بر روی داده‌های بعدی ارزیابی شده است. بنابراین هیچ‌گونه اطلاعاتی از بازه آزمون یا آینده سری زمانی وارد فرایند آموزش نشده است.

این راهبرد، شرایط پیش‌بینی واقعی را شبیه‌سازی کرده و موجب می‌شود معیارهای ارزیابی، برآوردی قابل اعتمادتر از توان تعمیم مدل در پیش‌بینی تغییرات آینده سطح آب زیرزمینی ارائه دهند. داده‌ها شامل مشاهدات ماهانه از چندین چاه پیژومتری بودند، به‌طوری که هر چاه به‌عنوان یک گره (Node) در یک گراف مکانی در نظر گرفته شد. در هر گام زمانی t ، ماتریس ویژگی‌های ورودی به‌صورت زیر تعریف می‌شود.

$$X_t \in \mathbb{R}^{N \times F} \quad (1)$$

که در آن، N تعداد چاه‌ها و F تعداد متغیرهای ورودی است. همچنین، بردار تراز آب زیرزمینی به‌صورت زیر نمایش داده می‌شود.

$$y_t \in \mathbb{R}^N \quad (2)$$

که هر مؤلفه آن متناظر با تراز آب زیرزمینی یک چاه خاص است. پیش‌پردازش داده‌ها شامل بررسی و جایگزینی داده‌های مفقود، نرمال‌سازی متغیرهای ورودی و سازمان‌دهی سری‌های زمانی در مقیاس ماهانه یکنواخت بود تا داده‌ها برای ورود به مدل‌های یادگیری عمیق آماده شوند. در این پژوهش، هدف مدل پیش‌بینی همزمان تراز آب زیرزمینی در تمامی چاه‌های پیژومتری موجود در شبکه پایش بود.

بنابراین خروجی مدل به‌صورت گره‌محور تعریف شد، به‌گونه‌ای که در هر گام زمانی، مقدار تراز آب زیرزمینی هر چاه به‌طور مستقل اما با در نظر گرفتن وابستگی‌های مکانی-زمانی سایر چاه‌ها پیش‌بینی می‌شود. فرایند آموزش با استفاده از بهینه‌ساز Adam انجام شد و تابع هزینه بر اساس میانگین مربعات خطا (MSE) تعریف شد. عملکرد مدل‌ها با استفاده از شاخص‌های آماری ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، ضریب تعیین (R^2) ارزیابی شد.

چاه‌ها بودند. متغیر تراز آب زیرزمینی به‌عنوان متغیر هدف در نظر گرفته شد. در این مطالعه، پمپاژ آینده به‌صورت یک سناریوی مستقل و صریح مدلسازی نشده است؛ بلکه ویژگی‌های پمپاژ به‌عنوان یکی از ورودی‌های مدل در نظر گرفته شده‌اند تا اثر تاریخی و مشاهده‌شده آن بر تغییرات سطح آب زیرزمینی در پیش‌بینی لحاظ شود. از این‌رو، رویکرد به‌کار گرفته شده بر یادگیری رابطه‌های مکانی-زمانی از داده‌های موجود استوار نه بر فرض‌سازی صریح درباره مقدار آینده پمپاژ است.

بنابراین، سناریوهای مبتنی بر پمپاژ آینده یا مدل‌های مبتنی بر تداوم روند به‌صورت جداگانه تعریف و مقایسه نشده‌اند. دلیل این انتخاب آن است که در بسیاری از آبخوان‌ها، پمپاژ آینده به سیاست‌های بهره‌برداری، تغییرات تقاضا، و تصمیمات مدیریتی وابسته است و در عمل دارای عدم قطعیت بالایی است. در چنین شرایطی، مدلسازی مبتنی بر داده‌های مشاهده‌شده و یادگیری الگوهای گذشته، برای پیش‌بینی عملیاتی و پشتیبانی از مدیریت پایدار آب زیرزمینی مناسب‌تر و قابل‌اتکاتر است.

این متغیرها مهم‌ترین عوامل مؤثر بر نوسانات آب زیرزمینی، از جمله فرایندهای تغذیه، ویژگی‌های هیدروژئولوژیکی و اثرات برداشت انسانی را نمایندگی می‌کنند. در این پژوهش، داده‌های مربوط به ۲۵ حلقه چاه پیژومتری شامل مشاهدات ماهانه عمق آب زیرزمینی طی یک دوره ۲۰ ساله مورد استفاده قرار گرفت که در مجموع یک سری زمانی منظم با پوشش مناسب برای تحلیل تغییرات زمانی-مکانی سطح آب زیرزمینی فراهم کرد. بررسی اولیه داده‌ها نشان داد که نرخ داده‌های مفقود حدود چهار درصد است. به‌منظور ارزیابی واقع‌بینانه عملکرد مدل و جلوگیری از نشت زمانی، تقسیم داده‌ها به‌صورت ترتیبی بر اساس توالی زمانی انجام شد و از رویکرد forward-chaining استفاده شد.

بدین صورت که ۷۰ درصد ابتدایی داده‌ها برای مرحله آموزش و اعتبارسنجی و ۳۰ درصد انتهایی داده‌ها به‌عنوان مجموعه آزمون نهایی در نظر گرفته شد. در داخل بخش ۷۰ درصدی نخست نیز داده‌ها بدون هرگونه اختلاط زمانی، به دو زیرمجموعه آموزش و اعتبارسنجی تقسیم شدند. به‌گونه‌ای که قسمت‌های

توزیع داده‌ها در مجموعه‌ی آموزش محاسبه شدند. سپس همین پارامترهای ثابت، بدون هیچ‌گونه بازبرازش یا تغییر، برای انتقال داده‌های مجموعه‌های اعتبارسنجی و آزمون به فضای مقیاس‌شده به کار گرفته شدند. در نهایت، ساختار این پروتکل پیش‌پردازش تضمین می‌کند که مدل در هیچ‌یک از مراحل آموزش و تنظیم فرایند آموزش، به ویژگی‌های آماری یا مشاهدات مربوط به آینده دسترسی نداشته و ارزیابی عملکرد آن در شرایطی کاملاً واقع‌بینانه و منطبق بر سناریوی پیش‌بینی عملیاتی صورت گرفته است.

توسعه مدل‌ها: در این مطالعه، چهار مدل یادگیری عمیق مبتنی بر شبکه‌های عصبی ترسیمی برای پیش‌بینی تراز آب زیرزمینی توسعه داده شد. هدف این مدل‌ها، استخراج همزمان روابط مکانی بین چاه‌ها و اثر متغیرهای محیطی و انسانی بر نوسانات آب زیرزمینی است.

شبکه عصبی ترسیمی: به‌منظور در نظر گرفتن وابستگی‌های مکانی بین چاه‌های مشاهده‌ای، چاه‌ها به‌صورت گره‌های یک گراف $G=(V,E)$ مدلسازی شدند، به‌طوری که V مجموعه گره‌ها (چاه‌ها) و E مجموعه یال‌ها (روابط مکانی) را نشان می‌دهد. برای تعریف ارتباط بین چاه‌ها، ماتریس مجاورت^۱ بر اساس فاصله مکانی بین چاه‌ها و با استفاده از وزن‌دهی معکوس فاصله ساخته شد. میزان نزدیکی یا ارتباط بین هر دو گره می‌تواند توسط ماتریس مجاورت توصیف شود که معمولاً بر اساس دانش پیشین، مانند فاصله مکانی یا شباهت عملکردی محاسبه می‌شود (Wang et al., 2021).

در این پژوهش، ماتریس مجاورت گراف بر اساس ساختار گراف کامل وزن‌دار و با استفاده از تابع معکوس فاصله بین چاه‌های پیژومتری ساخته شد. به عبارت دیگر، تمامی چاه‌ها به‌صورت بالقوه به یکدیگر متصل در نظر گرفته شدند، اما شدت ارتباط میان هر دو گره تابعی از فاصله اقلیدسی بین آنها بود؛ به‌طوری که چاه‌های نزدیک‌تر وزن بیشتری دریافت کردند و اثر چاه‌های دورتر به‌صورت تدریجی کاهش یافت. این رویکرد با هدف حفظ پیوستگی هیدرولیکی سامانه آب زیرزمینی

این شاخص‌ها برای مقایسه دقت و صحت پیش‌بینی چهار مدل گراف‌محور و تعیین کارآمدترین معماری در پیش‌بینی تراز آب زیرزمینی مورد استفاده قرار گرفتند. در این مطالعه پیش‌بینی برای یک ماه آینده انجام شده است. به عبارت دیگر، مدل با استفاده از اطلاعات در دسترس تا زمان t ، مقدار عمق آب زیرزمینی را در زمان $t+1$ برآورد می‌کند. در فرایند آموزش، اعتبارسنجی و آزمون، ساختار داده‌ها به‌صورت کاملاً ترتیبی و علی حفظ شد و از هیچ‌گونه اطلاعات مربوط به زمان‌های آینده در آموزش یا استنتاج استفاده نشد.

