

DOI:10.3876/j.issn.1000-1980.2026.05.002

图神经网络对地下水位预测的不同物理机制 融合方案比较

刘波,王佳宝,李志勇,姜伟

(河海大学水文与水资源学院)

摘要:为揭示不同物理机制融合方案对图神经网络(GNN)地下水位预测精度的影响,基于鄱阳湖流域 114 个监测站的逐日地下水位数据,综合考虑地下水位空间相关性、地表水-地下水关联属性及降雨滞时效应等物理因素,设计了 6 种物理机制融合方案的图卷积神经网络(GCN)结构,并对比分析了 6 种方案的地下水位预测精度。鄱阳湖流域实例验证结果表明:GCN 在预测地下水位动态变化时展现了出色的总体模拟能力和精度,各方案 R^2 均超过 0.9;融合提前 1 月降雨与地表水-地下水关联属性的方案精度最高(MAE 为 0.060 1 m),较单距离邻接矩阵方案提升约 6.8%;考虑降雨滞时可增强地下水位对降雨滞后响应的刻画,关联属性矩阵对潜水井水位预测结果的 RMSE 提升效果优于承压水井。

关键词:地下水位预测;图神经网络;物理机制融合;特征选择;图结构;鄱阳湖流域

中图分类号:TP183;P641.7

文献标志码:A

文章编号:1000-1980(2026)05-0010-08

Comparison of different physical mechanism fusion schemes for groundwater level prediction by graph neural networks

Liu Bo, Wang Jiabao, Li Zhiyong, Jiang Wei

(College of Hydrology and Water Resources, Hohai University)

Abstract: To reveal the influence of different physical mechanism fusion schemes on the groundwater level prediction accuracy of graph neural network (GCN), six graph convolutional network (GCN) structures with different physical mechanism fusion schemes were designed based on the daily groundwater level data from 114 monitoring stations in the Poyang Lake Basin by comprehensively considering the physical factors such as spatial correlation of groundwater levels, surface water-groundwater connectivity, and rainfall lag effect. The groundwater level prediction accuracies of the six schemes were compared. The results from the Poyang Lake Basin case validation show that the GCN demonstrated excellent overall simulation capability and accuracy when predicting the dynamic changes of groundwater levels; the R^2 of all schemes exceeds 0.9. The scheme fusing one-month-ahead rainfall and surface water-groundwater connectivity attributes achieves the highest accuracy (with an MAE of 0.060 1 m), improving the accuracy by about 6.8% compared with the single distance matrix scheme. Taking rainfall lag into account characterizes better the delayed response of groundwater levels to rainfall; moreover, the connectivity attribute matrix yields better RMSE improvements for phreatic well water-level predictions than for confined wells.

Key words: groundwater level prediction; graph neural network; physical mechanism fusion; feature selection; graph structure; the Poyang Lake Basin

地下水位动态特征与降雨、地表水系及水文地质条件等因素密切相关^[1-2]。降雨入渗^[3]及河流、湖泊等地表水体的入渗^[4]是潜水补给的重要来源^[5-7]。这些补给要素及其强度的空间分布受水文地质条件的控制,是影响地下水位动态的主要因素之一,具有明显空间差异性与相关性。

地下水位动态模拟预测的主要方法包括物理模拟、数值模拟与统计模型法。由于完备的水文地质条件^[8]往往难以获取,且水文地质概念模型的构建、边界条件及源汇项的确定均存在一定主观不确定性,加之计算成本较高,数值模拟法在资料匮乏地区及大尺度区域的应用受到限制^[9]。近年来,随着观测数据的不断积累与多源数据的日益丰富,众多学者已将数据驱动方法和机器学习技术广泛应用于地下水位预

测^[10-12]。此类方法能够捕捉输入变量与目标变量之间的非线性关系,识别时间序列数据中的隐藏模式,如支持向量机(SVM)^[12]、卷积神经网络(CNN)^[13]、长短时记忆网络(LSTM)^[14]、门控循环单元(GRU)^[15]等机器学习算法,在地下水位预测研究中展现了良好的应用潜力。但 Cao 等^[16]的研究发现,CNN 在处理非结构化数据和挖掘地下水位数据中的时序信息方面存在局限;LSTM 和 GRU 在处理非欧式空间数据和复杂数据结构特征方面存在不足。

