J. Lake Sci.(湖泊科学), 2026, 38(1):000-000
DOI 10.18307/2026.0143

基于图神经网络的洞庭湖洪水与枯水模拟分析*

韦溢龙，周研来**，罗宇轩
（武汉大学，水资源工程与调度全国重点实验室,武汉 430072）

摘　要：洞庭湖是长江中游的重要湖泊，准确模拟其各输入、输出站点的径流响应关系，对湖区防汛抗旱和生态保护至关重要。针对复杂水力连接下洞庭湖流域多站点径流过程的时空非线性关联特性，本研究提出了一种基于图神经网络的多输入—多输出径流响应模型，首先利用长江、洞庭湖和四水的流域拓扑空间结构，将各站点的原始观测序列转化为图结构数据，以表征多站点之间的空间关联特性；然后，通过互相关分析法研究各站点观测变量之间的时滞关系，确定模型的输入特征步长；最后，利用图神经网络对数据中的站点特征进行聚合与更新，以捕捉关键控制站点间的复杂时空依赖性，提高多站点径流模拟的准确性和可靠性。结果表明：在洪水事件中，图神经网络（GNN）的纳什效率系数 NSE 和平均绝对误差 MAE 相比前馈神经网络（BP）和长短期记忆神经网络（LSTM）模型均提高 5%以上，且相关性系数 R^2 均超过 0.97，在枯水断流事件中，召回率 TPR 和精度 Precision 普遍超过 0.96。GNN 在洪水和枯水断流等水文事件模拟方面具有明显优势，可为洞庭湖防汛抗旱和生态治理提供科学依据。

关键词：图神经网络；径流响应模型；多输入—多输出；时空关联特征

Exploring graph neural networks for simulating flood and drought events of the Lake Dongting

Wei Yilong, Zhou Yanlai**, Luo Yuxuan
(State Key Laboratory of Water Resources Engineering and Management, Wuhan University, Wuhan 430072，P.R.China)

Abstract: Lake Dongting, located in the middle reaches of the Yangtze River, is a crucial body of water. Accurately modelling the relationships between the runoff and the various input and output stations is essential for regional ecological protection, flood control, and drought defense. In order to address the complex relationships between runoff and the various input and output stations in the Lake Dongting basin, this study proposes a multiple-input and multiple-output runoff response model based on graph neural networks. Firstly, the model utilises the topological spatial structure of the Yangtze River, Lake Dongting and Sishui basins to transform the original observation sequences at each station into graph-structured data, thereby characterizing the spatial features of the basins. Secondly, the mutual correlation analysis method is used to identify the time lag relationship between the observed variables at each station, determining the input feature step of the model. Finally, graph neural networks are employed to aggregate and update the features, capturing the complex spatial and temporal dependencies among the control stations and enabling runoff simulation at multiple stations. The results show that, compared with backpropagation neural networks (BP) and long short-term memory (LSTM) neural networks, the graph neural network (GNN) model can achieve improvement rates of over 5% for the Nash–Sutcliffe efficiency coefficient (NSE) and mean absolute error (MAE) indicators. The correlation coefficient (R^2) is also greater than 0.97. In dry water cutoff events, the true positive rate (TPR) and precision are generally greater than 0.96. GNNs have significant advantages in simulating hydrological events such as floods and droughts and can provide scientific support for the ecological protection of Lake Dongting and its flood control and drought resistance measures.

*2024-11-28 收稿；2025-02-06 收修改稿。
国家重点研发计划项目（2021YFC3200303）资助。
*通讯作者；E-mail: yanlai.zhou@whu.edu.cn

Keywords: Lake Dongting; Graph neural network (GNN); Runoff response modelling; Multiple-input and multiple-output; Spatio-temporal correlation

洞庭湖是长江中游的大型通江湖泊，承担着分蓄长江超额洪水的重要任务[1]，同时还具有涵养水源、释氧固碳、净化环境等重要的生态功能[2]。受气候变化以及江湖关系演变等多方面因素的影响[2-3]，洞庭湖区域的水生态、水安全正面临严峻挑战[4]。在汛期，洞庭湖屡屡出现"同流量高水位、小流量高水位、中高水位维持时间拉长"等现象[5]，这些现象反映了洞庭湖流域复杂洪水特征；荆江松滋口、太平口和藕池口（简称荆江三口）为江湖关系纽带，在枯水季节，三口断流事件频发，且断流持续时间有延长趋势[6]，极端枯水事件导致湖区水资源短缺和环境恶化问题严重。由于洞庭湖不仅接纳荆江三口的长江来水，同时还汇集湘、资、沅、澧四水来流，径流响应关系极为复杂[7]。同时，湖区河网密布，水系交错纵横，各控制站点的径流过程在河道水力连接下相互影响，可视为一种具有复杂时空关联的多输入、多输出非线性水文系统。在江湖关系发生显著变化的新形势下，如何准确模拟洞庭湖控制站点的径流响应关系，为上游水利工程的防洪、生态调度提供科学依据，对洞庭湖防汛抗旱和生态治理具有重要的意义。

洞庭湖多站点径流模拟主要包括机理建模和数理统计建模两类手段。其中，机理模型主要通过一、二维水动力[5]和水文学方法[8]进行江湖演算，但这类方法对地形和河道数据资料要求较高。由于荆江三口和四水控制站涉及的未控区间较大，河道断面及实时观测数据十分稀缺，机理模型在实际作业模拟中因维数灾问题，无法有效平衡计算精度与效率。数理统计建模不依赖于经验规律或物理机制的先验知识，可基于干支流历史实测水文数据的统计规律来模拟径流响应关系，不仅具有较好的适用性，而且能在降低计算时间前提下维持较高计算精度。近年来，机器学习促进了数据驱动模型在水文模拟中的应用，通过历史数据建立输入输出映射，依托强大的非线性化表征能力，实现水文过程预测。常用模型包括浅层学习模型、深度学习模型、集成学习模型及混合模型，在径流预测、洪水预报和水质评估等领域发挥了重要作用。如前馈神经网络（Back propagation neural networks, BP）[9]、长短时记忆网络（Long short-term memory neural networks, LSTM）[10]等机器学习模型已被成功用于河湖系统的水文模拟。然而，BP 和 LSTM 等方法本质上只适用于时间序列等欧几里得结构数据的模拟任务[11]，无法充分考虑多输入、多输出变量的空间关系，导致模型训练时极易出现过拟合和误差累积传递等问题，降低了径流模拟精度[12]。与基于序列数据建模的机器学习模型不同，图神经网络（Graph neural networks, GNN）是一种适用于非欧几里得结构数据建模的机器学习模型，能够有效表征变量之间的多对多关系、层次关系、属性关系和空间关系等，在诸多复杂系统建模研究中得到了应用[13,14]。目前，GNN 在河湖系统径流模拟建模方面的研究存在空白，亟待开展深入探究。