بدین منظور، ورودی هر نمونه تنها شامل مشاهدات گذشته و جاری تا زمان t بوده و مقادیر مربوط به $t+1$ و بعد از آن صرفاً به‌عنوان هدف پیش‌بینی یا برای ارزیابی عملکرد مدل به کار رفته‌اند. همچنین، با توجه به تقسیم‌بندی زمانی داده‌ها و استفاده از رویکرد forward-chaining، مجموعه آزمون شامل بازه انتهایی سری زمانی بوده است و در هیچ مرحله‌ای اطلاعات این بازه به آموزش مدل نشت نکرده است. بنابراین، تنظیم آزمایش‌ها به‌گونه‌ای انجام شد که شرایط پیش‌بینی واقعی آینده به‌طور دقیق شبیه‌سازی شود. برای مدیریت مقادیر مفقود در هر چاه پیژومتری، از روش پیش‌رونده (Forward-fill) استفاده شد.

بدین معنی که هر مقدار مفقود صرفاً بر اساس آخرین مشاهده‌ی در دسترس در گذشته آن سری زمانی جایگزین شد. در مواردی که مقادیر مفقود در ابتدای سری زمانی قرار داشتند و هیچ پیشینه‌ای برای آنها ثبت نشده بود، از میانگین (یا میانه) داده‌های همان چاه، که صرفاً از بازه زمانی آموزش استخراج شده بود، به‌عنوان یک مقدار ثابت برای جایگزینی استفاده شد. این تدبیر تضمین کرد که فرایند جایگزینی، تحت تأثیر هیچ داده‌ای از بازه‌های زمانی آینده (اعتبارسنجی و آزمون) قرار نگیرد.

در گام دوم، به‌منظور هم‌مقیاس‌سازی متغیرها، از روش نرمال‌سازی Min-Max (یا استانداردسازی Z-score) استفاده شد. برای جلوگیری از بروز پدیده‌ی نشت اطلاعات (Data Leakage)، تمامی پارامترهای آماری مورد نیاز برای این تبدیل‌ها (ازجمله مقادیر حداقل، حداکثر، میانگین و انحراف معیار) تنها بر اساس

¹Adjacency Matrix

اگرچه در این پژوهش ارتباطات ترسیمی بر اساس فاصله مکانی بین چاه‌ها تعریف شده است، اما چنین ساختاری همچنان قادر است نحوه انتشار تأثیرات هیدرولوژیکی بین نقاط مختلف سیستم را نمایش دهد. در نتیجه، ماتریس مجاورت به عنوان ساختار اتصال اولیه برای یادگیری روابط مکانی در مدل‌های مبتنی بر گراف مورد استفاده قرار می‌گیرد (Lin et al., 2025؛ Kilinc et al., 2026).

مدل GNN به عنوان مدل پایه برای یادگیری مکانی مورد استفاده قرار گرفت. در این مدل، ویژگی‌های هر گره از طریق فرایند انتقال پیام^۱ از همسایگان آن به روزرسانی می‌شود. هر گره با جمع اطلاعات چاه‌های مجاور، نمایش مکانی جدیدی از رفتار آب زیرزمینی را یاد می‌گیرد. فرایند به روزرسانی نمایش گره‌ها در لایه $l+1$ به صورت زیر بیان می‌شود.

$$H^{(l+1)} = \sigma(\hat{A}H^{(l)}W^{(l)}) \quad (3)$$

که در آن، $H^{(l)}$ ویژگی‌های گره‌ها در لایه l ، $W^{(l)}$ ماتریس وزن‌های قابل آموزش، A ماتریس مجاورت و σ تابع فعال‌سازی غیرخطی است. خروجی نهایی این مدل برای پیش‌بینی تراز آب زیرزمینی استفاده می‌شود.

شبکه توجه-ترسیمی: به منظور مدلسازی دقیق‌تر وابستگی‌های مکانی میان چاه‌های مشاهده‌ای و لحاظ کردن تفاوت میزان اثرگذاری چاه‌های مجاور بر یکدیگر، مدل شبکه توجه-ترسیمی با افزودن مکانیزم توجه به چارچوب شبکه‌های عصبی ترسیمی توسعه داده شد تا سهم هر گره همسایه در به روزرسانی نمایش گره مرکزی به صورت داده‌محور و قابل آموزش تعیین شود. در این رویکرد، هر چاه مشاهده‌ای به صورت یک گره در گراف در نظر گرفته شده و روابط مکانی میان چاه‌ها از طریق یال‌های گراف نمایش داده می‌شود.

برخلاف مدل‌های ساده‌تر که در آنها همه همسایه‌ها اثر یکسانی بر گره هدف دارند، در GAT وزن تأثیر هر چاه مجاور به صورت تطبیقی و با استفاده از سازوکار توجه محاسبه می‌شود. برای هر گره i ، ابتدا ضریب توجه بین گره‌های i و j بر اساس ویژگی‌های آنها محاسبه می‌شود.

و جلوگیری از حذف ارتباطات بالقوه میان بخش‌های مختلف آبخوان انتخاب شد. در مرحله توسعه مدل، ساختارهای ساده‌تر نظیر گراف k -نزدیک‌ترین همسایه (kNN) و گراف مبتنی بر آستانه شعاعی نیز به صورت اولیه مورد بررسی قرار گرفتند، اما نتایج نشان داد که در آبخوان مورد مطالعه، استفاده از گراف کامل وزن‌دار مبتنی بر فاصله معکوس، پایداری بیشتری در فرایند آموزش و دقت بالاتری در بازنمایی وابستگی‌های مکانی ایجاد می‌کند. دلیل این موضوع را می‌توان به ماهیت نسبتاً پیوسته سامانه هیدروژئولوژیکی منطقه و ارتباط هیدرولیکی گسترده میان چاه‌ها نسبت داد.

در یک گراف ساده و متناهی، ماتریس مجاورت می‌تواند به صورت یک ماتریس دودویی باشد که در آن اگر $e_{ij} \in E$ باشد مقدار $a_{ij}=1$ و در غیر این صورت مقدار آن صفر است. در این پژوهش نوع وزن‌دار بر اساس فاصله استفاده شده است. تقارن ماتریس مجاورت نیز بیانگر نوع وابستگی بین گره‌ها است، به طوری که ماتریس متقارن نشان‌دهنده گراف بدون جهت بوده و ماتریس نامتقارن بیانگر وجود جهت در ارتباطات میان گره‌ها است. در این پژوهش گراف به صورت بدون جهت در نظر گرفته شد، در این روش، چاه‌هایی که فاصله کمتری از یکدیگر دارند، ارتباط قوی‌تری خواهند داشت که این موضوع بیانگر تداوم مکانی و پیوستگی هیدرولیکی در سیستم آب زیرزمینی است. این ساختار ترسیمی امکان یادگیری وابستگی‌های مکانی بین چاه‌ها را در فرایند آموزش مدل فراهم می‌کند.

از دیدگاه هیدرولوژیکی، ماتریس مجاورت می‌تواند بازنمایی ساده‌ای از نحوه انتشار فرایندهای محلی در سراسر سامانه آب زیرزمینی ارائه دهد و محدودیت‌های فیزیکی مؤثر بر انتقال آب در محیط متخلخل را به طور ضمنی در ساختار مدل لحاظ کند (Zha and Yang, 2024).

در مطالعات هیدرولوژیکی، ساختارهای ترسیمی مشابه، گاه بر اساس الگوهای تجمع جریان یا مسیرهای انتقال در سیستم‌های سطحی نیز استخراج می‌شوند که نشان‌دهنده ارتباطات هیدرولیکی و نحوه انتقال جریان در مقیاس حوضه هستند (Wang and Zhu, 2025).

¹ Message Passing

سپس یک لایه توجه، مهم‌ترین الگوهای استخراج‌شده را برجسته می‌کند. عملیات پیچشی-ترسیمی به صورت زیر تعریف می‌شود.

$$H^{(l+1)} = \sigma(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} H^{(l)} W^{(l)}) \quad (7)$$

که در آن، $\tilde{A} = A + I$ ماتریس مجاورت همراه با حلقه‌های خودی، $\tilde{D}$ ماتریس درجه متناظر، $H^{(l)}$ ماتریس ویژگی‌گره‌ها در لایه l ، $W^{(l)}$ ماتریس وزن قابل آموزش، و σ تابع فعال‌سازی غیرخطی است. نرمال‌سازی ماتریس مجاورت باعث می‌شود سهم گره‌ها در فرایند انتشار اطلاعات به صورت متعادل‌تری وارد مدل شده و پایداری عددی آموزش نیز بهبود یابد.

پس از استخراج نمایش مکانی اولیه توسط لایه GCN، یک لایه توجه به مدل اضافه می‌شود تا بتواند از میان ویژگی‌های مکانی استخراج‌شده، مؤثرترین روابط و الگوها را برجسته کند. این مرحله به مدل کمک می‌کند تا علاوه بر یادگیری ساختار کلی ارتباطات بین چاه‌ها، نسبت به تفاوت اهمیت این ارتباطات نیز حساس باشد. در نتیجه، مدل ترکیبی GCN-Attention قادر است هم ساختار همسایگی کلی آبخوان و هم اثرگذاری نسبی چاه‌های مجاور را به طور هم‌زمان در فرایند پیش‌بینی لحاظ کند.

از دیدگاه هیدروژئولوژیکی، این رویکرد برای سامانه‌های آب زیرزمینی مناسب است، زیرا تغییرات سطح آب زیرزمینی معمولاً حاصل برهم‌کنش مجموعه‌ای از عوامل محلی و ناحیه‌ای است. بخشی از این تغییرات ناشی از ساختار مکانی پیوسته آبخوان و همبستگی فضایی بین چاه‌ها است که توسط GCN به خوبی بازنمایی می‌شود، و بخش دیگر ناشی از تفاوت در اهمیت و شدت اثرگذاری چاه‌های مجاور است که با استفاده از لایه توجه قابل یادگیری خواهد بود. این ویژگی به‌ویژه در آبخوان‌هایی با ناهمگنی فضایی، شرایط تغذیه متفاوت، الگوهای برداشت متغیر و پاسخ‌های زمانی غیریکنواخت، اهمیت زیادی دارد.

