

王佳佳, 盛政, 胡文军. 基于 LSTM 的雨水管网水位预测[J]. 智能计算机与应用, 2025, 15(5): 156-162. DOI: 10.20169/j.issn.2095-2163.250522

## 基于 LSTM 的雨水管网水位预测

王佳佳<sup>1</sup>, 盛政<sup>1</sup>, 胡文军<sup>1,2</sup>

(1 湖州师范学院 信息工程学院, 浙江 湖州 313000;

2 浙江省现代农业资源智慧管理与应用研究重点实验室, 浙江 湖州 313000)

**摘要:** 排水管网系统是重要的城市基础设施之一, 对其管网水位的精准预测可以有效减少或消除道路积水、管道溢流等灾害。当前雨水管网水位与降雨量存在正相关、滞后、峰延等复杂关系, 同时与前  $m$  时刻的管网水位也存在密切关系, 导致现有方法在精度上难以满足实际应用要求。为此, 提出基于长短期记忆网络 (LSTM) 的雨水管网水位预测模型。该模型充分考虑到时间序列的影响因素, 提高了预测的准确性。以湖州市某一区域为试验区, 选定管网的 10 个节点, 使用模拟数据和实测数据对模型进行了验证。结果表明, 所提方法的预测准确率超过 89%, 达到了实际应用要求。

**关键词:** 降雨量; 雨水管网; 水位预测; 长短期记忆网络 (LSTM)

中图分类号: TP389.1

文献标志码: A

文章编号: 2095-2163(2025)05-0156-07

## Water level prediction in rainwater pipe network based on LSTM

WANG Jiajia<sup>1</sup>, SHENG Zheng<sup>1</sup>, HU Wenjun<sup>1,2</sup>

(1 School of Information Engineering, Huzhou University, Huzhou 313000, Zhejiang, China; 2 Zhejiang Province Key Laboratory of Smart Management & Application of Modern Agricultural Resources, Huzhou 313000, Zhejiang, China)

**Abstract:** The drainage pipe network system is one of the important urban infrastructures. Accurate prediction of the water level in the pipe network can effectively reduce or eliminate disasters such as road flooding and pipe overflow. Currently, the water level in the rainwater pipe network has complex relationships with rainfall, including positive correlation, lag effect, and peak delay. It also has a close relationship with the previous  $m$  moment's water level, making existing methods difficult to meet the requirements of practical applications in terms of accuracy. To address this issue, a water level prediction model for the rainwater pipe network based on Long Short-Term Memory (LSTM) networks is proposed. This model takes into account the influential factors of time series and improves the prediction accuracy. A specific area in Huzhou City is selected as the experimental zone, and 10 nodes of the pipe network are chosen for model validation using simulated and measured data. The results show that the proposed method achieves a prediction accuracy exceeding 89%, meeting the requirements of practical applications.

**Key words:** rainfall; rainwater pipe network; water level prediction; Long Short-Term Memory (LSTM) networks

## 0 引言

城市的排水管网系统是重要的基础设施, 其排水能力直接影响着市政排水和防涝能力, 因此, 建立一个有效的排水管网预警系统对预防内涝灾害至关重要。然而, 随着全球气候变暖、热岛效应的出现, 暴雨的几率增加, 洪涝灾害发生的频率也会增大。另外, 随着城市化进程的不断推进, 硬化路面、房屋和人工地表覆盖物等阻碍雨水的渗透和自然排水的

通畅<sup>[1]</sup>, 导致暴雨后容易出现洪涝自然灾害。近年来, 许多特大、超大城市出现了“城市看海”现象<sup>[2]</sup>, 中国应急管理部 2023 年 1 月 13 日发布的《2022 年自然灾害基本情况》<sup>[3]</sup> 表明, 2022 年全年全国发生了 38 次区域性强降雨导致的洪涝灾害。然而, 城市是人口密集的地区, 极端的暴雨天气不仅造成交通瘫痪, 严重影响着城市的健康发展, 同时也会威胁到人民的生命财产安全<sup>[4]</sup>。