针对洞庭湖径流模拟中多输入—多输出变量间复杂响应关系的建模难题，本研究提出一种基于图神经网络的多输入—多输出径流响应模型，以充分挖掘复杂水力连接下水文变量的空间关联特征，提高水文控制站点的径流模拟准确性和可靠性。首先，根据长江、洞庭湖和四水的流域拓扑空间结构，将各站点的原始观测序列转化为图结构数据，以实现系统空间信息的特征嵌入；其次，考虑不同站点观测变量的时间滞后关系，采用互相关分析方法确定模型输入特征步长；最后，通过图神经网络聚合与更新图数据中的站点特征，以捕获图数据的复杂时空依赖特性，并实现水文控制站点的多输出径流模拟。本研究基于 2000－2022 年洞庭湖水系及长江干流上的共 13 个水文站的日流量数据，分别构建基于 GNN、BP 和 LSTM 的多输出径流模拟模型，评估洞庭湖洪旱事件模拟的准确性和可靠性。

1　研究区域与数据

洞庭湖是我国第二大淡水湖，也是长江流域重要的吞吐调蓄型湖泊。洞庭湖流域（图 1(a)）水系交错，河网纵横，相互之间存在着复杂的水沙交换关系。除接纳荆江南岸松滋、太平、藕池三口(调弦口已于 1958 年建闸控制未再分流)的来水来沙以外，洞庭湖还承接着湘、资、沅、澧四水的入流，经调蓄后从城陵矶附近汇入长江。本研究收集了 2000-2022 年的日尺度气象水文数据用于建模，包括长江干流（宜昌站，河溶站，长阳站）、四水（石门站、桃江站、桃源站和湘潭站）、荆江"三口"五站（管家铺、康家岗、弥陀寺、沙道观和新江口）和洞庭湖出口城陵矶站的实测流量数据。数据被划分为训练期和测试期数据集，训练期

资料为 2000－2015 年（共 16 年）数据，用于模型率定，测试期资料为 2016－2022 年（共 7 年）数据，用于模型验证。

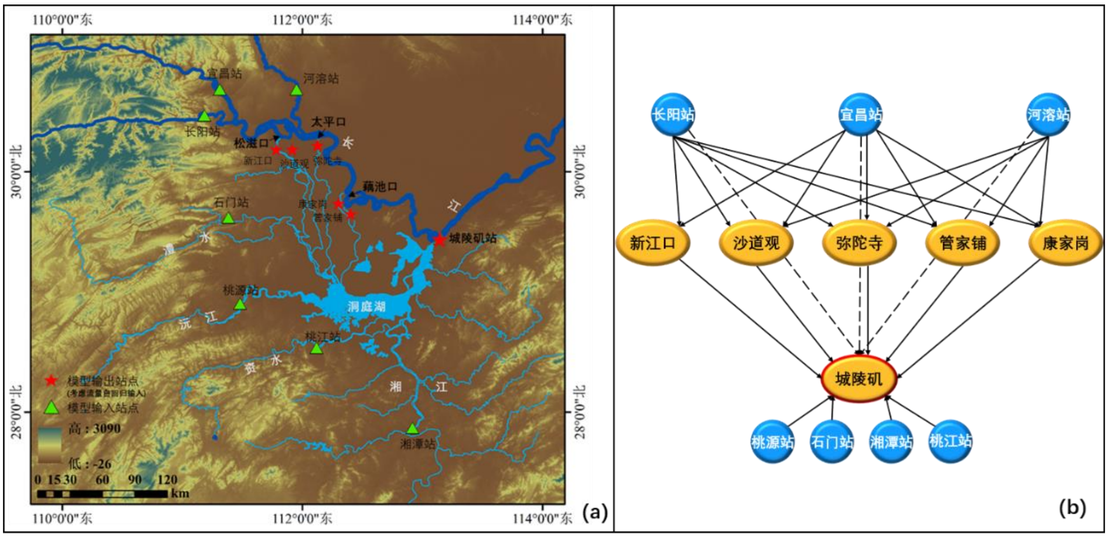

图 1 洞庭湖水系概化图
Fig.1 Generalization of Lake Dongtingwater system

2 研究方法

为解决复杂水力连接下多输入—多输出变量间时空响应关系的建模难题，提高洞庭湖各水文控制站点的径流模拟准确性和可靠性，本研究提出了一种基于图神经网络的洞庭湖多输入—多输出径流响应模型，模型结构如图 2（a）所示。采用 LSTM 模型（图 2（b））和 BP 模型（图 2（c））作为基准模型，以对比分析所提出模型的径流模拟准确性和可靠性。三种模型的计算原理如下所述。

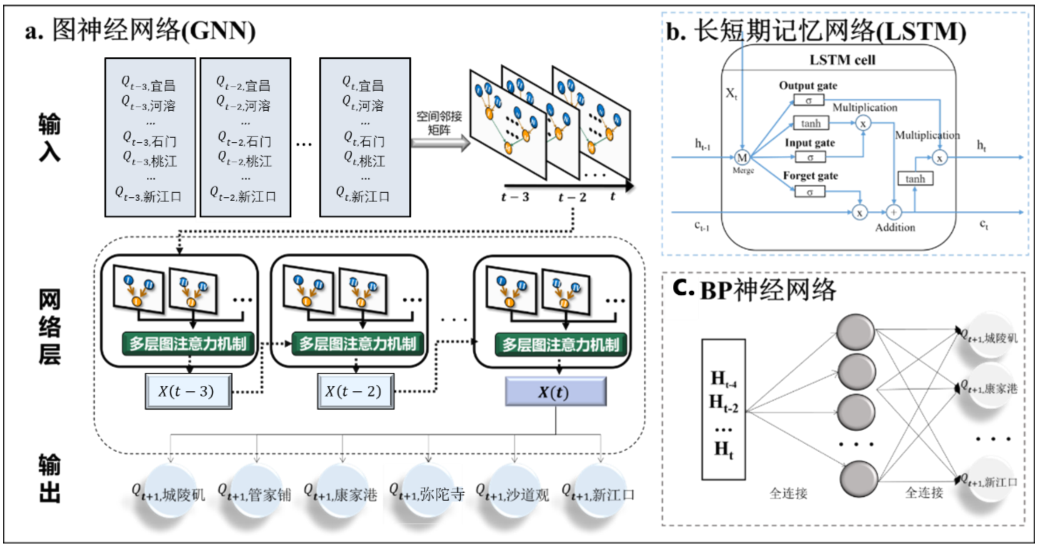

图 2 多输入-多输出径流响应模型（GNN、LSTM 和 BP）结构图
Fig.2 Architectures of the multi-input and output runoff simulation models.
a. GNN-based model. b. LSTM-based model. c. BP-based model