شبکه توجه ترسیمی پیچشی-حافظه بلندمدت کوتاه: از آنجا که تراز آب زیرزمینی دارای وابستگی زمانی قوی است، مدل GCN-LSTM با توجه برای یادگیری همزمان الگوهای مکانی-زمانی توسعه داده شد. در این معماری، ابتدا لایه‌های GCN ویژگی‌های مکانی را در هر گام زمانی استخراج می‌کنند و سپس

$$a_{i,j} = \frac{\exp(\text{LeakyReLU}(a^T[Wh_i||Wh_j]))}{\sum_{k \in N_i} \exp(\text{LeakyReLU}(a^T[Wh_i||Wh_k]))} \quad (4)$$

که در آن، h_i و h_j ویژگی‌های گره‌های i و j ، W ماتریس وزن قابل آموزش، a بردار توجه قابل آموزش و N_i مجموعه همسایگان گره i است. همچنین نماد $||$ نشان‌دهنده عملگر الحاق بردارها است. تابع LeakyReLU نیز برای اعمال غیرخطی‌سازی در محاسبه ضرایب توجه استفاده می‌شود. پس از محاسبه ضرایب توجه، نمایش جدید هر گره از طریق جمع وزن‌دار اطلاعات همسایگان به صورت زیر به‌روزرسانی می‌شود.

$$h_i^{(l+1)} = \sigma(\sum_{j \in N(i)} a_{ij}^{(l)} W^{(l)} h_j^{(l)}) \quad (5)$$

که در آن، $h_i^{(l+1)}$ نمایش گره i در لایه $l+1$ ماتریس وزن لایه l ، و σ تابع فعال‌سازی غیرخطی است. در صورت استفاده از ساختارهای عمیق‌تر، می‌توان از اتصال باقیمانده نیز برای جلوگیری از تضعیف اطلاعات اولیه و بهبود پایداری آموزش بهره گرفت.

$$h_i^{(l+1)} = \sigma(\sum_{j \in N(i)} a_{ij}^{(l)} W^{(l)} h_j^{(l)}) + h_i^{(l)} \quad (6)$$

در این پژوهش، سازوکار توجه این امکان را فراهم می‌کند که مدل بتواند چاه‌هایی را که اثر بیشتری بر رفتار هیدرودینامیکی چاه هدف دارند، شناسایی کند. به بیان دیگر، همه چاه‌های مجاور الزاماً نقش یکسانی در تغییرات سطح آب زیرزمینی ندارند و وزن‌های توجه آموخته‌شده می‌توانند این تفاوت را منعکس کنند.

چنین قابلیت به‌ویژه در آبخوان‌های ناهمگن اهمیت دارد، زیرا پاسخ سامانه به تنش‌های هیدرولوژیکی و اقلیمی در تمام نقاط یکسان نیست. این کار سبب افزایش پایداری فرایند یادگیری و بهبود توانایی مدل در استخراج الگوهای مکانی پیچیده می‌شود. در نهایت، نمایش نهایی هر گره برای پیش‌بینی تراز آب زیرزمینی در گام زمانی آینده مورد استفاده قرار می‌گیرد.

شبکه عصبی توجه- ترسیمی پیچشی: به منظور ترکیب مزایای پیچشی-ترسیمی در استخراج ساختار کلی وابستگی‌های مکانی و سازوکار توجه در تأکید بر مؤثرترین ارتباطات، از یک مدل ترکیبی GCN-Attention نیز استفاده شد. در این چارچوب، ابتدا ویژگی‌های گره‌ها از طریق عملگر پیچشی-ترسیمی و بر پایه ماتریس مجاورت نرمال‌شده انتشار می‌یابند و

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (12)$$

$$h_t = o_t \odot \tanh(\tilde{h}_t) \quad (13)$$

در این رابطه، W و b به ترتیب نشان دهنده وزن ها و بایاس های قابل آموزش هستند، نماد $\odot$ بیانگر ضرب در مؤلفه های متناظر^۴ است، x_t و h_{t-1} به ترتیب حالت پنهان قبلی و ورودی فعلی را نشان می دهند (Nazari et al., 2025).

در تمامی مدل های مبتنی بر گراف، ساختار شبکه شامل دو لایه گراف کانولوشنی (GCN) بود که به ترتیب دارای ۶۴ و ۳۲ واحد پنهان بودند. پس از هر لایه، تابع فعال سازی ReLU به منظور افزایش توانایی مدل در یادگیری روابط غیرخطی مورد استفاده قرار گرفت. همچنین برای جلوگیری از بیش برازش، نرخ dropout برابر با ۰/۲ در لایه های میانی اعمال شد. در مدل ترکیبی GCN-LSTM، خروجی لایه های GCN به یک شبکه LSTM دولایه منتقل شد که هر لایه شامل ۶۴ واحد حافظه بود.

در بخش LSTM از تابع فعال سازی تانژانت هیپربولیک (tanh) و دروازه های سیگموئیدی استاندارد استفاده شد. به منظور حفظ پایداری آموزش و کاهش نوسانات گرادیان، dropout بازگشتی (recurrent dropout) برابر با ۰/۲ نیز در لایه های LSTM اعمال شد. فرایند آموزش مدل ها با استفاده از بهینه ساز Adam و نرخ یادگیری اولیه ۰/۰۰۱ انجام شد. اندازه batch برابر با ۳۲ و تعداد epoch ها برابر با ۱۰۰۰ در نظر گرفته شد. علاوه بر این، برای جلوگیری از بیش برازش و انتخاب بهترین مدل، از روش توقف زود هنگام (Early Stopping) با patience برابر با ۱۵ epoch بر اساس خطای مجموعه اعتبارسنجی استفاده شد.

در تمامی آزمایش ها، بذره های تصادفی (random seeds) برابر با ۴۲ تنظیم شدند تا قابلیت تکرارپذیری نتایج تضمین شود. لازم به ذکر است که انتخاب این تنظیمات بر اساس مطالعات پیشین در حوزه یادگیری عمیق مکانی-زمانی و همچنین آزمون و خطای اولیه جهت دستیابی به تعادل مناسب میان دقت پیش بینی و پایداری مدل انجام شده است.

این ویژگی ها به شبکه حافظه بلند مدت-کوتاه (LSTM) وارد می شوند تا پویایی زمانی نوسانات آب زیرزمینی مدلسازی شود. شبکه عصبی حافظه بلند مدت-کوتاه نیز نوعی شبکه عصبی بازگشتی تخصصی که برای رفع محدودیت های RNN^۱ های سنتی در مدلسازی وابستگی های بلند مدت در داده های دنباله دار طراحی شده است.

برخلاف RNN های معمولی که در طی آموزش با مشکل ناپدید شدن یا انفجار گرادیان روبه رو هستند، LSTM با معرفی سازوکار دروازه ای^۲ و یک حالت حافظه اضافی موسوم به حالت سلولی^۳ جریان اطلاعات را در گام های زمانی مختلف تنظیم می کند. این معماری امکان حفظ گزینشی یا فراموشی ویژگی های زمانی را فراهم می سازد و آن را به گزینه ای مناسب برای تحلیل داده های سری زمانی تبدیل می کند. واحد LSTM شامل سه سازوکار دروازه ای تطبیقی است. دروازه ورودی، دروازه فراموشی و دروازه خروجی که به صورت جمعی وضعیت سلولی را کنترل می کنند.

هر دروازه از تابع فعال سازی سیگموئید (σ) استفاده می کند تا مقادیری بین صفر و یک تولید نماید که نشان دهنده میزان نگهداری یا سرکوب اطلاعات است. روابط ریاضی که عملکرد واحد LSTM را در گام زمانی t توصیف می کنند، به صورت زیر تعریف می شوند. دروازه فراموشی (Forget Gate) تعیین می کند کدام اطلاعات از حالت سلولی حذف یا فراموش شوند.

$$f_t = \sigma(W_f \cdot [h_{t-1}] + b_f) \quad (8)$$

دروازه ورودی (Input Gate): مشخص می کند کدام اطلاعات جدید در حالت سلولی ذخیره شوند.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (9)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (10)$$

به روزرسانی حالت سلولی (Cell State Update): حالت سلولی پیشین (c_{t-1}) را با مقادیر پیشنهادی جدید ($\tilde{c}_t$) ترکیب می کند.

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (11)$$

دروازه خروجی (Output Gate): میزان اطلاعاتی را که به حالت پنهان بعدی (h_t) منتقل می شود، کنترل می کند.