为了减少城市内涝灾害, 相关学者对城市内涝

**作者简介:** 王佳佳(1998—), 女, 硕士研究生, CCF 会员, 主要研究方向: 深度学习, 时序预测; 胡文军(1977—), 男, 博士, 教授, CCF 会员, 主要研究方向: 机器学习, 模式识别, 智能系统。

**通信作者:** 盛政(1981—), 男, 副高级, 主要研究方向: 智慧城市, 智慧水务, GIS 相关应用。Email: 03083@zjhu.edu.cn。

收稿日期: 2023-10-11

哈尔滨工业大学主办 ◆ 专题设计与应用

预测进行了大量研究,目前常用预测方法主要有基于水力机理模型和基于机器学习,前者如暴雨洪水管理模型(Storm Water Management Model, SWMM)、城市综合流域排水模型(Infoworks, ICM)等方法;而后者如支持向量机(Support Vector Machine, SVM)<sup>[5]</sup>、反向传播神经网络(Back Propagation Neural Network, BP)<sup>[6]</sup>、长短期记忆模型(Long-Short Term Memory, LSTM)等。暴雨洪水管理模型(SWMM)是一种用于预测和管理城市暴雨洪水的数学模型,其本质是根据质量守恒定律和动量守恒定律对水流的运动过程进行模拟<sup>[7]</sup>。由于SWMM具有严格的物理机制,其对数据的来源及精度要求较高。然而,随着城市的发展,城市地形越来越复杂,管网更新速度较快,路面硬化导致径流和渗透等系数发生变化,导致SWMM模型在精度上无法达到实际应用的需求<sup>[8]</sup>。Wang等学者<sup>[9]</sup>提出基于SVM的机器学习方法对雨水管网水位进行预测。盛政等学者<sup>[10]</sup>提出基于BP神经网络的雨水管网充满度预测。这2种方法都表现出了良好的预测效果,但上述方法只考虑变量的输入与输出之间的关系,没有考虑到变量之间的时序联系。

由于降雨形成径流到流入雨水管网需要一定的时间,同时降雨量与雨水管网水位之间存在滞后和峰延关系,因此有效的预测模型需要充分考虑到这种时序变化。近期,考虑时序因素的水位预测获得了较大的关注。如唐鸣等学者<sup>[11]</sup>采用长短时记忆网络(LSTM)构建了南水北调中位线水位预测模型,该模型能很好地预测水位波动趋势。Hung等学者<sup>[12]</sup>使用长短时记忆网络对越南海洞运行水闸水位进行预测,该模型能够为河口附近地区提供高精度的短周期水位预测方面的性能。上述方法主要针对河湖、水库等受纳水体,而对于城市雨水管网的水位预测较少。通常情况下,针对河湖水库的水位预测,研究人员会以天、周、月等较长时间间隔为样本的数据进行预测研究;而对于雨水管网水位的预测,则往往以一次降雨事件为研究对象,研究雨水管网水位的变化情况。为此,本文针对降雨量与水位之间的特殊关系以及时间序列因素,利用LSTM构建雨水管网水位预测模型,通过挖掘学习历史数据中降雨量与水位之间的关系来预测未来时刻的水位变化情况。

## 1 相关研究

循环神经网络(Recurrent Neural Networks, RNN)<sup>[13]</sup>是一种内部具有记忆能力的神经网络,主

要用于处理时间序列数据。RNN设计原理如图1(a)所示,通过隐藏层的重复连接来实现序列数据的记忆和学习,不仅考虑当前的输入信息,还能通过隐藏层状态存储并记忆之前的信息,从而能够有效地处理时间序列数据。然而,当处理长期记忆的问题时,随着时间序列增长、网络层数不断增加,后续节点对前面节点的感知能力变弱,导致模型容易出现梯度消失或梯度爆炸的问题<sup>[14]</sup>。为了解决该问题,Hochreiter和Schmidhuber<sup>[15]</sup>在RNN的基础上提出长短期记忆模型(LSTM),其原理如图1(b)所示。LSTM模型包括遗忘门 $f_t$ 、输入门 $i_t$ 、输出门 $o_t$ 三个门控单元,每部分都有各自的权重参数 $W$ 、 $U$ 、 $b$ 用于相应的位置对信息进行筛选和加权,以增强有用信息的权重并滤除冗余信息<sup>[16]</sup>。此外,LSTM网络中还增加了内部记忆单元 $c_t$ ,代表着有效信息的长期记忆,并会随着时间的推移而传递下去。LSTM模型通过引入门控机制和内部记忆单元,能够有效解决RNN模型中的梯度消失和梯度爆炸问题,从而提高模型的训练效果和泛化能力。下面将对LSTM模型的3个门控单元的功能进行具体介绍。