图神经网络(graph neural network, GNN)模型是专为分析和处理图结构数据而设计的深度学习模型^[17]。GNN 通过信息传递机制更新节点状态,整合节点特征和图结构信息,对时空属性数据更具预测能力,在生态水文、系统故障分析^[18-19]等领域取得了显著应用成效。例如:Chen 等^[18]通过将生态水文模型中的饱和流模型 MODFLOW 替换为径向基函数神经网络,提出了一种整合物理基础数值模型和机器学习模型的新范式,既保持了模型的准确性和泛化能力,又显著提升了模型的计算效率和灵活性;Gao 等^[19]提出了物理嵌入递归图神经网络(Pe-RGNN)的新型故障诊断模型,该模型通过将传感器间的物理依赖关系嵌入到图结构,并利用递归图神经网络提取时序信息,实现了复杂系统的故障诊断。

GNN 能够综合时空机制属性,有效提高地下水位动态预测精度^[20]。图卷积神经网络(GCN)^[21]是 GNN 的一种,它利用图的结构特性设计卷积操作,从而在图数据上进行有效的特征学习。有学者在构建图神经网络(GWN)模型时,将监测井作为节点,通过自适应邻接矩阵和图卷积层捕捉井间空间关系,并利用门控时间卷积网络提取时间特征,用于不列颠哥伦比亚省地下水位预测,取得了优于 CNN、LSTM 等模型的预测效果^[22]。通过考虑监测站之间的空间关系构建 GNN,可以有效提高模拟精度和效率^[23]。Pang 等^[24]提出了一种基于注意力机制的图神经网络(aGNN)模型,用于模拟地下水中的污染物传输,并量化污染源与污染物传播之间的因果关系。当前 GNN 用于地下水位预测的研究主要集中于模型应用和模拟能力实证方面,然而如何有效地将物理机制融入模型以提高预测的准确性和科学性,仍是有待探讨的问题。

为对比评估不同物理机制融合方案对 GNN 地下水位预测精度的影响,本文通过设置降雨、地表水-地下水关联、地下水流场等物理要素信息在 GNN 结构中的不同融合方案,以鄱阳湖流域为实例,探讨不同类型物理机制的建模方案对提高 GNN 预测精度的差异,以期为地下水位预测提供参考。

1 GNN 构建与结构设计

1.1 GNN

本文选取 GNN 的变体 GCN 构建地下水位预测模型,以实现时地下水位的时空结构模拟与预测。GNN 的核心在于信息传递机制^[25],其中每个节点通过聚合邻居节点的信息更新自己的状态表示,通过迭代更新节点状态来捕捉节点及其邻居的信息和图的拓扑结构。这种迭代更新机制使得节点的最终状态能够包含其邻居的信息以及图的拓扑结构特征。

特征矩阵是一个包含所有节点特征信息的矩阵,通常表示为 $\mathbf{X} \in \mathbf{R}_{N \times D}$,其中 N 为图中节点总数, D 为每个节点的特征维度。邻接矩阵是一个方阵,用于表示图中所有节点之间的连接关系,通常表示为 $\mathbf{A} \in \mathbf{R}_{N \times N}$ 。邻接矩阵 $\mathbf{A}$ 中的数据 A_{ij} 表示节点 i 与 j 之间的连通性。如果节点和节点之间连通,则 A_{ij} 的值为边的权重;如果不连通,则 A_{ij} 的值为 0。特征矩阵提供了节点的属性特征,邻接矩阵提供了节点之间的连接关系。GNN 模型通过特征矩阵和邻接矩阵的结合来学习节点的表示,即通过特征矩阵传递节点的特征信息,同时利用邻接矩阵来聚合邻居节点^[25]的信息。

1.2 GCN 模型框架

本文采用两层 GCN 网络层构建模型框架^[26](图 1)。模型的输入是一个图结构,该结构由邻接矩阵和特征矩阵共同定义。模型输入首先被送入 GCN 卷积层 1 进行处理。在此过程中,图结构数据通过图卷积操作进行特征提取,随后通过 ReLU(rectified linear unit)激活函数进行非线性变换,以增强模型的表达能力。经过卷积层 1 处理后,数据被传递到卷积层 2,数据再次经过图卷积操作,进一步提炼和抽象特征。卷积层 2 的输出结果经过 ReLU 激活函数处理后被用作模型的预测输出。这种双层 GCN 结构设计,旨在通过逐层图卷积模块和非线性激活函数,有效捕捉和利用图数据中的局部连接模式,从而提高模型对图结构数据的预测性能。

