

基于物联网和 GCNN-LSTM 的河流水文预测方法

刘丽娜¹, 罗清元², 方强³

(1. 郑州大学 河南省超算中心, 郑州 450001; 2. 河南省水文水资源测报中心, 郑州 450003;
3. 信阳市生态环境局 光山分局, 河南 信阳 465499)

摘要: 针对河流水文存在预测精度不高的问题, 利用物联网技术设计了分布式的降雨和水文信息自动采集系统, 并提出了一种基于图卷积神经网络和长短期记忆网络模型对河流水位和径流量进行预测的方法; 首先通过分析确定了影响河流水文的主要因素, 将流域范围内的降雨量信息组成网格化的二维图形矩阵; 然后提出了 GCNN-LSTM 预测模型, 将含有降雨信息的二维图形矩阵作为网络模型的输入, 获取该流域内降雨与水文变化的时空分布特征; 最后采用所提出的 GCNN-LSTM 预测模型对河南省周口市段颍河的历史水文数据进行训练, 再利用训练后的网络对测试集数据进行预测, 得到了较高精度的径流量和水位结果, 径流量预测结果的 RMSE、MAPE 和 MAE 分别仅为 17.09 m³/s、1.68% 和 8.57 m³/s, 水位预测结果的 RMSE、MAPE 和 MAE 分别仅为 0.32 m、0.65% 和 0.29 m, 与其他几种预测方法相比表现出了优越性, 对科学合理利用水资源和防洪减灾具有重要意义。

关键词: 河流水文预测; 物联网; 降雨量; 图卷积神经网络; 长短期记忆; 径流量和水位

River Hydrological Prediction Method Based on GCNN- LSTM

LIU Lina¹, LUO Qingyuan², FANG Qiang³

(1. Super Computer Center of Henan Province, Zhengzhou University, Zhengzhou 450001, China;
2. Hydrology and Water Resources Monitoring and Reporting Center of Henan Province, Zhengzhou 450003, China;
3. Guangshan Branch of Xinyang Ecological Environment Bureau, Xinyang 465499, China)

Abstract: Aiming at the problem of low prediction accuracy in river hydrology, a distributed automatic collection system for rainfall and hydrological information was designed using Internet of Things technology. A method for predicting river water level and runoff based on graph convolutional neural networks and Long Short-Term Memory (GCNN-LSTM) network models was proposed. Firstly, the main factors affecting river hydrology were identified through analysis, and the rainfall information within the watershed was composed into a grid based two-dimensional graphical matrix. Then, a GCNN-LSTM prediction model was proposed, using a two-dimensional graphical matrix containing rainfall information as input to the network model to obtain the spatiotemporal distribution characteristics of rainfall and hydrological changes in the watershed. Finally, the proposed GCNN-LSTM prediction model is used to train the historical hydrological data of the Yinghe River in Zhoukou City, Henan Province, then the trained network is utilized to predict the test set data and get a high-precision results of runoff and water level, and the RMSE, MAPE, and MAE of the runoff prediction results are only 17.09 m³/s, 1.68%, and 8.57 m³/s, respectively, while the RMSE, MAPE, and MAE of the water level prediction results were only 0.32 m, 0.65%, and 0.29 m, respectively, compared with other prediction methods, which demonstrates superiority and has a great significance for the scientific and rational utilization of water resources and flood control and disaster reduction.

Keywords: river hydrological prediction; internet of things; rainfall; graph convolutional neural networks; long short-term memory; water level and runoff

0 引言

我国幅员辽阔, 河流山川交错, 形成了复杂的河流水系, 人们通过修建各式各样的水坝对河流进行调节, 实现对水资源的更加合理利用^[1-3]。然而, 受不确定降雨的影响, 河流水位会有暴涨的情况发生, 给现有的水利调节带来巨大的挑战, 当暴雨长时间持续时, 甚至会出现流域灾害, 严重威胁人民的生命财产安全^[4-5]。例如: 2021 年 7 月