(1)遗忘门 $f_t$ :根据当前时刻输入信息 $x_t$ 结合上一时刻隐藏层信息 $h_{t-1}$ ,通过 $\sigma$ 激活函数来决定 $c_{t-1}$ 的哪些信息用于计算 $c_t$ ,计算公式如下:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (1)$$

其中, $\sigma(\cdot)$ 表示激活函数,通常使用Sigmoid函数, $W_f$ 、 $U_f$ 分别表示权重参数; $b_f$ 表示偏移量。

(2)输入门 $i_t$ :结合上一时刻隐藏层 $h_{t-1}$ 与当前时刻输入信息 $x_t$ ,通过 $\tanh$ 函数计算,创建一个新的输入细胞信息状态 $\tilde{c}_t$ 。而内部记忆单元 $c_t$ 通过遗忘门 $f_t$ 和输入门 $i_t$ ,计算当前的记忆信息 $c_t$ ,计算公式定义如下:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (3)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (4)$$

其中, $\tanh(\cdot)$ 表示正切激活函数; $W_i$ 、 $W_c$ 、 $U_i$ 、 $U_c$ 分别表示权重参数; $b_i$ 、 $b_c$ 表示偏移量;“ $\circ$ ”表示点乘。

(3)输出门 $o_t$ :通过 $\sigma$ 激活函数决定当前输入信息 $x_t$ 与上一时刻隐藏层 $h_{t-1}$ 需要输出的信息。最后LSTM结合当前输出 $o_t$ 与当前细胞状态 $c_t$ 计算出需要传送到下一时刻的信息 $h_t$ 。数学公式具体如下:

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (5)$$

$$h_t = o_t \circ \tanh(c_t) \quad (6)$$

其中, $W_o$ 、 $U_o$ 分别表示权重参数, $b_o$ 表示偏移量。

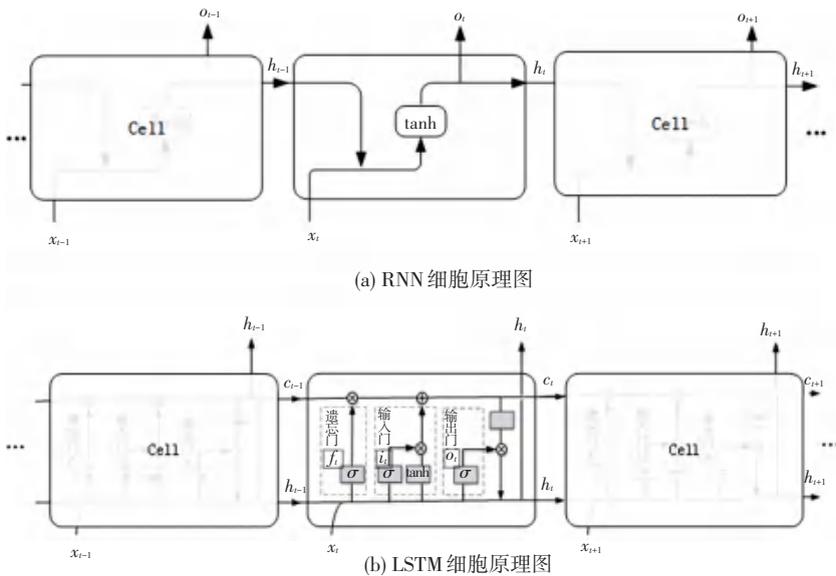


图 1 循环神经网络原理图

Fig. 1 Schematic diagram of recurrent neural network

## 2 雨水管网水位预测

本文以浙江省湖州市某区域为试验区设计总体方

案如图 2 所示,以此构建此实验区的雨水管网水位预测模型。该方案包括数据生成、数据预处理、模型训练和模型测试四部分。下面将对各部分具体展开介绍。

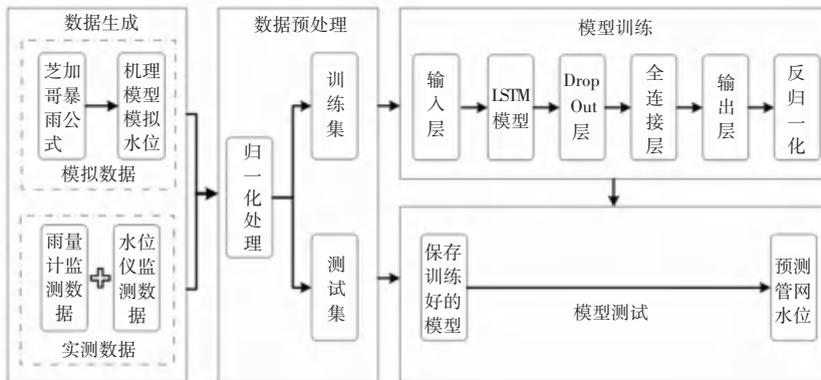


图 2 总体设计方案

Fig. 2 Overall design scheme

### 2.1 研究区域

本文采用湖州市某区雨水管网为试验区,实验区雨水管网系统平面布置如图 3 所示,该试验区面积约 16 公顷,含 150 个雨水节点,雨水管道直径为 300~400 mm,通过 3 个出水口连接河道。试验区内通过管道液位计测量 10 个点位数据,液位计采样间隔为 5 min;区域内安装有一台雨量计,可采集逐分钟的降雨数据。降雨量数据单位为毫米(mm),液位数据单位为米(m)。

### 2.2 数据生成

考虑到实测数据有限,为了使模型训练更充分,实验结合仿真数据和监测数据进行模型训练。数据模拟部分主要是根据《浙江省工程建设标准—城镇



图 3 雨水管网系统分布

Fig. 3 Distribution of rainwater pipe network system

防涝规划标准》<sup>[17]</sup>中提供的湖州市暴雨生成公式,生成适用于湖州当地的设计降雨数据。然后,使用 SWMM 机理模型和该实验区的管网数据对雨水管网进行建模,并将生成的降雨数据输入模型中,模拟仿真生成雨水管网水位数据。

### 2.2.1 模拟数据

(1)模拟降雨数据。适用于湖州市的暴雨生成公式具体如下,以此模拟生成适合于本试验区的短时强降雨事件:

$$i = \frac{23.090 + 22.825 \lg P}{(T + 18.862)^{0.842}} \quad (7)$$

其中,  $i$  表示暴雨强度 ( $\text{mm}/\text{min}$ );  $P$  表示设计降雨重现期 ( $a$ );  $T$  表示降雨历时 ( $\text{min}$ )。模拟一场历时 120 min、重现期为 1 年的降雨数据,如图 4 所示。

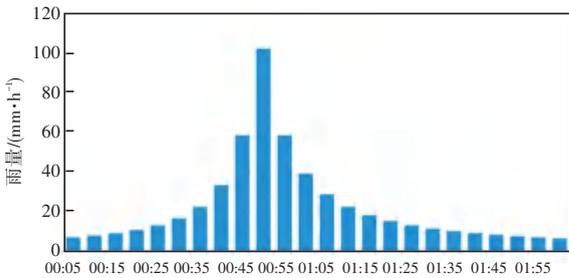


图 4 模拟降雨数据

Fig. 4 Simulated rainfall data

模拟降雨参数设置,时间间隔为 5 min,雨峰系数为 0.4。每一个重现期对应每一个历时数据,一一对应模拟降雨数据,不同重现期、不同历时的共生成 70 场降雨数据。每场降雨数据总历时 6 h,72 条样本数据。

(2)模拟水位数据。管网机理模型详见图 3。在试验区雨水管网图设 10 个节点,将模拟好的 70 场降雨数据分别输入到 SWMM 管网模型中模拟 10 个节点的管网水位,最后分别取出各个节点水位数据。重现期为 1 年、历时 120 min 的降雨数据模拟生成的各个节点的管网水位数据曲线如图 5 所示。