1.3 图结构方案设计

图结构由邻接矩阵与特征矩阵组成。对于图结构 $G | (V, E, \mathbf{A})$, V 为图节点集合, E 为图上各个节点之




图 1 GCN 模型框架

Fig.1 Framework of GCN model

间的连通性,也就是边的集合。在地下水位预测过程中,每个地下水监测井代表一个节点,每个节点之间的连接可以用边表示,以地下水位监测井的地下水位与降雨历史资料作为特征矩阵,地下水监测井之间的空间关系作为邻接矩阵,构成地下水监测井群的图结构,从而将整个研究区地下水网络用图进行描述。

邻接矩阵用于量化监测站点间的相互依赖性, A_{ij} 表示站点 i 与站点 j 之间的依赖权重,定义为两站点距离 (distance) 的倒数,即站点间的距离越短,其依赖权重越大,从而揭示了站点间联系的紧密程度。

通过不同的特征矩阵与邻接矩阵构建方式,设计 GCN 模型的图结构方案。鉴于降雨与地下水位动态之间存在显著的成因联系,即降雨过程直接影响地下水位变化,可反映气候条件对地下水位的影响^[27],本文选取降雨作为辅助预测变量。具体地,基于相关分析成果,以预测时段前 1 月及前 3 月的降雨数据作为节点特征,构建 GCN 模型。此外,考虑到地表水与地下水构成相互关联的水文连续体^[28],综合地下水流特征、地表水与地下水相互联系的物理机制^[29],进一步区分了两种类型的邻接矩阵,即地表水-地下水关联属性矩阵和距离邻接矩阵。地表水-地下水关联属性邻接矩阵依据监测井在鄱阳湖流域水系中的空间分布构建,通过站点之间是否存在地表水力联系^[30],确定地理连接关系。如果不存在地表水力联系则两站点间不存在边的连接,两点之间权重为 0,若存在地表水力联系,则两点之间的权重为距离的倒数。距离邻接矩阵考虑监测井周围 60 km 范围内(保证每个监测井可以与一个邻近监测井连为一条边)包含的监测井构建了基于距离的连接关系。相应得到 6 种图结构设计方案(表 1)进行 GCN 建模。

表 1 方案名称及方案内容

Table 1 Name and content of schemes

方案名称	方案内容
GR	地表水-地下水关联属性邻接矩阵,单地下水位数据作为特征矩阵
D+P _{t-1}	单距离邻接矩阵,地下水位+提前 1 个月的降雨作为特征矩阵
GR+P _{t-1}	地表水-地下水关联属性邻接矩阵,地下水位+提前 1 个月的降雨作为特征矩阵
GR+P _{t-3}	地表水-地下水关联属性邻接矩阵,地下水位+提前 3 个月的降雨作为特征矩阵
D+P _{t-3}	单距离邻接矩阵,地下水位+提前 3 个月的降雨作为特征矩阵
D	单距离邻接矩阵,单地下水位数据作为特征矩阵

采用 2018 年 1 月至 2019 年 12 月逐日数据进行 GCN 模型的训练与验证,通过滚动计算的方式预测 2020 年各月地下水位,比较不同方案的预测效果,评估其性能。

1.4 模型评价方法

通过贝叶斯优化方法确定 GCN 的最佳超参数,设置如下参数,批量大小为 32,学习率为 0.001,损失函数为均方误差(MSE),优化器为 Adam,激活函数为 ReLU。用于评估模型性能的指标包括平均绝对误差(MAE)、相对误差(RE)、均方根误差(RMSE)、决定系数(R^2),误差越小,预测越准确,决定系数越大,结果越可靠。