17 日至 23 日, 河南省遭遇了百年不遇的特大暴雨, 局部地区的累计降雨量高达 1 122.6 毫米, 导致河南省中北部地区的 12 条主要河流水位暴涨, 发生出现了历史罕见洪涝灾害, 此次灾害造成河南省境内 1 478.6 万人受灾, 292 人遇难, 47 人失踪, 直接经济损失高达 1 200.6 亿元, 给人民群众造成了巨大的损失。2023 年 8 月, 北京门头沟和房山地区也出现了持续的强降雨, 引发罕见的河水暴涨、洪涝和山洪等自然灾害, 造成近 129 万人受灾, 33 人死亡, 18 人

收稿日期: 2023-09-27; 修回日期: 2023-11-10。

基金项目: 河南省高等学校重点科研项目(22B520020)。

作者简介: 刘丽娜(1983-), 女, 硕士, 工程师。

引用格式: 刘丽娜, 罗清元, 方强. 基于物联网和 GCNN-LSTM 的河流水文预测方法[J]. 计算机测量与控制, 2024, 32(7): 288-293, 300.

失踪，5.5 万间房屋倒塌，农作物受灾面积达 22.5 万亩。面对这种情况，水文监测已经无法满足水利治理的需求，需要结合气象信息对河流水文进行准确的预测，提前做好防范措施，风险极大时，还可以向民众发出预警进行紧急撤离，避免出现更大的次生灾害^[6]。

近年来，越来越多的科研机构和专家对流域灾害预警预报进行深入研究^[7-8]。林瑜等人^[9]提出了基于马斯京根模型的融冰洪水演进模拟，并以黄河宁蒙河段为例进行了分析，得到了预期的效果。郑莉萍等人^[10]利用 SWAT 模型对璧南河流域进行研究，在 2013—2020 年月尺度上的模拟径流与实测径流拟合良好，得到了精度较高的径流量，相对误差绝对仅为 7.85%。虽然这些传统的预测方法能够实现高精度的洪水预报，但是存在建模过程复杂、内部参数过多和开发难度过大等问题。基于数据驱动型的 SVM 模型^[11]的结构相对简单，但是无法考虑降雨的空间分布特性对河流水文的影响，导致预测精度较低和泛化能力较弱。

随着人工智能和深度学习技术的发展，卷积神经网络被大量应用在了水文预测领域。王军等人^[12]利用时间卷积神经网络和注意力机制提出了径流量预测模型，大幅提升了预测精度。Jordan 等人^[13]利用长短期记忆网络对克林奇河支流康纳溪流域系统中遥感器收集的原始、多模态时间序列数据进行分析，较为准确地预测了水位的变化情况，在未来 5 分钟和 120 分钟的平均绝对误差分别为 0.158 和 0.490 英尺，从而验证了改方法的有效性。徐刚等人^[14]提出了基于卷积神经网络的径流量预测模型，通过对多维度数据的特征提取，找到降雨量与水文数据的内在联系，从而得到较高精度的预测结果。Xia 等人^[15]基于社区检测的联合学习，利用图卷积网络和长短期记忆建立了交通流预测模型，解决了随着数据量的增加而过多消耗全局 GCN 训练时长的问题，实现了流量、速度和占用率的短期交通预测。虽然这些基于数据驱动型的预测模型避免了大量关键参数的设定，但是存在数据量少以及对降雨数据特征挖掘不足的问题，忽略了空间分布特征和时间分布特征对水文预测的影响，所以预测精度仍然有提升的空间。综上所述，本文以河南省周口市境内的颍河为研究对象，设计了基于物联网的分布式自动信息采集系统，并大量部署在该流域内，来获取降雨和水文站的数据。同时，提出了一种基于图卷积神经网络和长短期记忆的（GCNN-LSTM，graph convolutional neural networks and long short-term memory）预测网络模型，通过对采集到的大量历史数据进行训练，获取该流域内时空分布特征与水文变化的关系。实验结果表明，提出的分布式信息采集系统能够实时准确获取降雨和水文信息，网络模型能够准确预测出径流量和水位，从而为防洪减灾预报和水资源规划的合理利用提供了数据支持。