2.1 基于图神经网络的多输入—多输出径流响应模型

图神经网络是一种针对图结构数据建模的深度学习方法，适用于各种复杂结构数据的建模问题。图神经网络利用图的拓扑结构和节点信息，能够有效地学习空间关系、连接关系、相似关系等非欧几里得结构数据内部的复杂特征，因而能够充分挖掘多维降雨、径流输入输出变量间的时空关联和非线性响应关系，从而有效提升径流模拟的准确性和可靠性。

步骤 1：图结构数据转化。图结构数据是一种由节点和边组成的数据形式，包含了变量之间的关联信

息。为了进一步提取和学习变量之间更深层次的空间关联特征和映射关系，需要将长江—洞庭湖系统内的站点观测序列转化为图结构数据，以满足图神经网络对建模数据的要求。在本研究中，节点为河湖系统内的各控制站点，边为站点在河网拓扑下的空间邻接关系，具体表示如式(1)—(3)。

$$\mathrm{G}_t = (\mathrm{V}_t, \mathrm{E}) \tag{1}$$

$$\mathrm{V}_t = \{\mathrm{v}_{t,i}(h_{t,i}) | i \in [1, \mathrm{N}]\} \tag{2}$$

$$\mathrm{E} = \{\mathrm{e}_{i,j} | \ i, j \in [1, C_N^2]\} \tag{3}$$

其中，t为模拟发起时刻；G_t代表t时刻模型的图结构数据输入；V_t为节点集合，代表河湖系统内所有测站；$v_{t,i}$为第i个站点，$i = 1,2,\ldots,N$，N为总站点数量；$h_{t,i}$为节点$v_{t,i}$的特征值向量，为考虑L阶滞时的径流观测序列；E为边集合；$e_{i,j}$为第i和第j个节点之间的边，反映两个站点之间的空间邻接关系。如果两个站点之间具有河道连接，边的权重设置为 1，否则为 0。

步骤 2：基于多层图注意力机制的空间特征学习。单层图注意力机制的核心思想是通过注意力机制识别不同领域节点相对中心节点的空间关联权重，以动态判断不同节点之间的重要性，从而表征输入、输出节点径流过程的空间关系。在此基础上，多层图注意力机制即通过增加注意力层数以扩大邻域识别范围，实现对流域整体空间关联关系的挖掘和表示。首先遍历图中节点，以边为索引检索其邻居节点，并将其特征值变换到与中心节点相同的特征空间；其次，通过图注意力网络对特征值进行加权聚合，得到各节点与其邻居节点的空间关联权重，生成各站点观测变量在空间上相互影响关系的特征向量；最后，生成可表征全局空间关系的特征嵌入向量。

$$\mathrm{h}'_{t,i}, \mathrm{h}'_{t,j} = f_\psi(\mathrm{h}_{t,i}, \mathrm{h}_{t,j}) \tag{4}$$

$$\alpha_{t,ij} = Att(\mathrm{h}'_{t,i}, \mathrm{h}'_{t,j}) \tag{5}$$

$$x_{t,i} = \mathrm{Softmax}\left(\sum_{i \in N} \alpha_{t,ij} \cdot \mathrm{h}'_{t,j}\right) \tag{6}$$

$$\mathrm{X_t} = [x_{t,1}, x_{t,2}, \ldots, x_{t,N}] \tag{7}$$

其中，$h'_{t,i}$和 $h'_{t,j}$分别为节点v_i和其邻居节点v_j转化后的特征向量；f_ψ为特征空间映射函数；$\alpha_{t,ij}$表示邻居节点 v_j相对中心节点v_i的空间关联权重；$x_{t,i}$表示节点 v_i 的空间特征嵌入向量；X_t 为全局空间特征嵌入向量；$Att(\cdot)$为注意力机制的函数算子；$Softmax(\cdot)$为非线性激活函数。

步骤 3：多站点径流模拟。通过 $N \times M$ 维度的全连接层，建立 N 维向量 X_t 和 M 个关键站点径流模拟值之间的非线性映射关系，输出多站点径流模拟序列。

$$[Q_{t+1,1}, Q_{t+1,2}, \ldots, Q_{t+1,M}] = f_{\mathrm{FCL}}(\mathrm{W} \cdot \mathrm{X_t} + b) \tag{8}$$

其中，$Q_{t,i}$ 为第 i 个站点在 t 时刻的径流模拟值，$i = 1,2,\ldots,M$；$f_{FCL}(\cdot)$为全连接网络的函数算子；W 为全连接层权重矩阵，b 为偏置项。

2.2 洞庭湖多输入-多输出径流响应模型构建

洞庭湖的入流主要包括长江干流，荆江“三口”以及湘江、资水、沅江、澧水“四水”来水，同时考虑三口五站和城陵矶站的流量自回归项，模型输入为 3 个长江干流控制站（宜昌、河溶和长阳）、四水 4 个控制站（石门、桃江、桃源和湘潭）、荆江“三口”五站（管家铺、康家岗、弥陀寺、沙道观和新江口）的历史实测流量序列。结合图 1（b）的河网拓扑结构确定站点空间邻接关系，将站点输入序列转化为图结构数据。由于图神经网络只考虑邻接站点的相关性，采用互相关分析方法计算各邻接站点观测变量之间响应时滞天数，计算结果如表 1 所示，最终确定各节点输入的历史流量为 *t*-4~*t*-1 时刻序列。模型输出为荆江三口 5 个站点和洞庭湖出口城陵矶站 *t* 时刻的流量值。

本研究采用 GNN 模拟荆江—洞庭湖河湖系统的径流响应关系，同时以 LSTM 模型和 BP 模型作为基准，评估和对比不同站点的径流模拟结果。尽管所有模型使用的是相同水文站点数据，但 GNN 的输入格式为图结构，其中 GNN 模型能够直接利用站点间的拓扑关系，而 LSTM 和 BP 模型则无法直接利用这种空间信息。通过比较这两类模型的性能以验证引入空间信息可以改善径流模拟精度的假设。

各模型的超参数均通过试错法予以确定，表 2 汇总了三个模型的输入、输出以及超参数设置情况。通过 Adam 梯度下降算法训练模型，算法参数设置为：学习率=0.001、梯度一阶矩衰减率（β_1）=0.9、梯度

二阶矩衰减率（β_2）=0.999。训练数据批次大小为 1000 和迭代次数为 300 次。考虑到本研究需要处理的数据维度较高，采用相比均方误差和线性误差损失函数等更具鲁棒性的 Huber Loss 函数计算损失，其参数设置为 0.3。