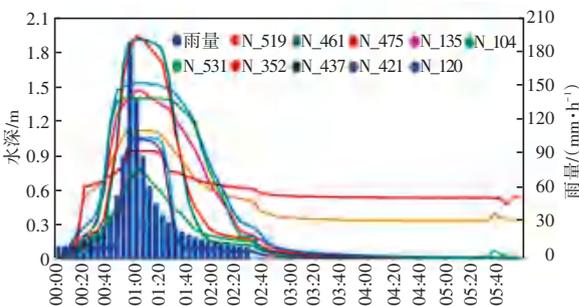


图 5 模拟水位数据曲线

Fig. 5 Simulated water level data curve

### 2.2.2 实测数据

根据实验区设备采集雨量计和水位仪记录的实际监测数据,部分实验数据具体如下。

(1)降雨监测数据。2023 年部分实测降雨数据见表 1。

表 1 降雨相关数据

Table 1 Rainfall related data

降雨场次	历时/h	总雨量/mm	雨峰/ $(\text{mm} \cdot \text{h}^{-1})$
2023 年 3 月 17 日	9.0	17.4	4.4
2023 年 5 月 26 日	4.5	23.9	15.8
2023 年 6 月 03 日	3.0	25.4	23.6

(2)水位监测数据。2023 年 5 月 26 日降雨的部分实测水位数据见表 2。

表 2 水位相关数据

Table 2 Water level related data

时间	水位/m	时间	水位/m
20:05	0.171	20:35	0.169
20:10	0.179	20:40	0.168
20:15	0.191	20:45	0.168
20:20	0.197	20:50	0.172
20:25	0.173	20:55	0.170
20:30	0.171	21:00	0.181

### 2.3 数据预处理

为了在训练中可以更快收敛,有助于数据的拟合,在数据输入前对数据进行了归一化处理。获取到降雨量以及管网水位训练数据后,分别以数组的形式进行归一化(minmaxscaler)处理。具体公式如下:

$$v' = \frac{v_i - v_{\min}}{v_{\max} - v_{\min}} \quad (8)$$

其中,  $v_i$  表示降雨量或水位原始数据;  $v_{\min}$  表示所有降雨量数据中的最小值或所有水位数据中的最小值;  $v_{\max}$  表示所有降雨量数据中的最大值或所有水位数据中的最大值;  $v'$  表示归一化后的降雨量数据或水位数据。

### 2.4 模型训练

模型训练具体如图 2 所示,输入数据为 70 场模拟数据和 5 场监测数据,使用五折交叉法共同训练,其中 60 场数据作为训练集,15 场作为验证集,最后使用单独的 2 场数据作为测试集;每一场数据有 72 条样本,即训练集有 4 320 条样本。利用训练好的模型,预测未来的管网水位。

模型使用 TensorFlow 框架构建 LSTM 模型,具体情况如下。

(1)模型搭建:构建 LSTM 模型,输入变量为降雨量和管网水位;隐藏层的神经元个数为 56;输入

滑动窗口为6;激活函数为 *relu*;模型的舍弃率0.2,模型的优化器为 *Adam*、损失函数为均方差 *MSE*。

(2)模型训练:由于训练数据每一场降雨时长为6 h,每5 min 一条数据,共72条样本数据。为了使训练过程中每场降雨数据完整,训练样本 *batchsize* 设为72, *epoch* 设为150。

(3)模型预测:训练后的模型在测试集上进行验证,采用平均绝对误差(*MAE*)、均方根误差(*RMSE*)、纳什效率系数(*NSE*)验证模型误差及预测精度。

### 3 实验与分析

#### 3.1 评价指标

模型训练中的损失函数使用均方差 (*MSE*) 来评估数据的拟合程度, *MSE* 公式定义如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - Y_i)^2 \quad (9)$$

其中,  $y_i$  表示实测值;  $Y_i$  表示预测值;  $\bar{y}_i$  表示总实测值的均值。

为了判断预测的准确性,本文使用以下几类评价指标:平均绝对误差 (*MAE*)、均方根误差 (*RMSE*)、纳什效率系数 (*NSE*)。

(1) *MAE* (Mean Absolute Error) 是绝对误差的平均值。 *MAE* 的公式定义如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - Y_i| \quad (10)$$

其中,  $y_i$  表示实测值,  $Y_i$  表示预测值。

(2) *RMSE* (Root Mean Square Error, *RMSE*) 是均方误差开根号,代表预测值和实际值之差的样本标准差。 *RMSE* 的定义如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - Y_i)^2} \quad (11)$$