1 河流水文分析及分布式自动采集系统

径流量和水位是河流水文信息中最重要的两项指标。径流量越大，说明汇入河流的水量越多。通常情况下，径

流量的增大，也会导致水位的上涨，而水位超过堤坝的安全线后，就会对周围的群众安全造成威胁^[16]。

1.1 河流水文分析

影响河流水文变化的因素有很多，包括上游各支流的来水量、流域内的自然降雨量、蒸发量、植被覆盖率、土壤条件和人工取水等。河流的总流量 Q_A 可以表示为：

$$Q_A = Q_L + Q_I - Q_Z - Q_h - Q_y \tag{1}$$

式中： Q_L 表示上游各支流汇入的来水量总和； Q_I 表示影响该流域内的降雨量； Q_Z 表示流域内水分的蒸发量； Q_h 表示流域内因土壤条件和地势条件造成的未汇入河流的含水量和存水量； Q_y 表示引渠灌溉取水水量。

上游各支流汇入的水量总和能够通过水文站测量获得，降雨量可以通过气象站测量得到，引渠灌溉取水水量则也可以通过测量水渠截面流量计算得到。然而，水分蒸发量、土壤含水量和存水量等因素造成的水源流失则非常难以直接测量和计算。众所周知，大多数内陆河流主要通过雨水补给，是决定河流水位和径流等水文变化的最主要因素，属于空间特性。另外，从雨水落到地面到汇入河流需要一定的时间，雨水所走的路径不同，最终到达的时间也不尽相同，这属于时间特性。本文将以降雨量为河流水文变化的主要研究变量，采用深度学习技术建立预测模型，探究河流水文变化与各因素潜在的时空特征联系，实现对径流量和水位的高精度预测。

1.2 分布式自动采集系统

为了更加准确预测河流径流量及水位，需要更加全面和准确的气象信息^[17-18]。针对山区气象站密度低、实时性差和数据代表性不足的问题，本文利用物联网技术搭建了分布式自动信息采集系统，通过在流域范围内部署大量的监测节点，获取更加准确、全面和及时的降雨量和水文信息。基于物联网的分布式自动采集系统结构如图 1 所示。系统主要由物联网服务平台、监测节点、水文站监测节点、引渠灌溉监测节点、水文总站监测中心以及预警系统等组成。

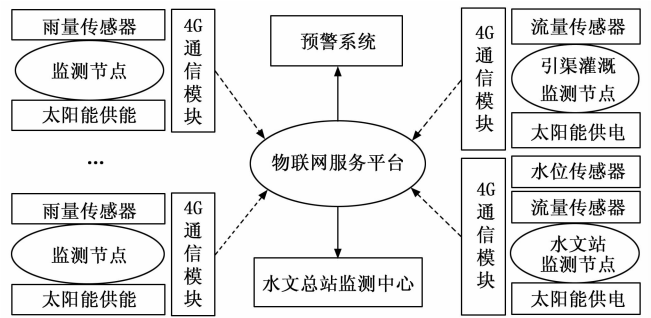


图 1 基于物联网的分布式自动采集系统结构

监测节点主要负责收集降雨量信息，并通过 4G 无线网络将发送至物联网云平台。水文监测站节点则采集各支流和干流的径流量和水位信息，引渠灌溉监测节点则负责采集所有水渠流量信息，并计算出上游农业用水均，均

通过 4G 无线网络将数据发送至物联网云平台。水文总站监测中心与物联网平台连接,负责各节点参数配置、数据管理、电池监测、水文预测和数据显示等功能,当遇到持续降雨时,会利用当前的实时降雨或者气象数据在水文预测模型中进行推演,得到未来一段时间的径流量和水位,结合当地的防洪标准,提前向公众和有关部门做好防洪减灾预警,并采取必要措施,为应急抢险等工作提供科学依据和理论支撑。

考虑到设备大部分部署在户外,势必会受到供电条件的限制,故节点均采用了太阳能供电方式,来确保节点能够持续工作。但是,如果遇到连续的阴雨天气,节点的供电保障将会遇到极大挑战,本文从三方面进行了增强设计:

1) 增大蓄电池容量。采用 12 V/100 AH 的大容量铅酸免维护蓄电池,并配备了 150 W 的太阳能光伏电池板对其进行充电;

2) 节点采用了省电休眠模式。根据设计的测量周期,自动唤醒后进行测量,测量完毕后则进入休眠省电模式,从而节省电量开销;

3) 电池监测管理。节点的程序中设置了监测功能,会自动将电池的健康状态以及剩余电量的信息发送到监测中心,方便了解每个节点的供电状态,出现异常后可安排人工维护,确保每个节点的正常运行。