表 1 输入-输出站点径流互相关分析结果

Tab.1 Cross-correlation analysis of model input and output

站点	最大相关系数对应的时滞天数（相关系数）							
	宜昌	河溶	长阳	石门	桃源	桃江	湘潭	城陵矶
管家铺（藕池口）	1(0.95)	3(0.94)	4(0.92)	1(0.90)	1(0.88)	1(0.86)	1(0.84)	3(0.72)
康加岗（藕池口）	1(0.82)	2(0.81)	3(0.79)	1(0.77)	1(0.75)	1(0.73)	1(0.71)	3(0.75)
弥陀寺（太平口）	1(0.94)	3(0.91)	4(0.89)	1(0.87)	1(0.85)	1(0.83)	1(0.82)	3(0.70)
沙道观（松滋口）	1(0.95)	3(0.93)	4(0.90)	1(0.87)	1(0.85)	1(0.83)	1(0.81)	4(0.76)
新江口（松滋口）	1(0.99)	3(0.97)	4(0.95)	2(0.92)	2(0.90)	1(0.88)	1(0.87)	4(0.72)
城陵矶	3(0.82)	2(0.80)	3(0.79)	3(0.81)	3(0.77)	4(0.79)	4(0.77)	

表 2 模型参数设置

Tab.2 Model parameter settings

模型结构	模型		
	GNN	LSTM	BP
输入		$Q_{T1,P1}^{in}$	
隐藏层层数	2层	2层	2层
神经元数量	64	64	128
输出		$Q_{T2,P2}^{out}$	

其中，in 表示输入，out 表示输出；T1 为输入时段，这里取 t-3~t；P1 为输入站点，这里取宜昌、河溶、长阳、石门、桃江、桃源和湘潭以及取荆江三口 5 个站点；T2 为输出时段，这里取 t+1；P2 为输出站点，这里取荆江三口 5 个站点和城陵矶站。

为准确评估各模型的径流模拟性能，本研究采用了 Nash-Sutcliffe 效率系数（NSE）、水量误差（VE）、平均绝对误差（MAE）分别用于评估模型对各站点径流过程、径流总量和单点流量的模拟能力。同时，考虑当前洞庭湖三口断流事件频发，采用召回率（TPR）和精度（Precision）指标进一步评估各模型模拟三口断流事件的准确性，这些评价指标的具体计算公式见附录 T1。

3 结果及分析

3.1 总体模拟精度评估

GNN、LSTM 和 BP 模型训练期和测试期的评价指标见表 3。在训练阶段，GNN 模型的模拟精度较为理想，6 个站点的 NSE 指标均超过 0.985，特别是在城陵矶站高达 0.998。而 BP 和 LSTM 模型虽然在前 5 个站点的 NSE 指标较高，但是在城陵矶站误差较大，表明 GNN 模型拟合精度极高，图结构学习能力能更好的表达出实测值和模拟值之间的关系。与 BP 和 LSTM 模型相比，GNN 模型的 MAE 指标普遍提高 5%以上，VE 指标均在±1.0%以内，论证了 GNN 模型在处理复杂的河流网络和拓扑结构时独特的优势。

在测试阶段，GNN 模型仍能保持稳定的模拟精度，NSE 指标基本处于 0.980 以上，与 LSTM 和 BP 模型相比，NSE 和 MAE 均普遍提高 5%以上。除沙道观和弥陀寺外，VE 的绝对值值均不超过 1.0%。从 TRP 可以看出，GNN 模型能够正确模拟出所有的断流时段。对于非断流时段，除了沙道观外，其他站点的错误率都比较低，GNN 模型的 Precision 均达到 96%以上，准确性显著优于 BP 和 LSTM 模型。值得注意的是，测试期 2022 年特枯水年，在沙道观站点三个模型的 VE 和 Precision 指标上均出现了一定程度的偏差，这种偏差可能是由于三峡水库在应对严重枯水时采取的水量调节措施所致。为了缓解枯水带来的影响，三峡水库临时增加下泄流量，距离较近且分流量小的沙道观实测径流受到较大影响，从而在模型模拟为断流的时段形内成了径流；距离较远的太平口和藕池口以及松滋口中分流量较大的新江口则影响不大。这种由水库的调度活动引起的径流变化在模型的常规模拟中可能未能得到充分反映，导致了模型模拟与实测数据之间

的偏差。

表 3 训练期和测试期三种模型的多站点模拟结果评价指标
Tab.3 The evaluation indicators of simulation results obtained from the three models in the training period and the test period at various stations

模型	时期	评价指标	藕池口		松滋口		太平口	洞庭湖出口
			管家铺	康家岗	沙道观	新江口	弥陀寺	城陵矶
GNN	训练期	NSE	0.993	0.989	0.988	0.986	0.991	0.998
		VE/%	-0.4%	-0.8%	0.5%	-0.2%	-0.3%	0.6%
		MAE/(m^3/s)	19	1	15	48	21	174
		TPR/%	100	100	100	100	100	\
		Precision/%	96	98	94	100	97	\
	测试期	NSE	0.996	0.991	0.990	0.989	0.979	0.992
		VE/%	-0.9%	-0.6%	-5.9%	-0.5%	1.3%	0.2%
		MAE/(m^3/s)	23	1	23	62	23	235
		TPR/%	100	100	100	100	100	\
		Precision/%	98	97	74	100	100	\
LSTM	训练期	NSE	0.963	0.965	0.979	0.961	0.965	0.956
		VE/%	-1.2%	1.9%	0.7%	-0.8%	-0.8%	0.8%
		MAE/(m^3/s)	24	5	20	62	31	217
		TPR/%	99	98	97	97	97	\
		Precision/%	95	96	93	97	94	\
	测试期	NSE	0.948	0.948	0.942	0.945	0.930	0.931
		VE/%	-2%	-1.7%	-9.4%	-1.7%	2.4%	1.3%
		MAE/(m^3/s)	26	5	29	71	25	273
		TPR/%	98	98	99	97	97	\
		Precision/%	96	97	71	97	97	\
BP	训练期	NSE	0.960	0.959	0.970	0.970	0.957	0.902
		VE/%	-0.4%	-0.6%	-0.5%	0.4%	0.3%	2.7%
		MAE/(m^3/s)	25	4	17	67	28	290
		TPR/%	98	98	96	97	97	\
		Precision/%	96	95	92	97	93	\
	测试期	NSE	0.946	0.939	0.937	0.940	0.929	0.855
		VE/%	-1.0%	-2.5%	-6.3%	0.6%	2.9%	2.6%
		MAE/(m^3/s)	30	7	32	67	24	380
		TPR/%	98	97	97	96	97	\
		Precision/%	94	95	70	96	96	\