2 研究区概况与数据

2.1 鄱阳湖流域概况

鄱阳湖流域,位于长江中下游南岸,地理坐标范围 24°29′14″N~30°04′41″N、113°34′36″E~118°28′58″E,

地形以丘陵和山地为主,中部湖区地势较低,四周被山脉环绕(图 2)。流域属于中亚热带湿润季风气候,气候温和,年均降水量约为 1 632 mm,降水的季节和年际变化显著,具有明显的地域性分布差异。鄱阳湖流域包含 6 个子流域,即赣江、抚河、信江、饶河、修河 5 条河流流域及鄱阳湖区(以下分别简称为赣、抚、信、饶、修、湖)。在鄱阳湖的不同洲滩,地下水埋深变化范围为 0.1~8.1 m。枯水季节,洲滩地下水埋深可达到 8.1 m,湖岸带^[31]不同典型区地下水埋深变化范围为 2.2~10 m,与湖水位变化在月尺度上表现出较好的一致性。汛期湖水位抬升,地下水与湖水保持约 4 个月较为活跃的水力联系。

2.2 数据来源

数据包括鄱阳湖流域 2018—2020 年 114 个地下水位监测站的逐日地下水位数据与 75 个中央报汛站逐日雨量资料,均来自江西省水文监测中心。

2.3 地下水位动态及其影响因素

降雨与地下水位动态存在物理因果联系,汛期降雨的有效补给使地下水位变化过程与降雨过程存在显著的相关性。同时,地下水位对降雨存在一定的滞后现象^[32],即地下水位有可能对若干个月之前的降水产生响应。合理引入地下水位变化的滞时因子,能够更准确地捕捉其动态规律^[29],从而显著提高地下水位预报的精度。鄱阳湖流域内 6 个子流域代表性地下水位与不同月份的前期降雨过程的相关性热图(图 3)表明,约 50%的站点相关系数介于 0.4~0.7,表明地下水位与降水量之间具有良好的相关性。研究区内逐月降雨过程与平原区代表站(黄沙站)和山丘区代表站(九江滨江站)的平均地下水位过程(图 4)进一步表明,平原区地下水位的变化较降雨过程存在 1~3 月的滞时(图 4(a)),山丘区降雨滞时略短,约为 1~2 月(图 4(b))。

3 结果与分析

3.1 不同方案地下水位预测精度比较

由于预测 2020 年各月地下水位和全年地下水位得到的评估指标数据较多,因此仅列出 2020 年全年的地下水位数据预测结果的精度(表 2)。各方案的 R^2 均超过 0.9,表明各方案模型都有很好的拟合度,能够很好地复现地下水位的变化过程。考虑降雨滞时的 $GR+P_{t-1}$ 方案 MAE、RE 均小于 GR 方案; $D+P_{t-1}$ 的 MAE 小于 D 方案(减小约 3%),表明在构建邻接矩阵时,添加降雨数据并适当考虑降雨滞时会使整体预测精度提升,相比于 D 方案,GR 的误差更小,表明使用地表水-地下水关联属性构建邻接矩阵能有效提高预测精度。

3.2 融合降雨的建模方案

为评估降雨数据融合对 GCN 模型预测准确性的影响,对比了考虑 1 个月、3 个月的地下水位对降雨滞时加距离因素和仅考虑距离因素的 GCN 模型在鄱阳湖站点的 RMSE。由图 5 可知,在山丘地区,考虑降雨 1 个月滞时构建的 GCN 模型预测性能最佳,RMSE 较低,表明合理整合降雨数据能提高模型在复杂地形(如





图 2 研究区概况

Fig. 2 Overview of study area



注:坐标轴上的数字表示地下水位对降水量的滞时长度,即当月地下水位之前不同月的降水量。

图 3 子流域代表站降水量与地下水位相关性热图

Fig. 3 Heat map of correlation between rainfall and groundwater level at representative stations in sub-basins




图 4 代表站逐月降水量与地下水位过程

Fig. 4 Processes of monthly rainfall and groundwater level at representative stations

表 2 各方案模型预测精度

Table 2 Prediction accuracies of each scheme model				
方案名称	MAE/m	RE/%	RMSE/m	R^2
GR	0.0618	0.20	0.1304	0.9799
D+P _{t-1}	0.0626	0.20	0.1347	0.9786
GR+P _{t-1}	0.0601	0.19	0.1306	0.9799
GR+P _{t-3}	0.0618	0.20	0.1317	0.9795
D+P _{t-3}	0.0644	0.21	0.1322	0.9794
D	0.0645	0.21	0.1318	0.9795

山丘)地区的预测精度。然而,构建邻接矩阵所融合的数据要素并非越多越好。模拟结果显示地下水位与降水量之间存在约 1 月的滞时,即引入 P_{t-1} 数据的模型表现更佳,而引入滞时为 3 月降雨数据的模型可能引入了过多干扰信息,不利于模型优化。综上,在预测目标变量的过程中,选择合适的数据比单纯追求数据量的增加更有利于模型预测。