³ Cell State

⁴ Element-Wise Multiplication

¹ Recurrent Neural Network

² Gating Mechanism

نتایج و بحث

شکل ۲، نتایج مربوط به مدل شبکه عصبی ترسیمی پایه (GNN) را در شبیه‌سازی سطح آب زیرزمینی نشان می‌دهد و شامل مجموعه‌ای جامع از تحلیل‌های زمانی، آماری و احتمالاتی است. بررسی دقیق بخش سری زمانی سازگاری نسبی بین داده‌های مشاهده‌شده و مقادیر شبیه‌سازی‌شده نشان می‌دهد که مدل GNN قادر است ساختار عمومی سیستم هیدروژئولوژیکی را یاد بگیرد و تغییرات میان‌مدت و بلندمدت را به‌طور مناسب دنبال کند. نمودار پراکندگی (Correlation Scatter Plot) نیز این موضوع را تأیید می‌کند. اگرچه بخش عمده‌ای از نقاط حول خط مرجع ۱:۱ قرار گرفته‌اند و این امر نشان‌دهنده وجود همبستگی مثبت و نسبتاً قوی بین داده‌های مشاهده‌شده و شبیه‌سازی‌شده است، اما فاصله تعدادی از نقاط از خط ایده‌آل بیانگر خطای قابل توجه مدل در برخی محدوده‌های مقداری است. مقدار ضریب تعیین R^2 برابر با ۰/۶ نشان می‌دهد که مدل حدود ۶۰ درصد از واریانس داده‌های واقعی را توضیح می‌دهد که بیانگر عملکرد متوسط رو به بالا است، اما همچنان حاکی از آن است که بخشی از پیچیدگی‌های سیستم توسط مدل بازنمایی نشده باقی مانده است.


این مقدار R^2 معمولاً برای مدل‌هایی که بر پایه ساختارهای ترسیمی و روابط مکانی هستند قابل انتظار است، زیرا این مدل‌ها بیشتر بر ساختارهای وابستگی مکانی تمرکز دارند و ممکن است الگوهای زمانی پیچیده را به‌طور کامل استخراج نکنند. توزیع خطاها (Residuals) نیز درک عمیق‌تری از کیفیت عملکرد مدل فراهم می‌کند. هیستوگرام باقی‌مانده‌ها نشان می‌دهد که اگرچه خطاها به‌طور تقریبی حول صفر توزیع شده‌اند، اما دامنه پراکندگی آنها نسبتاً وسیع است. این موضوع با مقادیر RMSE برابر ۰/۶۲۵ متر و MAE برابر ۰/۴۹۸ متر سازگار است که بیانگر وجود خطای متوسط تا نسبتاً زیاد در پیش‌بینی مقادیر سطح آب زیرزمینی است.

شکل منحنی چگالی احتمال نیز نشان می‌دهد که خطاها کاملاً نرمال نیستند و مقادیر مثبت اندکی بر توزیع غالب هستند، موضوعی که با مشاهده تمایل مدل به بیش‌برآورد (Overestimation) در بخش‌هایی از

سری زمانی همخوانی دارد. شاخص NSE برابر با ۰/۵۲۹ نیز نشان می‌دهد که مدل نسبت به مدل پایه (میانگین تاریخی) عملکرد بهتری دارد، اما این مقدار فاصله قابل توجهی با عملکرد ایده‌آل (نزدیک ۱) دارد و نشان می‌دهد که مدل در بازتولید دقیق روندهای کوتاه‌مدت و جزئیات رفتاری سیستم محدودیت‌هایی دارد. مقدار KGE برابر با ۰/۶۰۰ نیز حاکی از عملکرد متوسط مدل در سه مؤلفه همبستگی، بایاس و واریانس است. نمودار تابع توزیع تجمعی تجربی (ECDF) نیز اختلاف احتمالاتی میان توزیع واقعی و شبیه‌سازی‌شده سطح آب زیرزمینی را نشان می‌دهد. در بازه‌های پایین‌تر سطح آب (مثلاً کمتر از دو متر)، منحنی مدل نسبت به داده‌های مشاهده‌ای انحراف دارد و این موضوع نشان می‌دهد که مدل در بازنمایی فراوانی رخدادهای حدی شامل افت‌های شدید، اوج‌های ناگهانی سطح آب زیرزمینی و تغییرات سریع زمانی عملکرد ضعیف‌تری دارد.

این اختلافات در بخش‌هایی از توزیع می‌تواند ناشی از محدودیت‌های معماری شبکه‌های ترسیمی باشد که عمدتاً بر استخراج وابستگی‌های مکانی تمرکز دارند و ممکن است دینامیک زمانی پیچیده و غیرخطی سری زمانی را به اندازه کافی بازنمایی نکنند. به‌طور کلی، نتایج نشان می‌دهد که مدل GNN توانسته است ساختار کلی و روندهای بلندمدت را با دقت قابل‌قبول بازسازی کند و عملکرد آن در معیارهای کمی نظیر $R^2=0.600$ ، $RMSE=0.625$ و $NSE=0.529$ ، $KGE=0.600$ و $MAE=0.498$ نشان‌دهنده آن است که این مدل قادر به درک بخشی از رفتار سیستم بوده اما محدودیت‌هایی در بازنمایی دقیق نوسانات، رخدادهای حدی و وابستگی‌های زمانی پیچیده دارد.

این نتایج نشان می‌دهند که اگرچه استفاده از شبکه‌های ترسیمی برای مدلسازی سامانه‌های هیدروژئولوژیکی کاربردی و مفید است، اما برای دستیابی به عملکرد دقیق‌تر نیاز به بهره‌گیری از معماری‌های پیشرفته‌تر نظیر ترکیب مدل‌های GNN با LSTM، GRU و Transformers یا روش‌های هیبریدی وجود دارد تا بتوان ساختارهای زمانی و مکانی را به‌صورت همزمان و بهینه استخراج کرد.



شکل ۲- ارزیابی عملکرد مدل شبکه عصبی ترسیمی (GNN) در پیش‌بینی سطح آب زیرزمینی
Fig. 2. Performance evaluation of the Graph Neural Network (GNN) model in predicting groundwater level

اختصاص می‌دهد و بدین ترتیب اطلاعات مؤثرتر را تقویت می‌کند.


در بخش تحلیل خطا، هیستوگرام باقی‌مانده‌ها نشان‌دهنده کاهش پراکندگی خطاها نسبت به مدل GNN است. توزیع خطاها بیشتر حول مقدار صفر متمرکز شده و این امر بیانگر کاهش بایاس و افزایش دقت پیش‌بینی است. شاخص‌های کمی نیز این موضوع را تأیید می‌کنند، به‌گونه‌ای که مقدار RMSE برابر با ۰/۴۷۰ متر و مقدار MAE برابر با ۰/۵۹۰ متر و مقدار NSE برابر با ۰/۵۸۰ شده است. این مقادیر نسبت به مدل قبلی کاهش یافته و نشان‌دهنده توانایی بالاتر مدل در کاهش اندازه خطاهاست. افزون بر این، مقدار KGE برابر با ۰/۶۵۰ نشان می‌دهد که دقت مدل نسبت به مدل مرجع (میانگین تاریخی) به‌طور محسوسی بیشتر است و مدل توانسته روندهای زمانی را با دقت مناسبی بازسازی کند. همچنین مقدار KGE برابر با ۰/۶۵۰ نشان‌دهنده بهبود مطلوب در مؤلفه‌های بایاس، واریانس و همبستگی است. در نمودار ECDF نیز مشاهده می‌شود که منحنی مربوط به مدل GAT به خطوط ECDF داده‌های مشاهده‌شده نزدیک‌تر شده است. این رفتار نشان‌دهنده آن است که مدل توانسته است توزیع احتمالاتی داده‌های واقعی را بهتر بازسازی کند و ساختار آماری سری زمانی را دقیق‌تر بیاموزد. در مجموع، می‌توان نتیجه گرفت که استفاده از مکانیسم توجه در چارچوب شبکه‌های ترسیمی منجر به بهبود قابل ملاحظه‌ای در عملکرد مدل شده است.

شکل ۳ نتایج مربوط به مدل شبکه توجه-ترسیمی توسعه یافته است، نشان‌دهنده بهبود قابل توجه در مقایسه با مدل پایه GNN است. همان‌طور که در هیدروگراف سری زمانی مشاهده می‌شود، مدل GAT توانسته است تغییرات سطح آب زیرزمینی را با دقت بیشتری بازسازی کند. همپوشانی بیشتر میان مقادیر مشاهده‌شده و مقادیر مدل‌شده بیانگر آن است که مدل نه‌تنها روندهای بلندمدت را به‌خوبی شناسایی کرده، بلکه در بازنمایی نوسانات میان‌مدت نیز عملکرد دقیق‌تری ارائه داده است. این بهبود به‌ویژه در دوره‌هایی که رفتار سیستم از نوسانات متوسط برخوردار است، بیشتر قابل مشاهده بوده و نشان می‌دهد که مکانیزم توجه توانسته وزن‌دهی مؤثرتری به گره‌های کلیدی در ساختار گراف اعمال کند.

نمودار پراکنش نیز این بهبود عملکرد را تأیید می‌کند. تراکم بیشتر نقاط حول خط مرجع ۱:۱ نشان می‌دهد که مدل GAT قادر بوده است مقدارهای مشاهده‌شده را با دقت بالاتری تخمین بزند. مقدار $R^2=0/650$ نشان می‌دهد که این مدل توانسته حدود ۶۵ درصد از واریانس داده‌های واقعی را توضیح دهد، که نسبت به مدل پایه یک پیشرفت محسوب می‌شود. این افزایش در ضریب تعیین را می‌توان به توانایی مکانیزم توجه در تفکیک اهمیت نسبی گره‌های همسایه نسبت داد. زیرا GAT برخلاف GNN، کلیه گره‌های مجاور را با یک وزن یکسان در نظر نمی‌گیرد، بلکه بر اساس اهمیت هر گره در ساختار مکانی، وزن‌های متفاوتی

مکانی، در نظر گرفتن وابستگی‌های زمانی بلندمدت و کوتاه‌مدت نقش اساسی دارد. بنابراین، استفاده از مدل‌های ترکیبی که در آنها GAT با ساختارهای زمانی مانند LSTM، GRU یا Transformers ترکیب شود، می‌تواند مسیر مناسبی برای ارتقای بیشتر عملکرد مدل در آینده باشد.