3.2 模型可靠性评估

三个模型输出变量的实测值与模拟值的散点图见图 3。从图中可以看出，3 种模型在各个站点的回归曲线均维持在对角线部近，相关性系数较高。GNN 模型在 6 个站点中的 R^2 均超过 0.97，在康家港（藕池口）和新江口（松滋口）站点更是高达 0.99。相比之下，BP 模型在城陵矶站和藕池口表现较为发散，弥陀寺（太平口）的模拟值则是出现较为明显的系统性偏小；LSTM 模型在松滋口的两个站点也出现了一定的系统性偏差，沙道观站表现为模拟值整体偏高，新江口站则是模拟值 2000m^3/s 之后开始低于实测值，且两个站点的散点分布都在高流量处开始发散。GNN 模型在整体上提供了更好的结果，误差分布较为均匀，在城陵矶、管家铺和新江口站散点分布近似一条连续的直线，在弥陀寺、康家岗和沙道观站的高流量模拟中略有发散

但没有明显的系统性误差。这意味着模型在模拟高流量和低流量时都保持了较高的精度，在特殊水文事件的模拟中具有明显的优势，同时也表现了处理复杂的河流网络和非线性系统方面的良好性能。

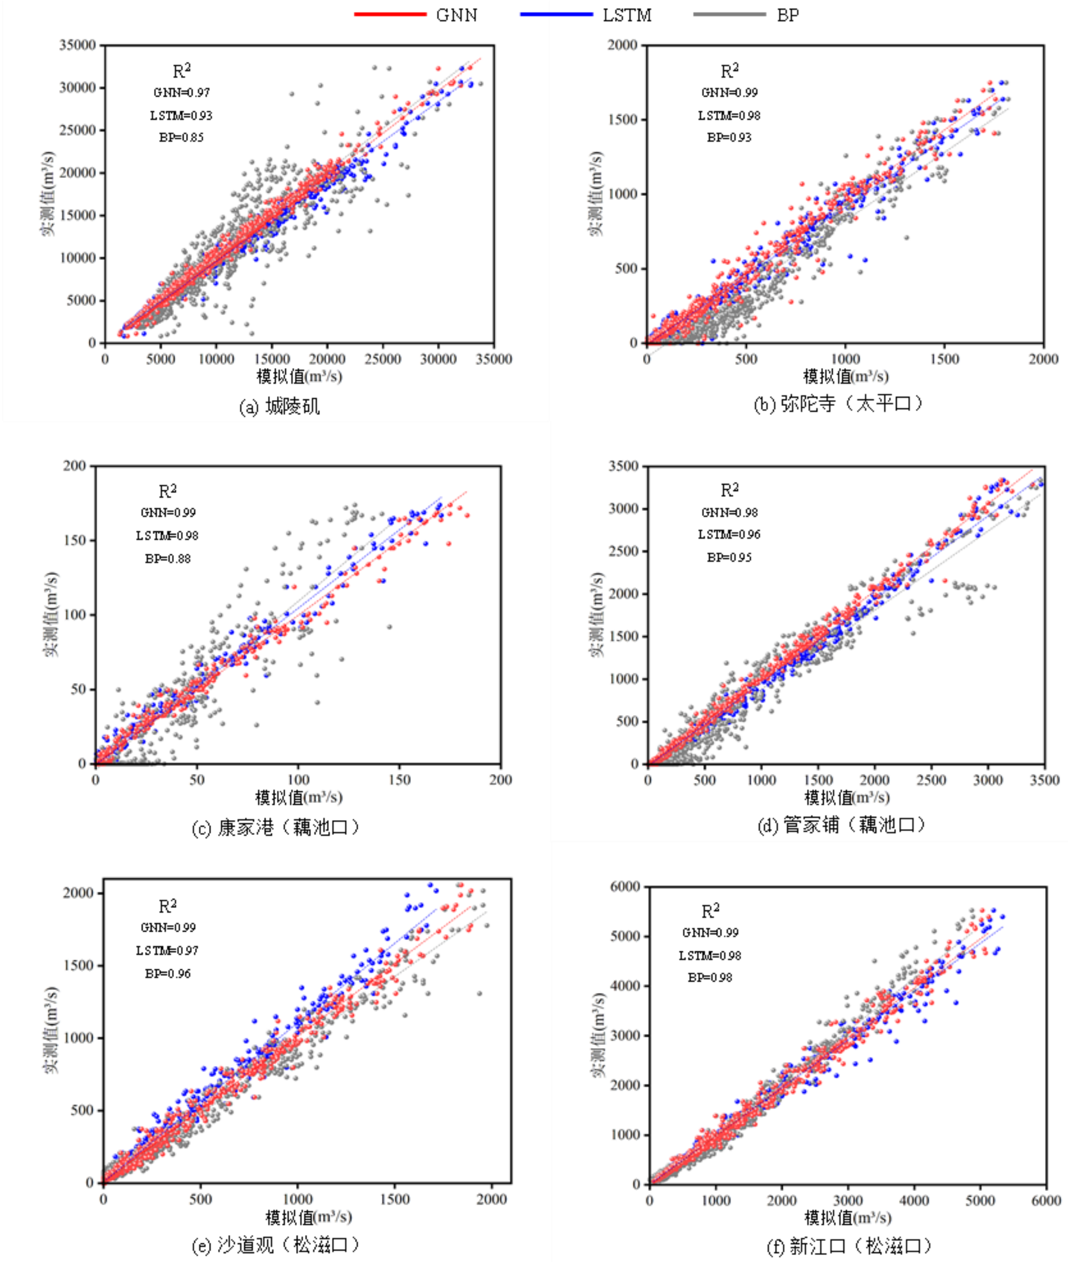

图 3 模型在 6 个站点的实测流量（Q_o）和模拟流量（Q_f）散点回归图

Fig.3 Scattered regression plots of observed flow (Q_o) and simulated flow (Q_f) of the models at 6 stations

3.3 典型丰、枯水年洞庭湖多站点径流模拟结果

3.3.1 2020 年典型丰水年径流模拟

2020 年，长江流域经历了一个典型丰水年，降水量异常增多，导致了新中国成立以来仅次于 1954，1998 年的流域性大洪水事件。受丰水年长江干流来水急剧增加和洞庭湖水位快速增长影响，荆江和三口洪道冲刷加剧，站点之间的径流响应关系变得复杂。因此，为验证模型在丰水年情景下径流响应关系模拟的准确性，本节对比分析 2020 年汛期（5-9 月）3 个模型在 6 个站点洪水模拟结果。

从 6 个站点的洪水流量过程线（图 4）可以看出，在单峰洪水事件（如城陵矶）中，BP 模型的模拟结果坦化，洪峰流量偏低，峰现时间和退水时间提前；对于多峰洪水事件，BP 和 LSTM 模型存在涨水过程（如康家岗和管家铺）和退水过程（如弥陀寺）的模拟精度不足的问题，且 BP 模型在康家岗站、LSTM 模