此外,在空间上,南坑站、龙南站、黄岗山站、德安站 3 种建模预测方案的 RMSE 均较大(图 5),因此以 $D+P_{t-1}$ 方案为例,进一步分析 2020 年全年地下水位模拟过程(图 6)。上述 4 个站对极值的预测均不够精确,导致 RMSE 偏大,可能是因为 4 个站位于流域上游,邻近站点较少,站仅通过较少边与其他站点相连,节点关联性较弱,限制了模型在这些节点处的信息传递;同时 4 个站地处丘陵山区,地下水位波动幅度较大,预测结果误差过大,使预测值与实际值出现偏差。

3.3 融合地表水与地下水相互作用的建模方案

考虑到地表水与地下水联系信息对模型性能的影响,本文选择 GR(侧重于体现地表水与地下水体的联系)和 D(只考虑站点之间的距离大小)两个方案的预测结果进行对比分析(图 7)。在面对地下水位变化波动剧烈或平滑的站点数据时,两种方案均能预测到地下水位的变化趋势,但 GR 方案相较 D 方案展现出更优的预测性能,对降雨滞后的控制能力更好。D 方案的邻接矩阵为无选择的,只依据距离的全连接方式,而 GR 方案则依据地表水与地下水之间的关系对站点之间邻接关系进行了选择性构建。这种基于先期特征选择的方法使得模型更容易、更准确地学习到数据中的潜在模式,从而提升模型的预测能力。图 7(b)龙南站的预测误差较小但是预测趋势与实际存在较大差距,可能是因为该站的节点关联性较弱,限制了其信息传递的效率,导致模型未能充分学习到该站点地下水位动态的局部细微特征,而过度依赖其已学习的全局特征。

在 114 个站点(即监测井)的整体数据中,有 76 个监测井的预测结果 RMSE 因加入地表水-地下水关联属性而得到提升,占比约 66.67%;另有 38 个监测井的预测结果 RMSE 有所下降,占比约 33.33%。这一数据充分说明,加入地表水-地下水关联属性对绝大部分监测井的预测精度起到了积极作用。在 84 个潜水监测井中,有 61 个的预测结果 RMSE 得到提升,占比约 72.6%,仅 23 个出现下降,占比约 27.4%;而在 30 个承压水监测井中,预测结果 RMSE 提升的为 16 个,占比约 53.3%,下降的为 14 个,占比约 46.7%。显然,潜水监测井的提升效果更为显著,这反映出潜水井与地表水体的联系更为紧密,对地表水-地下水关联属性的响应更敏感;而承压水监测井由于与地表水体的联系相对较少,其对该关联属性的响应也就不够明显。




图 5 典型方案地下水位预测误差
Fig. 5 Groundwater level prediction errors for typical schemes




图 6 2020 年代表站 $D+P_{t-1}$ 方案下地下水位过程线
Fig. 6 Processes of groundwater level under $D+P_{t-1}$ scheme at representative stations in 2020




图 7 2020 年代表站 7 月 D、GR 方案地下水位过程线

Fig. 7 Processes of groundwater level under D and GR schemes at representative stations in July 2020

4 结 论

- a. GCN 在预测地下水位动态变化时展现了出色的总体模拟能力和精度。GCN 通过适时引入降雨数据,并结合地表水与地下水的物理联系信息,有效捕捉了不同站点的地下水位变化模式,显著提升了模型对降雨滞时的控制能力,这一改进进一步验证了模型的高精度和稳定性。
- b. 考虑到降雨对地下水位的滞时影响特性,构建融入提前降雨数据的特征矩阵,能使 GCN 模型充分利用降雨时序特征,提升模型对滞后现象的控制能力,使其预测表现优于未充分结合降雨数据的方案,凸显了合理利用时序降雨信息对提升模型预测性能的重要性。
- c. 基于地下水位与地表水存在密切交互的特性,提出构建地表水-地下水关联属性邻接矩阵的方案,能准确捕捉水体物理联系及地下水位变化模式,预测精度与稳定性显著优于单纯基于距离的邻接矩阵方案。
- d. 加入地表水-地下水关联属性对地下水位预测的提升效果因观测的地下水类型而异:与地表水体联系紧密的潜水井预测精度提升显著,这源于两者的直接关联使其对该属性更敏感;而联系不紧密的承压水监测井因间接关联,受该属性影响有限,预测效果提升较弱。此外,引入物理信息后,GCN 模型的 MAE 显著下降,但 RMSE 无明显改善,说明模型对极端值的预测仍有不足,后续需针对性优化结构。同时,由于受模型与数据资料限制,本研究仅考虑了降雨及地表水-地下水物理联系两种机制,未涉及地形、植被等其他影响因素,后续可补充相关流域属性以进一步提升模型预测表现。