2 基于 GCNN-LSTM 的预测模型

河流的水文信息与流域内的降雨存在着时空关系,降雨的位置、地形、降雨量、降雨持续时长都会直接影响河流的水文信息,所以水文站的预测需要同时考虑时空特性。本文提出了一种基于图卷积神经网络 (GCNN) 和长短期记忆 (LSTM) 的水文预测网络模型,如图 2 所示。

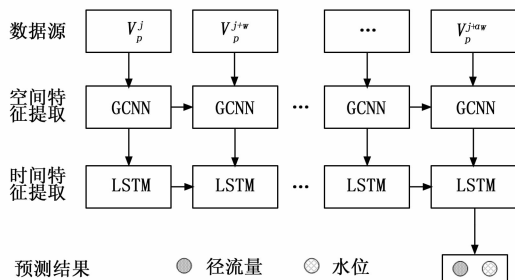


图 2 GCNN-LSTM 的预测模型

首先利用设计的分布式自动信息采集系统获取流域内降雨和水文信息,并对降雨信息进行网络化预处理,转变成二维图数据。然后,以窗口时刻降雨量为基础,将含有降雨量信息的二维图数据作为图卷积神经网络 (GCNN) 的输入变量,提取降雨分布情况与水文变化关系的空间特性。最后,把窗口时刻 GCNN 的所有输出序列作为长短期记忆网络 (LSTM) 的输入,挖掘窗口时刻与预测时刻的时间特征,从而实现对降雨与水文变化的时空特性融合。利用历史数据对预测网络训练后,便可利用实际测量到的降雨信

息或者预报的气象数据,更加准确地预测未来一段时间的径流量和水位。

2.1 降雨信息网络化预处理

部署的气象监测节点越多,就越能更加全面和准确地反应该地区的降雨量信息,预测的水文信息也就越准确。然而,部署大量的监测节点需要投入高额的建设成本和后期维护成本。综合考虑地理条件和建设条件等各种因素,本文采用网格化的方法进行预处理。首先确定气象信息采集区域,并将该区域划分成 $N \times M$ 个小方格,如图 3 所示,假设横纵网格线的交叉点为 $p_{n,m}$,坐标为 (n, m) ,其中 $1 \leq n \leq N, 1 \leq m \leq M$,即可将交叉点 $p_{n,m}$ 类比作图像的像素点,该像素点的属性值为 $q_{n,m}$,即该点处的降雨量。然后假设区域内有 D 个气象监测节点(空心圆点),第 d 个雨量监测站的坐标为 (x_d, y_d) ,对应采集到的降雨量为 q_{x_d, y_d}^d 。




图 3 网格化预处理示意图

本文采用虚拟近似法将网格线交叉点位置的降雨量用距离其最近气象站测量得到的降雨量表示。首先计算出网格交叉节点 $p_{n,m}$ 与第 d 个气象站之间的距离 $f_{n,m}(x_d, y_d)$,表达式如下:

$$f_{n,m}(x_d, y_d) = \sqrt{(n - x_d)^2 + (m - y_d)^2}, 1 \leq d \leq D \quad (2)$$

然后,存在一个气象站 (x_k, y_k) 距离 $p_{n,m}$ 最小,将 (x_k, y_k) 处气象站采集到的降雨量 q_{x_k, y_k}^k 赋值给 $q_{n,m}$,并遍历所有的点,便会得到一个 $N \times M$ 的二维数据矩阵,能够更加全面和准确地反应该地区降雨量信息,表达式如下:

$$\begin{cases} \exists (x_k, y_k), \min f_{n,m}(x_k, y_k), 1 \leq k \leq D \\ q_{n,m} = q_{x_k, y_k}^k, 1 \leq n \leq N, 1 \leq m \leq M \end{cases} \quad (3)$$

为了提高模型的学习效率,对同一窗口期内的数据进行归一化处理,计算方法如下:

$$q_{n,m} = \frac{q - q_{\min}}{q_{\max} - q_{\min}} \quad (4)$$

式中: q_{\min} 和 q_{\max} 分别表示同一窗口期内的最小和最大的降雨量。

经过网络化预处理后,矩阵中的每个元素都能代表该区域附近的降雨信息,符合图数据的结构形式,用 V_p^{j+aw} 表示,其中, V_p^j 表示第 j 时刻该流域内形成的二维网格化矩阵, w 表示采集周期, aw 表示预测窗口时间。