其中,  $y_i$  表示实测值,  $Y_i$  表示预测值。

(3) *NSE* (Nash-Sutcliffe Efficiency coefficient) 是纳什效率系数,常在水文领域,用来评估水文模型模拟结果的好坏。  $E$  取值为  $-\infty$  至1,  $E$  接近1,表示模型质量好,可信度高;  $E$  接近0,表示模拟结果接近观测值的平均值水平,即总体结果可信,但过程模拟误差大;  $E$  远远小于0,则模型不可信。 *NSE* 的定义如下:

$$N = 1 - \frac{\sum_{i=1}^T (y_o^t - Y_i^t)^2}{\sum_{i=1}^T (y_o^t - \bar{y}_o)^2} \quad (12)$$

其中,  $y_o^t$  表示实测值;  $Y_i^t$  表示预测值;  $\bar{y}_o$  表示观测值的总平均;上标  $t$  表示第  $t$  个时刻;  $T$  表示总时间。

#### 3.2 参数对比分析

降雨量与雨水管网水位相关性如图6所示,降雨量与雨水管网水位呈正相关且存在滞后和峰延的关系,前  $m$  个时刻的降雨量对雨水管网的水位有明显的关系。  $m$  的大小取决于降雨后雨水径流到雨水井中的时间。根据本试验区的面积以及水流速粗略计算,该时长大概为30 min左右,因此本文通过设计对比试验,得到最优步长。

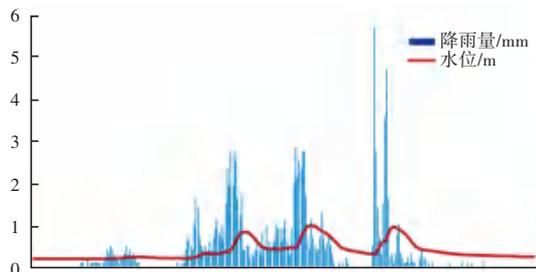


图6 降雨量与雨水管网水位相关性

Fig. 6 Correlation between rainfall and water level of rainwater pipe network

滑动窗口对比曲线如图7所示。步长参数对比见表3。模型在相同的参数情况下,对比不同的步长预测效果,当 *Windows* 为6时,各个参数结果最优, *NSE* 约为0.981,预测效果最好,因此本文模型滑动窗口的大小设置为6(30 min)。

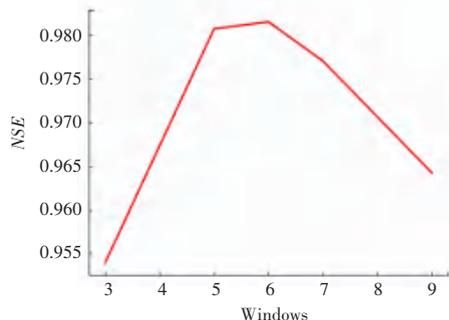


图7 滑动窗口对比曲线

Fig. 7 Comparison curve of sliding window

表3 步长参数对比

Table 3 Comparison of step size parameters

步长	<i>Val_loss</i>	<i>MAE</i>	<i>RMSE</i>	<i>NSE</i>
3	0.002 5	0.033 0	0.080 0	0.953 0
4	0.001 6	0.021 0	0.071 0	0.962 0
5	0.001 2	0.022 0	0.050 0	0.980 0
6	<b>0.000 3</b>	<b>0.016 0</b>	<b>0.048 0</b>	<b>0.981 0</b>
7	0.001 5	0.021 2	0.052 6	0.977 0

#### 3.3 模型验证分析

为了模型训练更充分,采用五折交叉验证的方法对模型进行训练及验证。分别对选取的10个节点进行验证,表4中分别给出了10个节点的 *Val\_loss*、*MAE*、*RMSE*、*NSE*(预测准确率指标)的均值。

从表 4 中可以看出,模型在每个节点都有良好的表现,其中  $Val\_loss$ 、 $MAE$ 、 $RMSE$  在  $N_{531}$  节点误差最小,预测精度最高;在  $N_{437}$  节点预测误差最大,预测精度较低。但是整体来看,模型的预测效果都达到了 0.895 以上,预测效果良好。

### 3.4 预测效果分析

模型训练完成后,单独对每个点位分别选用 2 场降雨数据进行模型的测试,2 场降雨的重现期为 1 年,历时分别为 60 min、90 min,预测结果如图 8 所示。