مدل GAT توانسته است روابط پیچیده‌تری را در ساختار گراف استخراج کند و نسبت به مدل پایه دقت بیشتری در پیش‌بینی سطح آب زیرزمینی ارائه دهد. با این حال، عملکرد مدل همچنان به سطح ایده‌آل نرسیده است. این موضوع نشان می‌دهد که در مدلسازی سری‌های زمانی هیدرولوژیکی، علاوه بر استخراج روابط



شکل ۳- ارزیابی عملکرد مدل شبکه توجه-ترسیمی (GAT) در پیش‌بینی سطح آب زیرزمینی

Fig. 3. Performance evaluation of the Graph Attention Network (GAT) model in predicting groundwater level

می‌کند که تقریباً ۸۰ درصد از واریانس داده‌های مشاهده‌شده توسط مدل توضیح داده می‌شود. این مقدار نه تنها بالاتر از مدل‌های قبلی است، بلکه نشان می‌دهد عملیات پیچشی روی گراف توانسته الگوهای مکانی را در سطحی عمیق‌تر و مؤثرتر استخراج کند.

تحلیل توزیع خطاها نیز نشان‌دهنده برتری مدل GCN است. باقی‌مانده‌ها پراکندگی بسیار کمتری نسبت به دو مدل قبل دارند و عمدتاً حول مقدار صفر متمرکز شده‌اند که نشانه نبود بایاس سیستماتیک و رفتار پایدار مدل است. شاخص‌های خطا نیز این یافته را تأیید می‌کنند (RMSE = ۰/۴۷۸ متر و MAE = ۰/۳۸۴ متر). این مقادیر نشان‌دهنده کاهش قابل توجه خطای پیش‌بینی نسبت به GNN و GAT هستند. افزون بر این، مقدار NSE = ۰/۷۲۴ نشان می‌دهد که مدل توانسته رفتار زمانی سیستم را با دقت بسیار بالاتری نسبت به مدل مرجع (میانگین تاریخی) بازسازی کند.


مقدار KGE = ۰/۸۴۴ نیز نشان می‌دهد که مدل در سه مؤلفه اساسی همبستگی، بایاس و بازنمایی واریانس عملکرد بسیار مطلوبی ارائه کرده است. نمودار ECDF نیز تطابق آماری بسیار قوی بین داده‌های مدل‌شده و

شکل ۴ نتایج مربوط به مدل شبکه ترسیمی- پیچشی توسعه یافته است، نشان می‌دهد که این مدل نسبت به دو معماری قبلی GNN و GAT عملکرد به مراتب بهتری در شبیه‌سازی سطح آب زیرزمینی ارائه داده است. مقادیر مدل‌شده تطابق بسیار بالایی با داده‌های مشاهده‌شده دارند و منحنی پیش‌بینی به‌طور دقیق نوسانات و روندهای زمانی سیستم را دنبال کرده است. همپوشانی نزدیک دو منحنی و کاهش چشمگیر اختلافات در اغلب بخش‌های سری زمانی حاکی از آن است که مدل GCN توانسته است دینامیک‌های غالب آبخوان را با دقت بالایی بازنمایی کند.

این سطح از تطابق نشان می‌دهد که اعمال شبکه پیچشی روی ساختار گراف توانسته ویژگی‌های مکانی- ساختاری را بسیار مؤثرتر استخراج کند. نمودار همبستگی نیز به‌وضوح برتری مدل GCN را نسبت به دو مدل قبلی تأیید می‌کند. تمرکز بیشتر نقاط در اطراف خط یک‌به‌یک و کاهش پراکندگی افقی-عمودی نقاط نشان می‌دهد که خطاهای مدل‌شده محدودتر شده‌اند و مدل توانسته مقادیر واقعی را با دقت بالا تخمین بزند. مقدار ضریب تعیین $R^2 = 0.797$ بیان

بیان می‌کند که مدل توانایی بازنمایی رخداد‌های نادر و تغییرات شدید سطح آب را نیز دارد. عملکرد مطلوب مدل GCN اهمیت استفاده از روش‌های پیشرفته‌تر یادگیری ترسیمی را در مدلسازی سیستم‌های پیچیده هیدرولوژیکی به‌خوبی برجسته می‌کند.

مشاهده‌شده را نشان می‌دهد. انطباق نزدیک دو منحنی در کل بازه مقادیر بیانگر آن است که مدل نه تنها روندها و مقادیر زمانی را درست پیش‌بینی کرده، بلکه ساختار توزیع آماری سطح آب زیرزمینی را نیز به‌طور مؤثر آموخته است. نزدیکی دو منحنی حتی در مقادیر حدی



شکل ۴- ارزیابی عملکرد مدل شبکه پیچشی-ترسیمی (GCN) در پیش‌بینی سطح آب زیرزمینی

Fig. 4. Performance evaluation of the Graph Convolutional Network (GCN) model in predicting groundwater level

محسوسی محدودتر و متمرکزتر از مدل‌های قبلی هستند. هیستوگرام خطاها، پهنای بسیار کم و تقارن نزدیک به نرمال را نشان می‌دهد که حاکی از نبود بایاس و پایداری مدل است. مقادیر $RMSE = 0.478$ و $MAE = 0.384$ کمترین مقدار در میان تمامی مدل‌ها هستند، که نشان‌دهنده کاهش قابل توجه خطای پیش‌بینی است. همچنین مقدار $NSE = 0.724$ نشان می‌دهد که مدل رفتار زمانی سیستم را با دقت بسیار بالا و فراتر از مدل مرجع (میانگین تاریخی) بازسازی کرده است.

مقدار $KGE = 0.844$ نیز عملکرد بسیار مناسب مدل را از نظر سه مؤلفه اصلی همبستگی، بایاس و بازنمایی واریانس تأیید می‌کند. نمودار ECDF نیز انطباق آماری عالی میان توزیع تجمعی مقادیر شبیه‌سازی‌شده و داده‌های واقعی را نشان می‌دهد. دو منحنی تقریباً به‌طور کامل بر یکدیگر منطبق هستند، که بیانگر آن است که مدل توانسته توزیع آماری سطح آب زیرزمینی، از جمله مقادیر میانی و رخداد‌های حدی، را با دقت بالا بازسازی کند.


برتری این مدل را می‌توان به ماهیت ترکیبی و مکمل دو بخش GCN و LSTM نسبت داد. بخش GCN قادر است ویژگی‌های فضایی و روابط ساختاری بین نقاط مشاهده‌ای آبخوان را به‌طور مؤثر استخراج

شکل ۵، نتایج مدل ترکیبی شبکه ترسیمی-پیچشی (GCN) و شبکه بازگشتی LSTM را نشان می‌دهد. مدلی که بالاترین عملکرد را در میان تمامی معماری‌های بررسی‌شده ارائه داده است. در هیدروگراف سری زمانی، همپوشانی تقریباً کامل میان داده‌های مشاهده‌شده و مقادیر شبیه‌سازی‌شده قابل مشاهده است. این تطابق نزدیک نشان می‌دهد که مدل نه تنها روند کلی تغییرات سطح آب زیرزمینی، بلکه نوسانات کوتاه‌مدت و بلندمدت سیستم را با دقت بسیار بالا بازسازی کرده است. حضور اختلافات بسیار ناچیز در اکثر بازه‌های زمانی بیانگر آن است که مدل توانسته الگوهای پیچیده دینامیک آبخوان را به‌طور کامل فراگیرد و بازتولید کند.

نمودار همبستگی نیز این موضوع را تأیید می‌کند. تمرکز شدید نقاط در اطراف خط یک‌به‌یک نشان‌دهنده دقت بسیار بالای پیش‌بینی‌ها است. مقدار $R^2 = 0.797$ که نزدیک به ۹۰ درصد واریانس داده‌های واقعی را توضیح می‌دهد، بالاترین مقدار در میان تمامی مدل‌ها است. این مقدار نشان می‌دهد که مدل ترکیبی GCN-LSTM توانسته وابستگی‌های پیچیده و چندبعدی داده‌ها را مؤثرتر از سایر مدل‌ها استخراج کند. تحلیل توزیع خطاها نشان می‌دهد که باقی‌مانده‌ها به‌طور

کند. از طرف دیگر، LSTM وابستگی‌های زمانی بلندمدت و الگوهای پویای سیستم را یاد می‌گیرد. ادغام این دو قابلیت باعث شده است که مدل بتواند به‌طور همزمان ساختار فضایی و دینامیک زمانی داده‌ها را یاد بگیرد. این یکپارچگی موجب شده پیش‌بینی‌های مدل دقیق‌تر، پایدارتر و واقع‌بینانه‌تر از مدل‌های تک‌بعدی یا مبتنی بر گراف ساده باشد. در مجموع، عملکرد مدل