2.2 空间特征提取

本文通过构建图卷积神经网络 (GCNN) 对含有降雨信息的二维图数据进行挖掘,来提取降雨的分布情况与水文

信息之间的空间特征。GCNN 是以图数据为对象的卷积神经网络, 能够提取非欧结构的空

间特征^[19-20]。通过分布式的降雨采集系统获得窗口时间的降雨量二维图数据 $V = (Q, E, A)$, Q 表示二维数据矩阵中虚拟近似后节点上的降雨信息集合, E 表示边的集合, A 表示邻接矩阵。假设图卷积神经网络的函数为 f , 输入和输出分别为 X 和 Y , 则表达式为:

$$Y = f(X, A) \tag{5}$$

通过邻接矩阵 \tilde{A} 和特征矩阵 H^l 相乘获得邻接特征, 再乘参数权重矩阵 W^l , 然后利用激活函数进行非线性处理, 最终得到邻接顶点特征矩阵 $H^{(l+1)}$ 。

图卷积的传播形式为:

$$H^{(l+1)} = \sigma(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} H^l W^l) \tag{6}$$

式中: H^l 表示第 l 层卷积后输出的特征矩阵; W^l 表示第 l 层的权重参数; σ 表示激活函数; $\tilde{A} = A + I$, 其中 I 为单位矩阵; \tilde{D} 表示 \tilde{A} 的度矩阵。

经过图卷积神经网络处理后, 能够建立起流域内每个虚拟点的降雨量与水文变化之间的空间特征联系。另外, 降雨对河流水文的影响具有累加效应, 且雨水从上游流入河流需要经过复杂的地形, 需要一段时间后才能抵达水文站, 所以降雨位置、降雨量和地形等因素与水文之间还需要找出对应的时间特征关系。

2.3 时间特征提取

本文采用 LSTM 网络挖掘时间特征, 每个 LSTM 通过内部特殊的结构存储短期和长期的数据信息, 能够解决长序列数据在训练过程中的梯度消失和爆炸的问题, 从而准确提取出降雨与水文的时间特征。LSTM 单元结构如图 4 所示。




图 4 LSTM 单元结构

LSTM 主要有遗忘门、更新门和输出门三部分组成^[21-22]。遗忘门可以判别是哪些信息要遗弃, 表达式为:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \tag{7}$$

更新门负责判别哪些信息要更新, 表达式为:

$$\begin{cases} i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \\ C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \end{cases} \tag{8}$$

输出门则负责对结果进行过滤, 输出预测值, 表达式为:

$$\begin{cases} o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \\ h_t = o_t * \tanh(C_t) \end{cases} \tag{9}$$

式中: σ 和 \tanh 为激活函数; x_t 为窗口时刻的水文数据; h_t 表示隐藏状态向量; f_t, i_t, o_t, c_t 分别表示遗忘门、输入门、输出门和细胞状态; W_f, W_i, W_o, W_c 分别表示状态更新的权重系数矩阵; b_f, b_i, b_o, b_c 分别表示状态更新的偏置矩阵。

通过引入长短期记忆网络, 能够找到降雨信息与水文变化之间的时间特征, 即通过对历史发生的降雨以及当下降雨量数据的分析, 就可以预测未来一段时间的水文变化情况, 消除了因降雨和水文变化的时间差影响, 从而大幅提升了预测精度。

3 实验结果与分析

本文以河南省周口市境内的颍河为研究对象进行实验, 首先利用设计的分布式自动信息采集系统获取长期大量的降雨和水文数据, 然后利用提出的预测模型对历史数据训练, 最后与不同的预测方法进行对比, 来验证本文方法的优越性。

3.1 研究区域

颍河发源于河南省登封县嵩山, 全长 620 公里, 流经平顶山、许昌、漯河等地区, 大部分为山地, 地形结构复杂。该河流流经周口市主城区, 上游有沙河和贾鲁河共计两条主要支流, 是农业灌溉的重要水源, 也是洪涝灾害严重的河流, 本文选择周口监测站上游 80×80 公里的区域为降雨观测区域。周口市颍河流域简图如图 5 所示。