表 4 评价指标结果对比

Table 4 Comparison of evaluation index results

监测点位	$Val\_loss$	$MAE$	$RMSE$	$NSE$
$N_{531}$	0.000 7	0.009 2	0.014 2	97.5
$N_{519}$	0.001 1	0.011 3	0.020 0	96.8
$N_{352}$	0.000 6	0.010 2	0.021 1	97.4
$N_{461}$	0.001 8	0.023 2	0.060 6	91.1
$N_{437}$	0.006 2	0.031 2	0.061 2	89.5
$N_{475}$	0.000 9	0.016 5	0.048 1	89.9
$N_{421}$	0.005 0	0.020 2	0.051 3	96.5
$N_{139}$	0.001 1	0.013 4	0.034 3	94.9
$N_{120}$	0.001 4	0.018 1	0.045 2	94.6
$N_{104}$	0.001 5	0.017 6	0.046 9	97.2

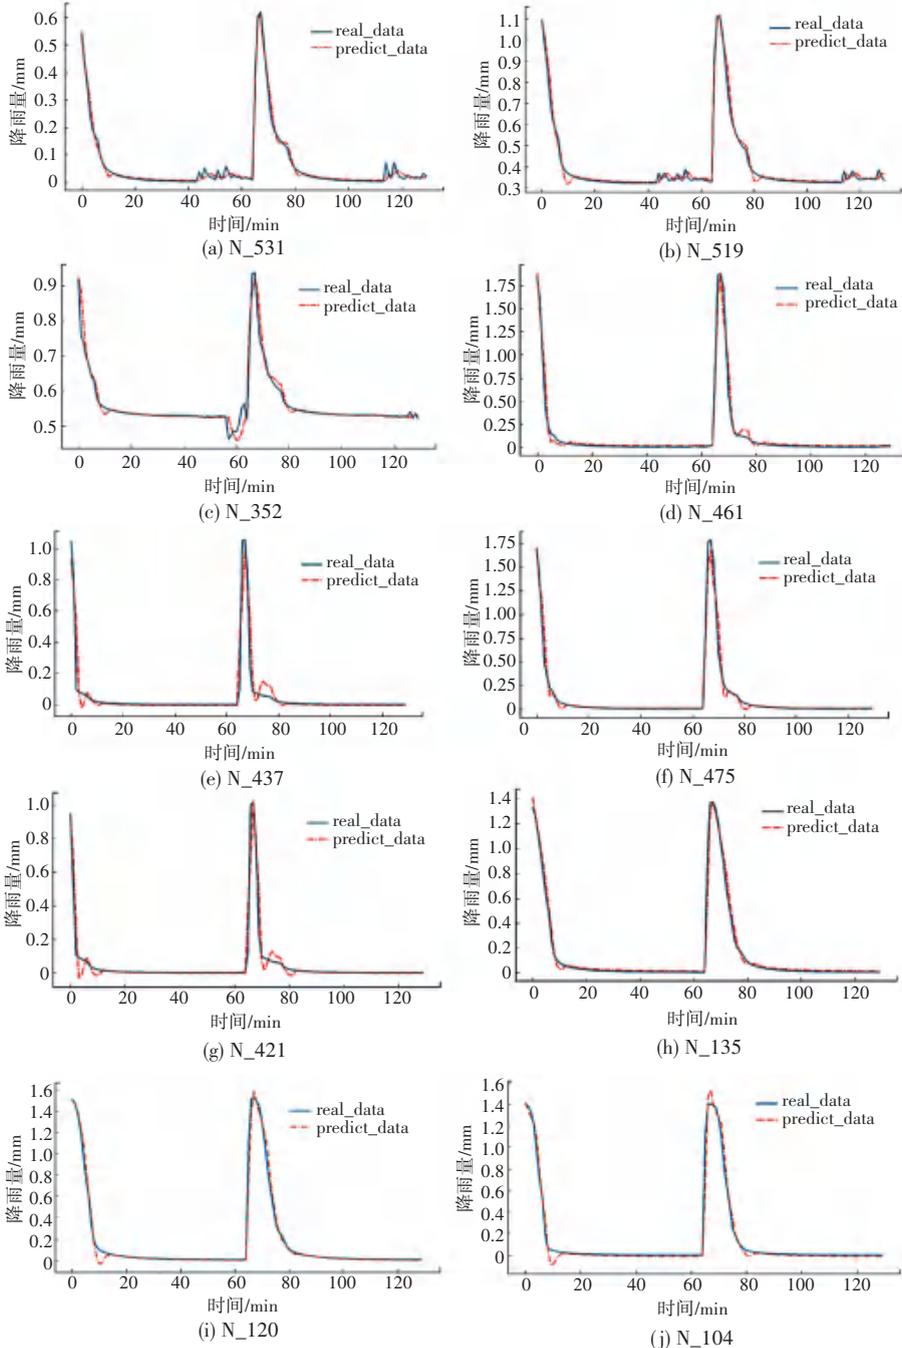


图 8 各节点模拟数据预测结果

Fig. 8 Prediction results of simulated data at each node

在图8可以看出,每个监测点位的预测值与测量值基本吻合。*NSE*判断模型的精度以及说明模型在水文领域的可用性。其中,N\_461点位的预测精度为0.89以上,其余点位的预测精度均可达0.90以上,可满足实际应用所需的精度要求。

## 4 结束语

本文根据降雨量与管网水位之间的时序关系建立了一个基于LSTM的雨水管网水位预测模型,根据历史降雨量和水位数据预测未来时刻的雨水管网水位。使用芝加哥暴雨公式模拟生成降雨和机理模型在试验区的10个不同监测点位模拟生成水位数据,同时结合实际的监测数据共同在LSTM模型中进行训练,模型经过多次训练学习可以快速且较为准确地预测管网水位。

通过对比实验,结果表明当步长为6个时刻(30 min),预测效果最好,*NSE*可达0.9。通过10个监测点位的测试预测,模型在平均绝对误差、均方根误差、纳什效率系数都表现出可接受且显著的预测效果,可满足实际应用中的预测精度要求。在实际应用中雨水管网系统对雨水管网的水位进行实时监测,若突发暴雨本文提供的模型可快速预测未来管网的水位情况,可为有关部门提供的一定决策帮助,降低内涝发生的可能,尽可能减少内涝带来的不可逆危害。

## 参考文献

[1] 王柱和. 某输水渠道对地下水水位升高影响及治理方案探析[J]. 水利水电工程设计, 2020, 39(3): 46-48.

[2] 罗嘉玲, 张争胜. 基于地理核心素养的问题式单元教学设计: 以探究从“城市看海”到“海绵城市”为例[J]. 地理教育, 2022(5): 30-33.