参考文献:

[1] 束龙仓,殷晓然,袁亚杰,等. 三江平原典型区河水与地下水水量交换的时空变化规律分析[J]. 水利学报,2021,52(10): 1151-1162. (Shu Longcang, Yin Xiaoran, Yuan Yajie, et al. Temporal and spatial variation of water quantity exchange between surface water and groundwater in typical district of Sanjiang Plain[J]. Journal of Hydraulic Engineering, 2021, 52(10): 1151-1162. (in Chinese))

[2] 束龙仓,徐丽丽,袁亚杰,等. 三江平原典型区地下水流场变化及主要影响因素分析[J]. 水利学报,2022,53(6): 644-654. (Shu Longcang, Xu Lili, Yuan Yajie, et al. Analysis on variation of groundwater flow field and its main influencing factors in the typical district of Sanjiang Plain[J]. Journal of Hydraulic Engineering, 2022, 53(6): 644-654. (in Chinese))

[3] 谢丽纯,陈建耀,付丛生,等. 华南滨海小流域降雨入渗对地下水的补给分析[J]. 生态环境学报,2011,20(8/9): 1259-1267. (Xie Lichun, Chen Jianyao, Fu Congsheng, et al. Observation and analyses of groundwater recharge from rainfall infiltration in a coastal watershed, South China[J]. Ecology and Environment Sciences, 2011, 20(8/9): 1259-1267. (in Chinese))

[4] 周瑞静,宋炜,倪宝峰. 基于数值模拟的地表水体对地下水源地影响研究:以北京市通州区为例[J]. 城市地质,2020,15(4): 388-393. (Zhou Ruijing, Song Wei, Ni Baofeng. Study on influence of surface water on groundwater source based on numerical simulation: taking Tongzhou district of Beijing as an example[J]. Urban Geology, 2020, 15(4): 388-393. (in

Chinese))

[5] 宋子奕,鲁程鹏,吴成城,等. 2009—2019 年河西走廊地下水位时空分布及演变趋势[J]. 水资源保护,2023,39(2):160-167. (Song Ziyi,Lu Chengpeng,Wu Chengcheng,et al. Spatiotemporal Distribution and evolution trend of ground water level in Hexi Corridor from 2009 to 2019[J]. Water Resources Protection,2023,39(2):160-167. (in Chinese))

[6] 刘紫莹,周冰玉,李志威,等. 黄河源区典型泥炭湿地地下水水位时空变化及流量过程[J]. 水利水电科技进展,2024,44(3):27-33. (Liu Zixuan,Zhou Bingyu,Li Zhiwei,et al. Spatiotemporal change of groundwater level and discharge process in a typical peatland watershed in Source Region of Yellow River[J]. Advances in Science and Technology of Water Resources,2024,44(3):27-33. (in Chinese))

[7] Wang Wang,Chen Jiaqi,Chen Jiansheng,et al. External groundwater recharge of Tianchi Lake in Changbai Mountain[J]. Water Science and Engineering,2026,19(1):47-55.

[8] 井森,张江江,刘瑾,等. 水位、水量、产量联控的华北平原地下水超采区节水灌溉多目标优化[J]. 水资源保护,2025,41(2):184-192. (Jing Miao,Zhang Jiangjiang,Liu Jin,et al. Multi-objective optimization of water-saving irrigation in groundwater over-exploitation area of the North China Plain under joint control of water level, water volume, and crop yield[J]. Water Resources Protection,2025,41(2):184-192. (in Chinese))

[9] 郝治福,康绍忠. 地下水系统数值模拟的研究现状和发展趋势[J]. 水利水电科技进展,2006,26(1):77-81. (Hao Zhifu,Kang Shaozhong. Current situation and development trend of numerical simulation of groundwater system[J]. Advances in Science and Technology of Water Resources,2006,26(1):77-81. (in Chinese))

[10] Tao Hai,Hameed M M,Marhoon H A,et al. Groundwater level prediction using machine learning models: a comprehensive review[J]. Neurocomputing,2022,489:271-308.