از طرف دیگر، LSTM وابستگی‌های زمانی بلندمدت و الگوهای پویای سیستم را یاد می‌گیرد. ادغام این دو قابلیت باعث شده است که مدل بتواند به‌طور همزمان ساختار فضایی و دینامیک زمانی داده‌ها را یاد بگیرد. این یکپارچگی موجب شده پیش‌بینی‌های مدل دقیق‌تر، پایدارتر و واقع‌بینانه‌تر از مدل‌های تک‌بعدی یا مبتنی بر گراف ساده باشد. در مجموع، عملکرد مدل



شکل ۵- ارزیابی عملکرد مدل شبکه پیچشی-ترسیمی (GCN) - حافظه بلندمدت کوتاه (LSTM) در پیش‌بینی سطح آب زیرزمینی

Fig. 5. Performance evaluation of the Graph Convolutional Network-Long Short-Term Memory (GCN-LSTM) model in predicting groundwater level

به‌منظور ارزیابی جامع عملکرد مدل‌های یادگیری عمیق شامل GAT، GNN، GCN و GCN-LSTM، مجموعه‌ای از شاخص‌های استاندارد شامل ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، ضریب کارایی نش-ساتکلیف (NSE)، شاخص (KGE) و میانگین قدر مطلق خطا (MAE) مورد استفاده قرار گرفت تا توانایی مدل‌ها در بازسازی الگوهای داده، دقت پیش‌بینی و میزان خطای باقیمانده به‌طور هم‌زمان بررسی شود. برای تحلیل چندبعدی عملکرد، نتایج در قالب یک داشبورد تحلیلی شامل چهار نمایش مکمل ارائه شد.

نمودار راداری (پنل A) نشان داد که مدل ترکیبی GCN-LSTM با مقادیر $R^2 = 0.896$ ، RMSE = 0.336، NSE = 0.864، KGE = 0.904 و MAE = 0.269، بیشترین سطح پوشش چندمعیاره را دارد و در تمامی شاخص‌ها بهترین عملکرد را نشان می‌دهد. این موضوع بیانگر آن است که ادغام ساختار پیچشی-ترسیمی با توانایی مدلسازی وابستگی‌های زمانی در LSTM، موجب بازنمایی دقیق‌تر ویژگی‌های فضایی و پویایی‌های زمانی شده است. پس از آن، مدل GCN با مقادیر

به‌منظور ارزیابی جامع عملکرد مدل‌های یادگیری عمیق شامل GAT، GNN، GCN و GCN-LSTM، مجموعه‌ای از شاخص‌های استاندارد شامل ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، ضریب کارایی نش-ساتکلیف (NSE)، شاخص (KGE) و میانگین قدر مطلق خطا (MAE) مورد استفاده قرار گرفت تا توانایی مدل‌ها در بازسازی الگوهای داده، دقت پیش‌بینی و میزان خطای باقیمانده به‌طور هم‌زمان بررسی شود. برای تحلیل چندبعدی عملکرد، نتایج در قالب یک داشبورد تحلیلی شامل چهار نمایش مکمل ارائه شد.

نمودار راداری (پنل A) نشان داد که مدل ترکیبی GCN-LSTM با مقادیر $R^2 = 0.896$ ، RMSE = 0.336، NSE = 0.864، KGE = 0.904 و MAE = 0.269، بیشترین سطح پوشش چندمعیاره را دارد و در تمامی شاخص‌ها بهترین عملکرد را نشان می‌دهد. این موضوع بیانگر آن است که ادغام ساختار پیچشی-ترسیمی با توانایی مدلسازی وابستگی‌های زمانی در LSTM، موجب بازنمایی دقیق‌تر ویژگی‌های فضایی و پویایی‌های زمانی شده است. پس از آن، مدل GCN با مقادیر


مانند RMSE و MAE که مقادیر کمتر مطلوب‌تر هستند، نرمال‌سازی به صورت معکوس انجام گرفت. پس از نرمال‌سازی، شاخص GPI از طریق میانگین وزنی شاخص‌های نرمال‌شده محاسبه شد.

در نسخه حاضر مطالعه، به منظور جلوگیری از اعمال سوگیری ذهنی در اهمیت شاخص‌ها، وزن یکسان برای تمامی معیارها در نظر گرفته شد. به عبارت دیگر، هر یک از شاخص‌های آماری سهم برابری در محاسبه مقدار نهایی GPI داشتند. این انتخاب با هدف ایجاد یک ارزیابی متعادل میان دقت، پایداری، بازنمایی واریانس و میزان خطای مدل‌ها انجام شد.

علاوه بر این، برای بررسی پایداری نتایج، آزمون‌های حساسیت اولیه با تغییر محدود وزن شاخص‌ها انجام شد. نتایج نشان داد که اگرچه مقادیر مطلق GPI با تغییر وزن‌ها اندکی تغییر می‌کند، اما رتبه‌بندی کلی مدل‌ها، به‌ویژه برتری مدل LSTM-GCN نسبت به سایر معماری‌ها، پایدار باقی می‌ماند. این موضوع نشان می‌دهد که نتیجه‌گیری‌های اصلی پژوهش وابستگی شدیدی به انتخاب خاص وزن‌ها نداشته و از پایداری نسبی برخوردار است.

RMSE و افزایش R^2 را برقرار کرده است. ماتریس حبابی نرمال‌شده (پنل C) نیز این نتایج را تأیید می‌کند. به گونه‌ای که بزرگ‌ترین و گرم‌ترین حباب‌ها متعلق به GCN-LSTM است و نشان می‌دهد که این مدل در تمام شاخص‌ها برتر است، در حالی که مدل GNN کوچک‌ترین حباب‌ها را دارد. نهایتاً، شاخص عملکرد جهانی (GPI) در پنل D نشان می‌دهد که GCN-LSTM با مقدار ۱/۰۰ بهترین عملکرد کلی را دارد، در حالی که GCN با مقدار ۰/۶۱ در رتبه دوم و مدل‌های GAT (۰/۱۵) و GNN (۰/۰۰) در رتبه‌های بعدی قرار دارند. شاخص عملکرد کلی^۱ به منظور ارائه یک معیار تجمیعی برای مقایسه همزمان عملکرد مدل‌ها در چندین شاخص آماری محاسبه شد.

در این پژوهش، ابتدا تمامی شاخص‌های ارزیابی شامل (R^2) ، NSE، KGE، RMSE و MAE به صورت خطی نرمال‌سازی شدند تا مقادیر آنها در یک بازه قابل مقایسه قرار گیرد. برای شاخص‌های سودمند^۲ مانند (R^2) ، NSE و KGE که مقادیر بزرگ‌تر نشان‌دهنده عملکرد بهتر هستند، از رابطه نرمال‌سازی مستقیم استفاده شد؛ در حالی که برای شاخص‌های هزینه‌محور^۳



شکل ۶- مقایسه عملکرد مدل‌های GNN، GAT، GCN و GCN-LSTM بر اساس شاخص‌های آماری و گرافیکی

Fig. 6. Comparison of the performance of GNN, GAT, GCN, and GCN-LSTM models based on statistical and graphical indicators

سری زمانی به کار می‌رود و قادر است مشخص کند که آیا اختلاف مشاهده‌شده در خطاهای پیش‌بینی دو مدل از نظر آماری معنی‌دار است یا خیر. در این پژوهش، آزمون DM بر اساس سری خطاهای جفتی مدل

به منظور بررسی معنی‌داری آماری تفاوت عملکرد مدل‌ها، از آزمون Diebold–Mariano (DM) بر روی خطاهای پیش‌بینی مدل‌ها استفاده شد. این آزمون به طور گسترده برای مقایسه دقت پیش‌بینی مدل‌های

³ Cost-based

¹ Global Performance Index (GPI)

² Benefit-based

زیرزمینی را دارد و یک جایگزین محاسباتی کارآمد برای مدیریت آب زیرزمینی در محیط‌های هیدروژئولوژیکی پیچیده ارائه می‌کند. بهبود عملکرد مدل GAT نسبت به GNN نشان داد که مکانیزم توجه می‌تواند اهمیت نسبی گره‌ها را بهتر تفکیک کرده و بخشی از نویز موجود در روابط مکانی را کاهش دهد.

با این حال، نبود سازوکار مؤثر برای یادگیری وابستگی‌های زمانی عمیق، همچنان عملکرد این مدل را محدود کرد. این نتیجه با مطالعه Ma et al., (2026) همسو است که نشان دادند مدل H-STGAT با تلفیق وابستگی‌های فضایی، زمانی و دوره‌ای عملکرد دقیق‌تری ارائه می‌دهد. در ادامه، مدل GCN با استخراج مؤثرتر الگوهای ساختاری و فضایی گراف، موجب کاهش خطا و افزایش شاخص‌های R^2 و NSE شد.

نتایج این بخش با یافته‌های Chen et al., (2025) درباره برتری مدل‌های فضایی-زمانی مبتنی بر STGCN-M نسبت به LSTM و GRU مطابقت دارد. با این وجود، نبود مکانیزم حافظه در GCN همچنان باعث ضعف در بازنمایی تغییرات زمانی و رخدادهای ناگهانی می‌شود. در نهایت، ترکیب GCN و LSTM بهترین عملکرد را در میان تمامی مدل‌ها ارائه داد، زیرا توانست وابستگی‌های فضایی و زمانی را به‌صورت همزمان یاد بگیرد. این نتیجه با پژوهش Wang et al., (2024) نیز همخوانی دارد.