型在管家铺站的前后洪峰模拟值大小皆具有相似性，表明模型在学习过程中没有充分捕捉到洪水事件中各个洪峰之间的时间依赖性，在模拟过程中平滑了洪峰之间的差异，说明 BP 和 LSTM 模型没法有效刻画多峰洪水过程。GNN 模型表现最佳，在同一个站点中（如康家岗和管家铺）洪水流量急剧变化的情况下，也能保持较高的模拟精度，准确地模拟出洪峰流量的大小和峰现时间（见表 4）；在不同站点间的洪水流量模拟中表现出较高的适应性，能准确把握洪水峰值和变化趋势，说明该模型能够适用于不同的水文条件和河流特性，具有较强的泛化能力。在洪水模拟中，GNN 模型能够捕捉到流域内各个水文站点之间的相互影响和水流路径，相比 BP 和 LSTM 模型能提供更为精确的洪水模拟结果。

表 4 典型洪水 20200820 洪峰误差表
Tab.4 Typical Flood 20200820 Flood Peak Error Table

站点	洪峰流量误差/%			峰现时间误差/天		
	GNN	LSTM	BP	GNN	LSTM	BP
弥陀寺	0.37	2.47	4.01	1	1	1
康家岗	-2.41	3.28	-26.03	0	1	0
管家铺	-1.99	-3.69	8.59	0	0	0
沙道观	-5.09	-8.12	-16.82	0	1	1
新江口	-3.51	-7.32	-11.63	0	1	1

3.3.2 2022 特枯水年断流模拟

2022 年长江流域遭遇丰枯急转的流域性干旱，四水合成流量为近 40 年以来最小，进而加剧了区域内的枯水事件，荆江三口断流现象更加严重，太平口、藕池口断流时间较近 5 年平均提前近 3 个月。根据该典型年的水文数据和模型模拟结果，绘制断流前三口的流量过程线（图 5），对比验证 GNN 模型在特枯水年情景下的三口断流模拟准确性。在康家岗站，GNN 模型的模拟值相比其他模型更为平滑，能够很好地响应非断流时段和断流时段的变化。在弥陀寺站，GNN 模型的模拟值与实测值更为贴合，对于非断流期间的流量变化捕捉要明显优于 LSTM 和 BP 模型，在断流期间流量模拟也相对稳定。对于沙道观站，3 种模型的模拟值均有明显的滞后性，断流期间可能由于上游水库进行调度放水，模拟流量与实测值有所出入，但是 GNN 模型在整个流量过程上表现也较为出色。总体而言，GNN 模型在三个站点的模拟中均显示出了更高的准确性和可靠性，这得益于其强大的图结构学习能力，能够有效地表达出实测值和模拟值之间的关系，尤其是在模拟复杂的河流网络和非线性动态方面的能力。上述结果验证了 GNN 模型在江湖关系持续变化情势下，具备准确模拟洞庭湖多输入-多输出动态径流响应关系的潜力。

4 讨论

在对洞庭湖径流模拟建模过程中，难点在于准确捕捉和模拟由于长江荆南三口地区的水系连通变异性产生的复杂时空关联和非线性响应关系。本研究提出一种基于图神经网络的多输入—多输出径流响应模型，通过与 LSTM 和 BP 模型对比验证，系统地评估了它在洞庭湖径流模拟中挖掘水文变量的空间关联特征和提升径流模拟精度方面的性能和可靠性。

GNN 作为一种新兴的机器学习技术，擅长处理非欧几里得结构数据，有效地捕捉变量间的复杂关系，提升径流模拟精度[15]。相比之下，传统的机器学习模型（LSTM 和 BP 等）在处理多输入—多输出的径流响应时，由于无法充分考虑流域内各站点之间的空间关联和相互作用，存在明显局限。Zhang 等人[16]提出一种基于 GNN 的城市排水网络模型，证明了图结构对于径流模拟的经济高效性。Oliveira 等人[17]则利用 GNN 模型对洪水事件进行预报，研究结果表明在 3h 预见期范围内模型表现出色。

在长江荆南三口地区的径流模拟中，上游水库下泄清水导致荆南三口河道不对等冲刷，以及河湖关系

的动态变化，这些因素共同造成了径流模拟的动态非线性特性。本研究提出的图神经网络考虑了站点的空间关系，并且通过多层图注意力机制对这种动态变化进行充分学习。在汛期，荆南三口地区的径流特点表现为流量急剧增加和洪峰频繁，这要求模型能够快速响应并准确模拟洪水事件的发展过程。如图 4 和表 4 所示，在典型洪水事件模拟中，GNN 模型能够准确捕捉洪峰流量和峰现时间，取得了显著的预测性能。在非汛期典型枯水事件的模拟中，GNN 模型同样展现出了其在捕捉枯水期径流变化方面的优势，如图 5 所示，模型能够精确模拟断流现象和低流量时段，为枯水期水资源管理和调度提供了有力的支持。这些研究结果表明，GNN 模型在处理具有复杂时空关联的径流模拟问题时，相较于传统的 LSTM 和 BP 模型，具有明显的性能优势。