[11] Azad A S,Islam N,Nabi M N,et al. Developments and trends in water level forecasting using machine learning models: a review[J]. IEEE Access,2025,13:63048-63065.

[12] 牛欣怡,鲁程鹏,卢佳赞,等. 机器学习模型在地下水埋深模拟中的适应性分析[J]. 河海大学学报(自然科学版),2022,50(4):74-82. (Niu Xinyi,Lu Chengpeng,Lu Jiayun,et al. Adaptability analysis of machine learning model in groundwater depth simulation[J]. Journal of Hohai University (Natural Sciences),2022,50(4):74-82. (in Chinese))

[13] Yang Xingyu,Zhang Zhongrong. A CNN-LSTM model based on a meta-learning algorithm to predict groundwater level in the Middle and Lower reaches of the Heihe River,China[J]. Water,2022,14(15):2377.

[14] 闫佰忠,孙剑,王昕洲,等. 基于多变量 LSTM 神经网络的地下水水位预测[J]. 吉林大学学报(地球科学版),2020,50(1):208-216. (Yan Baizhong,Sun Jian,Wang Xinzhou,et al. Multivariable LSTM neural network model for groundwater levels prediction[J]. Journal of Jilin University (Earth Science Edition),2020,50(1):208-216. (in Chinese))

[15] 陈文龙,杨云丽,张煜,等. 基于天地协同与深度学习的灌区地下水位模拟[J]. 长江科学院院报,2023,40(7):88-95. (Chen Wenlong,Yang Yunli,Zhang Yu,et al. Simulation of groundwater level in irrigation area based on sky-earth cooperation and deep learning[J]. Journal of Yangtze River Scientific Research Institute,2023,40(7):88-95. (in Chinese))

[16] Cao Hongye,Han Ling,Li Liangzhi. A deep learning method for cyanobacterial harmful algae blooms prediction in Taihu Lake, China[J]. Harmful Algae,2022,113:102189.

[17] Yu Bing,Yin Haoteng,Zhu Zhanxing. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting[C]//Proceedings of the 27th International Joint Conference on Artificial Intelligence (IJCAI). Stockholm:IJCAI,2018.

[18] Chen Chong,Zhang Hui,Shi Wenxuan,et al. A novel paradigm for integrating physics-based numerical and machine learning models: a case study of eco-hydrological model[J]. Environmental Modelling & Software,2023,163:105669.

[19] Gao Yushan,Zhong Zhirong,Ma Meng,et al. Physics-embedded recurrent graph neural network for fault diagnosis of complex systems[J]. IEEE Access,2024,12:122426-122436.

[20] Zhou Yu,Zheng Haixia,Huang Xin,et al. Graph neural networks: taxonomy, advances, and trends[J]. ACM Transactions on Intelligent Systems and Technology,2022,13(1):15.

[21] 谢娟英,张建宇. 图卷积神经网络综述[J]. 陕西师范大学学报(自然科学版),2024,52(2):89-101. (Xie Juanying,Zhang Janyu. The review of the graph convolutional neural networks[J]. Journal of Shaanxi Normal University (Natural Science Edition),2024,52(2):89-101. (in Chinese))

[22] Bai Tao,Tahmasebi P. Graph neural network for groundwater level forecasting[J]. Journal of Hydrology,2023,616:128792.

[27] 杨建华,李丽,张伟. 基于形态学的锯材表面缺陷图像处理研究方法[J]. 林业机械与木工设备,2012,40(9):18-20. (Yang Jianhua,Li Li,Zhang Wei. Research on processing methods for sawn timber surface defect images based on morphology[J]. Forestry Machinery & Woodworking Equipment,2012,40(9):18-20. (in Chinese))

[28] 孙永生,刘大健,秦蒙. 多幅图像中值法在滤除噪声中的应用[J]. 电视技术,2012,36(23):15-17. (Sun Yongsheng,Liu Dajian,Qin Meng. Many images median method in application of noise filtering[J]. Video Engineering,2012,36(23):15-17. (in Chinese))

[29] Hörning S,Haese B. RMWSPy (v 1.1): a Python code for spatial simulation and inversion for environmental applications[J]. Environmental Modelling & Software,2021,138:104970.