شکل ۷ میزان خطای پیش‌بینی سطح آب زیرزمینی در پیرومترهای مختلف را برای یک ماه با استفاده از مدل منتخب GCN-LSTM به‌عنوان مثال نشان می‌دهد. نتایج بیانگر آن است که مقدار خطا در اغلب پیرومترها در بازه قابل قبول و نسبتاً پایین قرار دارد که نشان‌دهنده دقت مناسب مدل در شبیه‌سازی رفتار مکانی-زمانی آب زیرزمینی است. با این حال، اختلاف جزئی میان پیرومترها مشاهده می‌شود که می‌تواند ناشی از تفاوت در شرایط هیدروژئولوژیکی، کیفیت داده‌های ورودی، نوسانات محلی سطح آب و یا میزان تأثیرپذیری هر پیرومتر از عوامل محیطی و بهره‌برداری باشد. کم بودن پراکندگی خطاها در اکثر نقاط نشان می‌دهد که مدل GCN-LSTM توانسته

LSTM-GCN و سایر مدل‌های مقایسه‌ای شامل GAT، GNN و GCN اجرا شد و تابع زیان بر پایه مربع خطاها^۱ تعریف شد.

نتایج آزمون نشان داد که مدل LSTM-GCN در مقایسه با سایر معماری‌ها دارای کاهش معنی‌دار خطای پیش‌بینی در سطح اطمینان ۹۵ درصد است ($p < 0.05$). این یافته بیانگر آن است که بهبود مشاهده‌شده در شاخص‌هایی نظیر RMSE، NSE و KGE صرفاً ناشی از نوسانات تصادفی یا شرایط اولیه آموزش نبوده، بلکه از برتری واقعی مدل ترکیبی در یادگیری همزمان وابستگی‌های فضایی و زمانی ناشی می‌شود. همچنین نتایج آزمون نشان داد که اختلاف عملکرد میان GCN و GAT نسبت به اختلاف میان LSTM-GCN و سایر مدل‌ها کمتر بوده است که این موضوع نقش مؤلفه زمانی LSTM را در افزایش دقت پیش‌بینی برجسته می‌سازد.


نتایج حاصل از ارزیابی مدل‌های گراف‌محور و ترکیبی نشان داد که دقت و قابلیت اطمینان پیش‌بینی سطح آب زیرزمینی به‌شدت وابسته به نحوه استخراج و یکپارچه‌سازی اطلاعات فضایی و زمانی است. عملکرد مدل پایه GNN نشان داد که اگرچه شبکه‌های عصبی ترسیمی قادرند ساختار مکانی سیستم را تا حد قابل‌قبولی بازنمایی کنند، اما نبود سازوکارهای یادگیری توالی باعث می‌شود که این مدل‌ها در بازتولید نوسانات سریع، رخدادهای حادی و الگوهای زمانی پیچیده دچار محدودیت شوند، مطالعات انجام شده توسط Taccari et al., (2024) نشان داد چارچوب مبتنی بر گراف امکان ادغام پیوستگی فضایی و پویایی‌های زمانی را فراهم می‌کند و بدین ترتیب، برهم‌کنش‌های پیچیده در سامانه آب زیرزمینی را به‌خوبی ثبت و مدل‌سازی می‌کند.

مقادیر R^2 ، RMSE و NSE در این مدل بیانگر آن بود که اطلاعات مکانی به‌تنهایی برای مدل‌سازی دقیق دینامیک آبخوان کافی نیست و یادگیری وابستگی‌های زمانی نقش تعیین‌کننده‌ای دارد، مطابق نتایج Liang et al., (2025) نتایج نشان می‌دهند که این چارچوب توانایی ارائه پیش‌بینی‌های سریع و قابل اعتماد تراز آب

¹ Squared Error Loss

ایستگاه‌ها حاکی از قابلیت بالای این روش در پیش‌بینی دقیق سطح آب زیرزمینی و کاربرد آن در مدیریت و پایش منابع آب زیرزمینی است.

است و وابستگی‌های فضایی میان پیزومترها و همچنین روند زمانی تغییرات سطح آب زیرزمینی را به خوبی استخراج کند. بنابراین، عملکرد پایدار مدل در اکثر



شکل ۷- میزان خطا در هر یک از پیزومترها با استفاده از روش منتخب (GCN-LSTM)

Fig. 7. Error values in each piezometer using the selected method (GCN-LSTM)

بررسی، نوع داده‌ها و ساختار شبکه پایش وابسته است. بنابراین، تعمیم نتایج به سایر آبخوان‌ها و شرایط هیدروژئولوژیکی نیازمند ارزیابی‌های تکمیلی و تحلیل پایداری مدل در مجموعه داده‌های مختلف خواهد بود. همچنین، اگرچه مدل پیشنهادی ظرفیت مناسبی برای کاربردهای پیش‌بینی دارد، استفاده عملیاتی از آن مستلزم انجام آزمون‌های بیشتر در شرایط زمانی و مکانی متفاوت و بررسی قابلیت تعمیم‌پذیری آن است. با وجود عملکرد مطلوب مدل ترکیبی GCN-LSTM در بازسازی دینامیک سطح آب زیرزمینی، همچنان ظرفیت قابل توجهی برای توسعه معماری‌های پیشرفته‌تر یادگیری عمیق وجود دارد. در مطالعات آینده، استفاده از مدل‌های مکانی-زمانی نوین نظیر AGCRN، STGCN، DCRNN و Graph WaveNet و همچنین مقایسه آنها با مدل‌های قدرتمند سری زمانی غیرگرافایی مانند TCN و Temporal Fusion Transformer (TFT) می‌تواند درک جامع‌تری از نقش وابستگی‌های پیچیده فضایی و زمانی در سامانه‌های آب زیرزمینی فراهم کند. افزون بر این، توسعه ماتریس‌های مجاورت پویا و قابل یادگیری، و وارد کردن ویژگی‌های

نتیجه‌گیری

در این پژوهش، عملکرد مدل‌های GNN، GCN، GAT و مدل ترکیبی GCN-LSTM برای پیش‌بینی سطح آب زیرزمینی در آبخوان کوچصفهان مورد بررسی قرار گرفت. نتایج نشان داد که در نظر گرفتن همزمان روابط مکانی بین چاه‌ها و وابستگی‌های زمانی سری‌های داده می‌تواند موجب بهبود عملکرد مدل در بازسازی تغییرات سطح آب زیرزمینی شود. در این میان، مدل ترکیبی GCN-LSTM نسبت به سایر مدل‌های بررسی‌شده توانایی بیشتری در بازنمایی الگوهای زمانی و مکانی داده‌ها نشان داد. همچنین نتایج بیانگر آن بود که مدل‌های مبتنی بر ساختار گراف مانند GAT و GNN، اگرچه بخشی از ارتباطات مکانی سیستم را یاد می‌گیرند، اما در بازنمایی کامل نوسانات زمانی و تغییرات سریع دارای محدودیت هستند.

در مقابل، استفاده از ساختار پیچشی در GCN و ترکیب آن با LSTM موجب بهبود استخراج ویژگی‌های فضایی و زمانی شد. با وجود عملکرد مناسب مدل پیشنهادی در این مطالعه، نتایج به شرایط آبخوان مورد

فیزیکی یال‌ها شامل تراوایی، جهت جریان زیرزمینی، ارتباط رودخانه-آبخوان و ساختارهای زمین‌شناسی، می‌تواند بازنمایی واقع‌بینانه‌تری از رفتار هیدروژئولوژیکی آبخوان ارائه دهد. انتظار می‌رود ترکیب این رویکردها با داده‌های اقلیمی، سنجش از دور و مدل‌های فیزیک‌مبنا، مسیر مؤثری برای توسعه سامانه‌های پیش‌بینی هوشمند، پایدار و قابل اعتماد در مدیریت منابع آب زیرزمینی باشد.

تشکر و قدردانی

تعارض منافع

در این مقاله تضاد منافی وجود ندارد و این مسأله مورد تایید همه نویسندگان است.