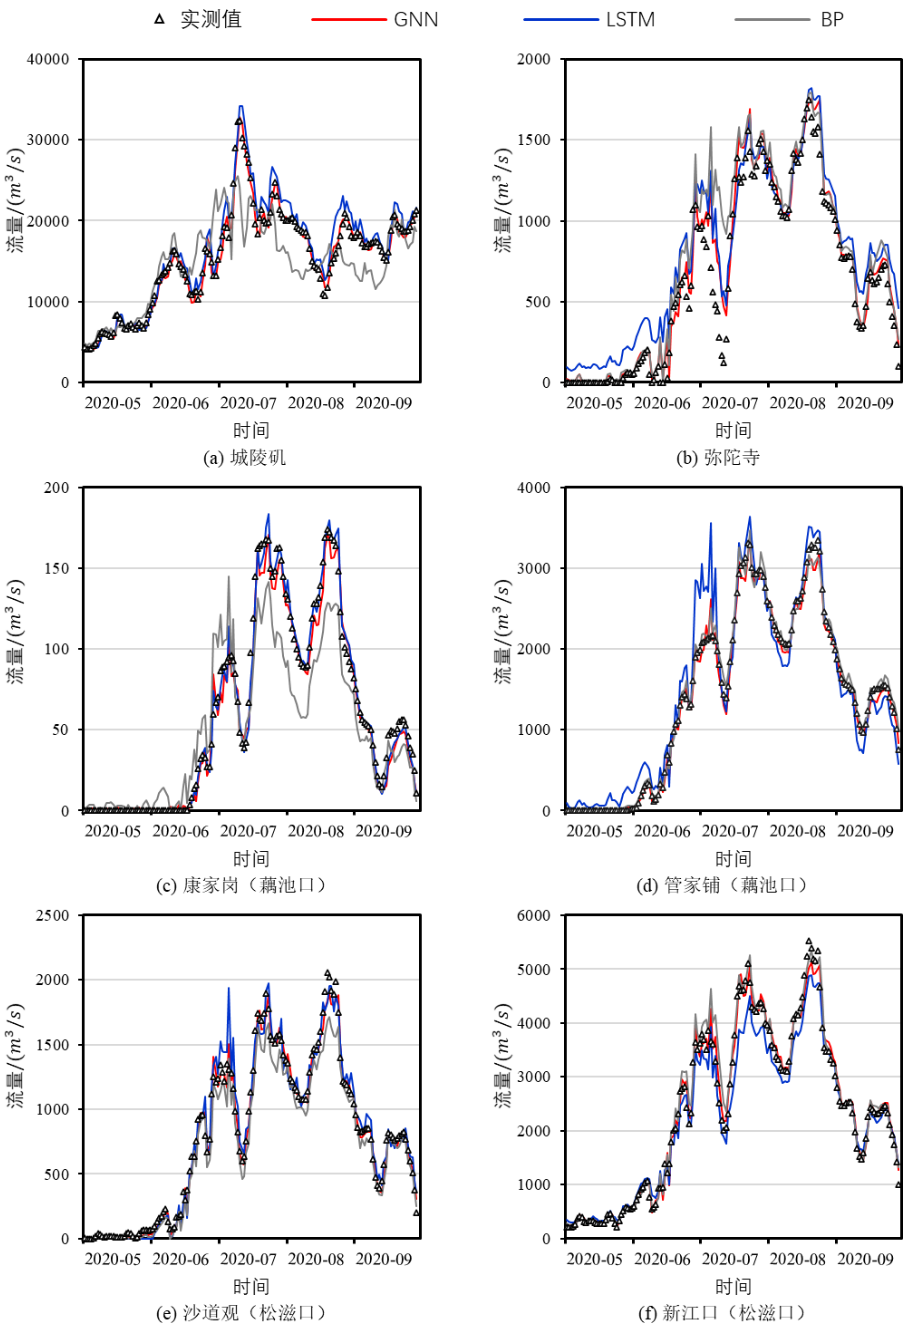

图 4 模型在 6 个站点典型洪水流量过程线对比（2020 年）

Fig.4 Comparison analysis of three models for representative flood processes at six stations（2020）

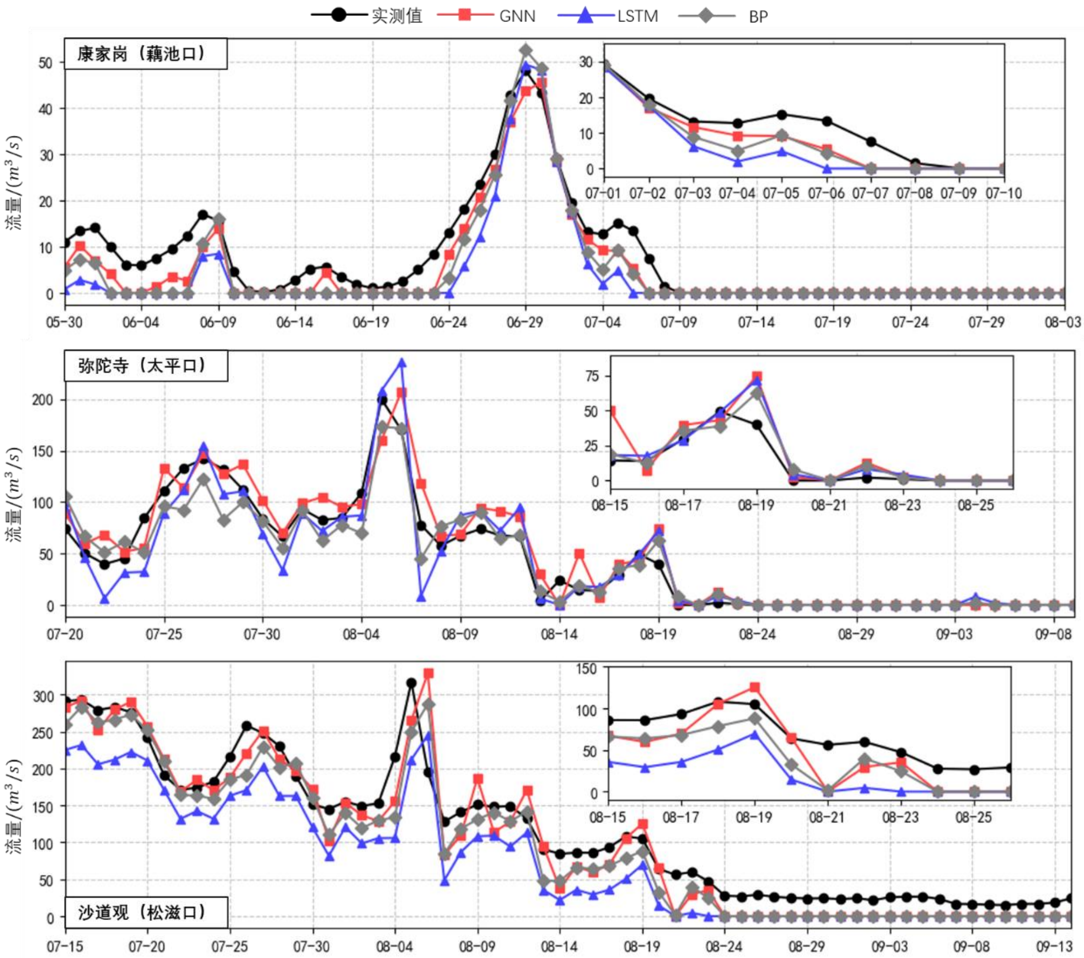

图 5 荆江三口断流期间流量过程线（2022 年）
Fig.5 The flow interruption processes of the three control stations of the Jingjiang River（2022）

5 结语

本文以长江荆江段与洞庭湖水系为研究区域，提出了一种基于图神经网络（GNN）的径流模拟模型，通过与经典的 BP 神经网络和 LSTM 模型的对比，实现精度评估、可靠性验证，并完成了洪水和枯水过程的模拟，主要结论如下：

（1）在训练和测试阶段，GNN 模型的总体模拟结果显著优于 BP 和 LSTM 模型，NSE 和 MAE 普遍提高了 5%以上，城陵矶站点的 NSE 指标高达 0.998，断流事件的指标 TPR 和 Precision 指标值超过 0.96，说明图结构学习能更加精细地捕捉和模拟流域内各个水文站点间的相互影响和水流路径。