[30] Stephan M,Docter J. JUQUEEN:IBM Blue Gene/Q® supercomputer system at the Jülich Supercomputing Centre[J]. Journal of Large-Scale Research Facilities,2015,1:A1.

[31] Baldauf M,Seifert A,Förstner J, et al. Operational convective-scale numerical weather prediction with the COSMO model: description and sensitivities[J]. Monthly Weather Review,2011,139(12):3887-3905.

[32] Lawrence P J,Chase T N. Representing a new MODIS consistent land surface in the Community Land Model (CLM 3.0)[J]. Journal of Geophysical Research:Biogeosciences,2007,112(G1):G01023.

(收稿日期:2025-05-28 编辑:刘晓艳)

(上接第17页)

[23] 许明家,孙龙,李爽,等. 基于图神经网络的地下水位动态模拟模型[J]. 水文,2025,45(1):30-36. (Xu Mingjia,Sun Long,Li Shuang,et al. Dynamic model of groundwater level based on graph neural networks[J]. Journal of China Hydrology,2025,45(1):30-36. (in Chinese))

[24] Pang Min,Du Erhu,Zheng Chunmiao. Contaminant transport modeling and source attribution with attention-based graph neural network[J]. Water Resources Research,2024,60(6):e2023WR035278.

[25] Wu Zonghan,Pan Shirui,Chen Fengwen, et al. A comprehensive survey on graph neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems,2021,32(1):4-24.

[26] Scarselli F,Gori M,Tsoi A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks,2009,20(1):61-80.

[27] 李小根,刘泓辰,付景保,等. 基于 CNN-Attention-LSTM 模型的地下水水位预测[J]. 水资源保护,2025,41(4):228-235. (Li Xiaogen,Liu Hongchen,Fu Jingbao, et al. Groundwater level prediction based on CNN-Attention-LSTM model[J]. Water Resources Protection,2025,41(4):228-235. (in Chinese))

[28] 梅超,石虹远,李瑞栋,等. 基于数值试验的降雨径流过程对不透水面空间分布的响应分析[J]. 水资源保护,2024,40(1):86-92. (Mei Chao,Shi Hongyuan,Li Ruidong, et al. Response analysis of rainfall runoff process to spatial distribution of impervious area based on numerical experiments[J]. Water Resources Protection,2024,40(1):86-92. (in Chinese))

[29] 黄强,尚嘉楠,方伟,等. 基于可解释机器学习的黄河源区径流分期组合预报[J]. 人民黄河,2024,46(9):50-59. (Huang Qiang,Shang Jianan,Fang Wei, et al. Combined forecasting of streamflow in the source region of the yellow river based on interpretable machine learning[J]. Yellow River,2024,46(9):50-59. (in Chinese))

[30] 吴学文,瞿永钢,李玲. 基于复杂网络理论的河流网络建模与分析[J]. 河海大学学报(自然科学版),2014,42(2):177-182. (Wu Xuewen,Qu Yonggang,Li Ling. River network modeling and analysis based on complex network theory[J]. Journal of Hohai University (Natural Sciences),2014,42(2):177-182. (in Chinese))

[31] 李云良,张小琳,赵贵章,等. 鄱阳湖区地下水位动态及其与湖水侧向水力联系分析[J]. 长江流域资源与环境,2016,25(12):1894-1902. (Li Yunliang,Zhang Xiaolin,Zhao Guizhang, et al. Dynamics of groundwater level and laterally hydraulic connection between lake and groundwater in Poyang Lake Area[J]. Resources and Environment in the Yangtze Basin,2016,25(12):1894-1902. (in Chinese))

[32] 黄一凡,张翔,邓梁堃,等. 基于机器学习的汉江流域径流模拟与时滞变化分析[J]. 水资源保护,2024,40(6):173-180. (Huang Yifan,Zhang Xiang,Deng Liangkun, et al. Runoff simulation and time-lag change analysis in the Han River Basin based on machine learning[J]. Water Resources Protection,2024,40(6):173-180. (in Chinese))

(收稿日期:2025-04-25 编辑:刘晓艳)