منابع مورد استفاده

- Aslam, R.A., Shrestha, S., Pandey, V.P., 2018. Groundwater vulnerability to climate change: A review of the assessment methodology. *Sci. Total Environ.* 612, 853–875. <https://doi.org/10.1016/j.scitotenv.2017.08.237>.
- Bai, T., Tahmasebi, P., 2021. Sequential gaussian simulation for geosystems modeling: A machine learning approach. *Geosci. Front.* 13(1), 101258. <https://doi.org/10.1016/j.gsf.2021.101258>.
- Bai, T., Tahmasebi, P., 2023. Graph neural network for groundwater level forecasting. *J. Hydrol.* 616, 128792. <https://doi.org/10.1016/j.jhydrol.2022.128792>.
- Chamanpira, G., Zehtabian, G., Ahmadi, H., Melkian, A., 2014. Investigating the impact of drought on groundwater resources for optimal exploitation management: case study of Alishtar plain. *Water. Engin. Manage.* 6(1), 10–20. <https://doi.org/10.22092/ijwmse.2014.101733>.
- Chen, J., Dai, Z., Yang, Z., Pan, Y., Zhang, X., Wu, J., Reza Soltanian, M., 2021. An improved tandem neural network architecture for inverse modeling of multicomponent reactive transport in porous media. *Water Resour. Res.* 57(12), e2021WR030595. <https://doi.org/10.1029/2021WR030595>.
- Chen, L., Zhang, D., Xu, J., Zhou, Z., Jin, J., Luan, J., Wulamu, A., 2025. Enhancing the accuracy of groundwater level prediction at different scales using spatio-temporal graph convolutional model. *Earth Sci. Inform.* 18(2), 250. <https://doi.org/10.1007/s12145-024-01502-3>.
- Dudley, R.W., Hodgkins, G.A., Nielsen, M.G., Qi, S.L., 2018. Estimating historical groundwater levels based on relations with hydrologic and meteorological variables in the U.S. glacial aquifer system. *J. Hydrol.* 562, 530–543. <https://doi.org/10.1016/j.jhydrol.2018.05.019>.
- Famiglietti, J.S., 2014. The global groundwater crisis. *Nat. Clim. Change* 4(11), 945–948. <https://doi.org/10.1038/nclimate2425>.
- He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep residual learning for image recognition. *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>.
- Heidari, N., Hedegaard, L., Iosifidis, A., 2022. Graph convolutional networks. In: *Deep Learning for Robot Perception and Cognition* 71–99. <https://doi.org/10.1016/B978-0-32-385787-1.00009-9>.
- Homayounpour, B., Goodarzi, M., Zehtabian, G., Motamed-Vaziri, B., Ahmadi, H., 2022. Evaluating the impact of climate change on groundwater fluctuations in Barkhar plain, Isfahan. *Water. Engin. Manage.* 14(4), 465–480. <https://doi.org/10.22092/ijwmse.2022.353543.1880>.
- Kamrava, S., Sahimi, M., Tahmasebi, P., 2021. Simulating fluid flow in complex porous materials by integrating the governing equations with deep-layered machines. *NPJ Comput. Mater.* 7(1), 1–9. <https://doi.org/10.1038/s41524-021-00598-2>.
- Khorramdel, G.N., Mohammadi, K., Monem, M.J., 2008. Optimization of observation well network for estimation of groundwater balance using double water table fluctuation method. *J. Water Soil* 22(2), 358–370 (in Persian).
- Kilinc, H.C., Apak, S., Ozkan, F., Yurtsever, A., 2025. AH-GCAN-LSTM: Adaptive hybrid graph convolution attention network with LSTM and genetic optimization for hydrological time series forecasting. *Water Resour. Manage.* 39(15), 8293–8312. <https://doi.org/10.1007/s11269-024-03984-2>.
- Li, D., Zhao, W., Hu, J., Zhao, S., Liu, S., 2023. A long-term water quality prediction model for marine ranch based on time-graph convolutional neural network. *Ecol. Indic.* 154, 110782. <https://doi.org/10.1016/j.ecolind.2023.110782>.

- Liang, X.X., Gloaguen, E., Claprood, M., Paradis, D., Lauzon, D., 2025. Graph neural network framework for spatiotemporal groundwater level forecasting. *Math. Geosci.* 57(6), 1071–1093. <https://doi.org/10.1007/s11004-024-10145-1>.
- Lin, X., Lu, Q., Zhao, P., Chen, L., Tang, J., Guan, D., Broyd, T., 2026. Field-theory inspired physics-informed graph neural network for reliable traffic flow prediction under urban flooding. *Reliab. Eng. Syst. Saf.* 265, 111487. <https://doi.org/10.1016/j.ress.2025.111487>.
- Long, D., Yang, W., Scanlon, B.R., Zhao, J., Liu, D., Burek, P., Pan, Y., You, L., Wada, Y., 2020. South-to-North water diversion stabilizing Beijing's groundwater levels. *Nat. Commun.* 11(1), 1–10. <https://doi.org/10.1038/s41467-020-17428-6>.
- Ma, C., Xu, K., Li, Y., Hao, Y., Sun, H., Gao, S., Wang, X., 2026. Heterogeneous spatiotemporal graph attention network for karst spring discharge prediction: Advancing sustainable groundwater management under climate change. *Sustain.* 18(2), 933. <https://doi.org/10.3390/su18020933>.
- Marufinia, E., Sharafati, A., Abooghari, H., Hassanzadeh, Y., 2025. Application of machine learning and deep wavelet algorithms for predicting the Korkorsar River flow in Nowshahr. *Water. Engin. Manage.* 17(4), 424–447. <https://doi.org/10.22092/ijwmse.2025.369325.2115>.
- Minnig, M., Moeck, C., Radny, D., Schirmer, M., 2018. Impact of urbanization on groundwater recharge rates in Dübendorf, Switzerland. *J. Hydrol.* 563, 1135–1146. <https://doi.org/10.1016/j.jhydrol.2017.09.058>.
- Mirmoshtaghi, M., Amirnejad, R., Khaledian, M.R., 2012. Evaluating of water quality of Sefid-Rood and zoning by water quality index NSFQI and OWQI. *J. Wetl. Ecobiol.* 3(9), 23–34 (in Persian).
- Nazari, A., Jamshidi, M., Roozbahani, A., Golparvar, B., 2025. Groundwater level forecasting using empirical mode decomposition and wavelet-based long short-term memory (LSTM) neural networks. *Groundw. Sustain. Dev.* 28, 101397. <https://doi.org/10.1016/j.gsd.2024.101397>.
- Raissi, M., Perdikaris, P., Karniadakis, G.E., 2019. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *J. Comput. Phys.* 378, 686–707. <https://doi.org/10.1016/j.jcp.2018.10.045>.
- Saatsaz, M., 2012. Groundwater resource assessment of Astaneh-Kouchesfahan plain. PhD Thesis, Universiti Putra Malaysia, Serdang, Malaysia.
- Sahoo, S., Russo, T.A., Elliott, J., Foster, I., 2017. Machine learning algorithms for modeling groundwater level changes in agricultural regions of the U.S. *Water Resour. Res.* 53(5), 3878–3895. <https://doi.org/10.1002/2016WR019933>.
- Shiri, J., Kisi, O., Yoon, H., Lee, K.K., Nazemi, A.H., 2013. Predicting groundwater level fluctuations with meteorological effect implications—A comparative study among soft computing techniques. *Comput. Geosci.* 56, 32–44. <https://doi.org/10.1016/j.cageo.2013.01.007>.
- Taccari, M.L., Wang, H., Nuttall, J., Chen, X., Jimack, P.K., 2024. Spatial-temporal graph neural networks for groundwater data. *Sci. Rep.* 14(1), 24564. <https://doi.org/10.1038/s41598-024-75892-5>.
- Tang, Y., Zang, C., Wei, Y., Jiang, M., 2019. Data-driven modeling of groundwater level with least-square support vector machine and spatial-temporal analysis. *Geotech. Geol. Eng.* 37, 1661–1670. <https://doi.org/10.1007/s10706-018-0713-6>.
- Wang, C., Zhu, Y., Zang, T., Liu, H., Yu, J., 2021. Modeling inter-station relationships with attentive temporal graph convolutional network for air quality prediction. *Proc. 14th ACM Int. Conf. Web Search Data Min.*, 616–624. <https://doi.org/10.1145/3437963.3441731>.
- Wang, L., Jiang, Z., Song, L., Yu, X., Yuan, S., Zhang, B., 2024. A groundwater level spatiotemporal prediction model based on graph convolutional networks with a long short-term memory. *J. Hydroinform.* 26(11), 2962–2979. <https://doi.org/10.2166/hydro.2024.168>.
- Wang, Q., Zhu, S., 2025. Multi-station joint runoff forecasting using graph neural network coupled with spatial connectivity of hydrological stations. *Math. Geosci.* 57(4), 759–797. <https://doi.org/10.1007/s11004-024-10142-4>.
- Wu, C., Zhang, X., Wang, W., Lu, C., Zhang, Y., Qin, W., Tick, G.R., Liu, B., Shu, L., 2021. Groundwater level modeling framework by combining the wavelet transform with a long short-term memory data-driven model. *Sci. Total Environ.* 783, 146948. <https://doi.org/10.1016/j.scitotenv.2021.146948>.
- Wu, Y., Mei, G., Shao, K., Xu, N., Peng, J., 2025. Forecasting groundwater level by characterizing multiple spatial dependencies of environmental factors using graph-based deep learning. *J. Geophys. Res. Mach. Learn. Comput.* 2(2), e2024JH000520. <https://doi.org/10.1029/2024JH000520>.
- Wunsch, A., Liesch, T., 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). *Hydrol. Earth Syst. Sci.* 25(3), 1671–1687. <https://doi.org/10.5194/hess-25-1671-2021>.

- Yao, Y., Zheng, C., Liu, J., Cao, G., Xiao, H., Li, H., Li, W., 2015. Conceptual and numerical models for groundwater flow in an arid inland river basin. *Hydrol. Process.* 29(6), 1480–1492. <https://doi.org/10.1002/hyp.10276>.
- Yousefi, H., Zahedi, S., Niksokhan, M.H., Momeni, M., 2019. Ten-year prediction of groundwater level in Karaj plain (Iran) using MODFLOW2005-NWT in MATLAB. *Environ. Earth Sci.* 78, 1–14. <https://doi.org/10.1007/s12665-019-8340-y>.
- Zha, Y., Yang, Y., 2024. Innovative graph neural network approach for predicting soil heavy metal pollution in the Pearl River Basin, China. *Sci. Rep.* 14(1), 16505. <https://doi.org/10.1038/s41598-024-67210-w>.
- Zhu, Y., Liu, Q., 2025. Toward transparent groundwater contamination risk forecasting: Integrating causal discovery and Bayesian graph neural networks. *Sci. Total Environ.* 998, 180233. <https://doi.org/10.1016/j.scitotenv.2024.180233>.