图 5 周口市颍河流域简图

3.2 数据集及训练

为了验证本文提出的水文预测方法的有效性和优越性, 采用设计的基于物联网技术的分布式自动信息采集系统对颍河周口流域内 128 个位置的气象和水文信息以小时为采样周期进行监测, 得到近 5 年 (2017 年—2022 年) 的降雨量和各支流的水位及径流量等信息, 保存后形成了海量的数据集。将获得到的数据集分成训练集与测试集两部分, 以降雨信息作为本文提出预测模型的输入, 并以水文站测量得到的径流量和

表 1 训练超参	
参数	取值
迭代次数	500
批次大小	128
损失函数	MSE
优化器	Adam
学习率	0.001

为了进一步验证本文提出的预测模型的优越性,选用 2021 年 7 月份的数据作为研究对象,该流域从 20 日发生了较大的降雨量,导致颍河干流周口水文站的径流量和水位出现了较大幅度的变化,采用本文设计的分布式自动采集系统监测得到的个周口水文站日均水文结果,如表 2 所示。

表 2 周口水文站 2021 年 7 月水文监测结果

日期	径流量(m^3/s)	水位(m)
1	19.2	43.10
2	15.3	43.10
3	11.0	43.05
4	13.6	43.07
5	21.4	43.02
6	41.4	43.06
7	51.5	42.99
8	43.1	43.43
9	18.1	43.01
10	6.16	42.82
11	27.8	42.93
12	33.0	43.11
13	29.7	42.94
14	26.9	42.95
15	59.6	43.06
16	60.6	42.97
17	86.3	43.16
18	97.7	43.10
19	60.8	43.12
20	274.0	43.33
21	834.0	44.18
22	1 700.0	46.89
23	1 980.0	48.10
24	1 830.0	47.62
25	1 630.0	47.01
26	1 510.0	46.56
27	1 480.0	46.46
28	1 400.0	46.24
29	1 250.0	45.85
30	946.0	44.88
31	398.0	42.62

从表 2 的测量结果可知,2021 年 7 月份的 1—14 日,周口市及上游的主要城市的降雨量相对较小,主要以阴天及小雨天气构成,降雨量均在 50 mm 以下,未给颍河的流量和水文带来较大明显的变化,径流量在 $15\sim 30\text{ m}^3/\text{s}$ 的范围波动,水位保持在 43 米左右。从 15 日—19 日,周口市以及颍河上游的许昌、漯河和平顶山等地陆续出现强降雨天气,降雨量达到了 $100\sim 200\text{ mm}$,至 20 日,水文站的径流量和水位分别达到了 $274\text{ m}^3/\text{s}$ 和 43.43 m,径流量是平时的数倍。随后几日,又出现了更大范围和规模的降雨,局部地区则出现了特大暴雨,降雨量达到 $250\sim 350\text{ mm}$,到 23 日径流量和水文达到了顶峰,此时径流量和水位分别达到了 $1\,980\text{ m}^3/\text{s}$ 和 48.10 m。从 24 日开始至 31 日,周边

的降雨量从大雨逐渐转为中小雨,降雨量逐日减少,径流量和水位也随之减少和降低,采集到的水文变化情况与气象数据非常吻合,说明本文设计的分布式水文采集系统能够准确地测量出水文站的径流量和水位。

3.3 不同预测算法的对比分析

为了验证本文所提预测模型的优越性,采用文献 [12] 中的时间卷积神经网络和注意力机制(记作:TCN-Attention)预测模型、文献 [14] 中的多维度数据的卷积神经网络(记作:MD-CNN)预测模型和本文所提预测模型(记作:GCNN-LSTM)对 2021 年 7 月份的日均径流量和水位进行预测,得到的预测结果如图 6 所示。其中,实线表示实测值。