（2）GNN 模型在可靠性评估中表现突出，其散点图中模拟值与实际值高度拟合，在 6 个站点中的 R^2 均超过 0.97，具有更强的数据拟合能力和更低的模拟误差，模型的模拟可靠性更好。

（3）在模拟洪水流量过程和断流现象中，GNN 模型能准确捕捉洪水事件的洪峰流量和时间，以及枯水期的断流现象，验证了 GNN 模型在动态径流响应模拟中的实际应用潜力和高效性能。

本研究提出的 GNN 模型通过模拟分析洞庭湖的洪水与枯水过程，为科学应对特殊水文事件、保障区域水资源安全以及修复河湖健康生态系统等方面提供了水文基础支撑。未来可考虑人类活动对水文过程的影响，以提高模型在受影响区域的适用性。

6 参考文献

[1] Pan HM, Cai HY, Wang BZ et al. Evolution characteristics of water temperature in Dongting Lake from 1973 to 2020. Journal of Lake Sciences, 2023, 35(01): 326-337. [潘惠敏，蔡华阳，王博芝等. 1973-2020 年洞庭湖水温演变特征. 湖泊科学, 2023, 35(01): 326-

337.]

[2] Chai ZQ, Guo XH, Zhu YH et al. Research Progress on the Relationship between Jingjiang River and Dongting Lake after the Operation of Three Gorges Project. Journal of Yangtze River Scientific Research Institute, 2023, 40(04): 17-23+30. [柴泽清, 郭小虎, 朱勇辉. 三峡工程运用后荆江与洞庭湖关系变化研究进展. 长江科学院院报, 2023, 40(04): 17-23+30.]

[3] Xia J, Chen J, She DX. Impacts and countermeasures of extreme drought in the Yangtze River Basin in 2022. Journal of Hydraulic Engineering, 2022, 53(10): 1143-1153. [夏军, 陈进, 佘敦先. 2022 年长江流域极端干旱事件及其影响与对策. 水利学报, 2022, 53(10): 1143-1153.]

[4] Yin XY, Song SM, Yan GH et al. Construction and application of aquatic ecological risk assessment model for Dongting Lake. Water Resources and Hydropower Engineering, 2022, 53(S1): 45-53. [殷雪妍, 宋思敏,严广寒等. 洞庭湖水生态风险评价模型构建及应用. 水利水电技术(中英文), 2022, 53(S1): 45-53.]

[5] Zhang DD, Dai ML, Chen X et al. Influences of topographical change of Jingjiang reach on hydrological situation of Dongting Lake. Water Resources Protection, 2022, 38(06): 71-80. [张冬冬, 戴明龙, 陈玺等. 荆江河段地形变化对洞庭湖水文情势的影响. 水资源保护, 2022, 38(06): 71-80.]

[6] Zhu BY, Xu Q, Zhu LL et al. Variations in water diversion at three outlets to Dongting Lake from Jingjiang River based on identification of multiple factor contributions since 1955. Journal of Lake Sciences, 2023, 35(05): 1832-1844. [朱博渊, 徐琪, 朱玲玲等. 1955 年以来入洞庭湖的荆江三口分流变化. 湖泊科学, 2023, 35(05): 1832-1844.]

[7] Xiao X, Mao BP, Wu SQ. Dynamics of hydrological characteristics in Changjiang River and Dongting Lake confluence reach in the past 100 years. Journal of Lake Sciences, 2021, 33(01): 266-276. [肖潇, 毛北平, 吴时强. 近 100 年来长江与洞庭湖汇流河段水文特征演变. 湖泊科学, 2021, 33(01): 266-276.]

[8] Sun ZD, Huang Q, Lotz Tom. Parameter optimization for swat model and its extended application in the Dongting Lake basin, Yangtze River. Resources and Environment in the Yangtze Basin, 2015, 24(08): 1299-1304. [孙占东,黄群, Lotz Tom. 洞庭湖流域分布式水文模型. 长江流域资源与环境, 2015, 24(08): 1299-1304.]

[9] Zhao WG, Liu XQ, Song W et al. Preliminary study on runoff forecast at Nanzui Station in West Dongting Lake based on PSO-BP neural network. Yangtze River, 2019, 50(03): 124-130. [赵文刚, 刘晓群, 宋雯等. 基于 PSO-BP 神经网络的西洞庭湖南咀站径流预测. 人民长江, 2019, 50(03): 124-130.]

[10] Zhang RZ, Dai LQ, Dai HC et al. Spatial heterogeneity analysis of the impact of the Three Gorges Reservoir impounding on the water level of Dongting Lake based on the improved LSTM model. Water Resources and Hydropower Engineering, 2022, 53(02): 98-108. [张睿芝, 戴凌全, 戴会超等. 基于改进 LSTM 模型的三峡水库蓄水对洞庭湖水位影响的空间异质性分析. 水利水电技术(中英文), 2022, 53(02): 98-108.]

[11] Deng L, Zhang X, Slater J L et al. Integrating Euclidean and non-Euclidean spatial information for deep learning-based spatiotemporal hydrological simulation. Journal of Hydrology, 2024, 638: 131438.

[12] Zhang ZD, Tang HH, Qin H et al. Multi-step ahead probabilistic forecasting of multiple hydrological variables for multiple stations. Journal of Hydrology, 2023, 617: 120094.

[13] Ma S, Liu JW, Zuo X. Survey on Graph Neural Network. Journal of Computer Research and Development, 2022, 59(01): 47-80. [马帅, 刘建伟, 左信. 图神经网络综述. 计算机研究与发展, 2022, 59(01): 47-80.]

[14] Sun AY, Jiang P, Mudunuru, MK et al. Explore Spatio-Temporal Learning of Large Sample Hydrology Using Graph Neural Networks. Water Resources Research, 2021, 57(12): e2021WR030394.

[15] Deng LK, Zhang X, Louise J. Slater, Liu HY, Tao SY. Integrating Euclidean and non-Euclidean spatial information for deep learning-based spatiotemporal hydrological simulation, Journal of Hydrology, 2024, 638: 131438

[16] Zhang ZY, Tian WC, Lu CKX, Liao ZL, Yuan ZG. Graph neural network-based surrogate modelling for real-time hydraulic prediction of urban drainage networks, Water Research, 2024, 263: 122142

[17] Oliveira Santos V, Costa Rocha PA, Scott J, Thé JVG, Gharabaghi B. A New Graph-Based Deep Learning Model to Predict Flooding with Validation on a Case Study on the Humber River. *Water*. 2023, 15(10):1827.