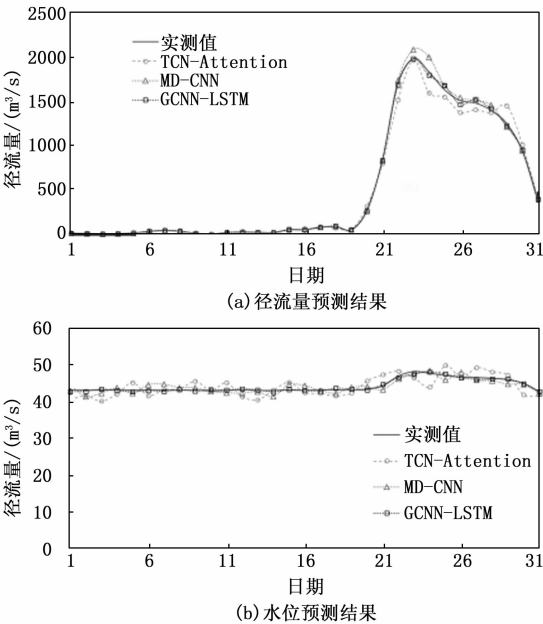


图 6 不同方法下水文预测结果

从图 6 的结果可看出,这几种方法均能有效预测出河流的径流量和水位。当未出现持续的降雨时,径流量的误差并不明显。从 20 日—31 日出现了较大范围和较大规模的降雨,导致径流量急剧增大,同时水位也明显提升,不同预测方法出现较大的预测误差。其中,文献 [12] 中的 TCN-Attention 模型结合时间卷积神经网络将流量、降水量、含沙量作为模型的输入,来提取特性信息,并引入注意力机制减少了无用信息量,但由于缺乏对影响水文变化的主要因素(降雨量)进行精细化处理,导致预测值曲线与实际值偏离较大,预测精度较差。文献 [14] 中的 MD-CNN 预测模型对流域进行了网格划分,并将各变量数据处理为高维张量数据形式,使得预测值曲线与实际值较为接近,预测精度有明显提升,但因忽略了降雨与河流水文形成的时间差,导致预测精度仍然不高。而本文提出的 GCNN-LSTM 预测模型则采用了两者的优点,将影响水文变化的主要因素(降雨量)进行了网格化精细处理,并通过图卷积神经网络和长短期记忆网络相结合的形式提取到空间

特征和时间特征，从而能够更加准确地预测出水文变化情况，使得预测值曲线与实际值更为接近。

为了进一步分析不同预测方法的精准度，通过均方根误差（*RMSE*）平均绝对百分比误差（*MAPE*）和平均绝对误差（*MAE*）3 个指标进行评价，3 个误差指标的计算公式如下。

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^{i=m} (f_r(i) - f_p(i))^2}$$

(10)

$$MAPE = \frac{1}{m} \sum_{i=1}^{i=m} \left| \frac{f_r(i) - f_p(i)}{f_r(i)} \right|$$

(11)

$$MAE = \frac{1}{m} \sum_{i=1}^{i=m} |f_r(i) - f_p(i)|$$

(12)

式中：*i* 表示第 *i* 次测量；*m* 表示测量的总数；*f_r*(*i*) 表示第 *i* 次的预测值；*f_p*(*i*) 是相应的真实值。

利用公式（10）～（12）对 2021 年 7 月份的日均径流量和水位进行计算，得到径流量预测误差和水位预测误差评价结果，如表 3～4 所示。

表 3 径流量预测误差评价结果

预测方法	<i>RMSE</i> /(m ³ /s)	<i>MAPE</i> /%	<i>MAE</i> /(m ³ /s)
TCN-Attention	74.47	9.35	38.56
MD-CNN	39.31	4.03	18.23
GCNN- LSTM	17.09	1.68	8.57

从表 3 的结果可看出，本文提出的预测方法得到的径流量的结果在 *RMSE*、*MAE* 和 *MAPE* 三个指标上的值最小，分别仅为 17.09 m³/s、1.68% 和 8.57 m³/s。

表 4 水位预测误差评价指标

预测方法	<i>RMSE</i> /m	<i>MAPE</i> /%	<i>MAE</i> /m
TCN-Attention	1.95	3.83	1.70
MD-CNN	1.00	2.06	0.91
GCNN- LSTM	0.32	0.65	0.29

从表 4 得结果可看出，本文提出的预测方法得到的水位结果在 *RMSE*、*MAE* 和 *MAPE* 三个指标上的值也是最小，分别仅为 0.32 m、0.65% 和 0.29 m。

综上所述，本文提出的预测方法与其他方法相比表现出了优越性，进一步说明了提出的预测模型能够更加准确地预测出河流的水位和径流。

4 结束语

为了提高河流水文预测的精度，采用物联网技术设计了分布式自动化采集系统来获取降雨和水文数据，并设计了 GCNN-LSTM 网络模型，能够有效提取降雨与水文变化的时空特征，大幅提高了预测的精度。本文以河南省周口市境内的颍河为研究对象，采集其近 5 年的降雨和颍河水文数据，并对提出的 GCNN-LSTM 网络模型进行训练，能够根据实时的降雨信息准确地预测出径流量和水位，预测径流量结果的 *RMSE*、*MAPE* 和 *MAE* 分别仅为 17.09 m³/s、

1.68% 和 8.57 m³/s，预测水位结果的 *RMSE*、*MAPE* 和 *MAE* 分别仅为 0.32 m、0.65% 和 0.29 m。同时，该预测模型通过训练还可以推广至其他河流水文预测的应用中，为合理开发利用水资源和防汛抗旱等工作制定决策提供数据支撑。

参考文献：

[1] 李建柱, 李磊菁, 张 婷, 等. DEM 数据源及分辨率对流域洪水模拟影响研究 [J]. 水力发电学报, 2023, 42 (3): 26 - 40.

[2] 张 婷, 李 怡, 李建柱, 等. 多源降雨数据融合及其水文应用研究进展 [J]. 自然灾害学报, 2022, 31 (1): 15 - 28.

[3] 刘松楠, 汪 君, 王会军. 多源降水在门头沟山洪模拟中的应用及比较 [J]. 气象, 2021, 47 (7): 817 - 829.

[4] 周庆梓, 何自立, 吴 磊, 等. 多源数据融合的深度学习径流预测模型 [J]. 水力发电学报, 2023, 42 (5) 5: 43 - 52.

[5] 韩 萍, 王 晋, 张相忠. 基于多源 DEM 数据的小流域水文特征提取分析 [J]. 中国农村水利水电, 2022 (5): 133 - 137, 146.

[6] 王志波, 王继柱. 基于光纤光栅传感技术和卷积神经网络的铁路信号调节方法研究 [J]. 工业仪表与自动化装置, 2023 (1): 91 - 96.

[7] 丁 洁, 朱 仟, 张 昊, 等. 基于多源蒸散发的参数率定对日径流模拟的影响 [J]. 中国农村水利水电, 2022 (10): 105 - 111, 118.

[8] 周 斌, 王 婷, 李雨鸿, 等. 利用空一地多源数据监测评估暴雨对辽河洪涝灾害的影响 [J]. 兰州大学学报: 自然科学版, 2022, 58 (3): 331 - 336.

[9] 林 瑜, 吕海深, 朱永华, 等. 融冰洪水演进的马斯京根模型 [J]. 水资源与水工程学报, 2021, 32 (4): 86 - 92.

[10] 郑莉萍, 胡煜佳, 张森林, 等. 基于 SWAT 模型的璧南河流域径流模拟分析 [J]. 重庆师范大学学报: 自然科学版, 2023, 40 (3): 31 - 47.

[11] 胡作龙, 高 鹏. 基于 EEMD-SVM 模型的北洛河上游径流预测 [J]. 水土保持研究, 2023, 30 (4): 98 - 102.

[12] 王 军, 高梓勋, 单春意. 基于 TCN-Attention 模型的多变量黄河径流量预测 [J]. 人民黄河, 2022, 44 (11): 20 - 25.

[13] JORDAN H, JEREMY W, ANAHITA K, et al. Deep temporal neural networks for water level predictions of watershed systems [C] // Virginia, USA: Systems and Information Engineering Design Symposium, 2023.

[14] 徐 刚, 胡婷婷, 王琛倪. 基于深度学习的流域洪水预报模型研究 [J]. 水文, 2023, 43 (3): 82 - 87.

[15] XIA M R, JIN D W, CHEN J Y, et al. Short-term traffic flow prediction based on graph convolutional networks and federated learning [J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24 (1): 1191 - 1203.

[16] 雍 斌, 张建云, 王国庆. 黄河源区水文预报的关键科学问题 [J]. 水科学进展, 2023, 34 (2): 159 - 171.

(下转第 300 页)