[3] 应急管理部. 应急管理部发布2022年全国自然灾害基本情况

[J]. 防灾博览, 2023(1): 26-27.

[4] LIU Yuanyuan, LIU Yesen, ZHENG Jingwei, et al. Intelligent prediction method for waterlogging risk based on AI and numerical model[J]. Water, 2022, 14(15): 2282.

[5] CHAUHAN V K, DAHIYA K, SHARMA A. Problem formulations and solvers in linear SVM: A review[J]. Artificial Intelligence Review, 2019, 52(2): 803-855.

[6] 邱云峰, 班元朗, 陈林. 基于BP神经网络的晶体管寿命预测研究[J]. 科学技术创新, 2022(35): 100-103.

[7] YAZDI M N, KETABCHY M, SAMPLE D J, et al. An evaluation of HSPF and SWMM for simulating streamflow regimes in an urban watershed[J]. Environmental Modelling & Software, 2019, 118: 211-225.

[8] ZAKIZADEH F, MOGHADDAM N, SALAJEGHEH A, et al. Efficient urban runoff quantity and quality modelling using SWMM model and field data in an urban watershed of Tehran Metropolis[J]. Sustainability, 2022, 14(3): 1086.

[9] WANG Hao, SONG Lixiang. Water level prediction of rainwater pipe network using an SVM-based machine learning method[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2019, 34(2): 2051002.

[10] 盛政, 王浩正, 胡坚. 基于BP神经网络的雨水管网充满度预测[J]. 中国给水排水, 2018, 34(23): 130-133.

[11] 唐鸣, 雷晓辉, 龙岩, 等. 基于长短时记忆网络(LSTM)的南水北调中线水位预测[J]. 中国农村水利水电, 2020(10): 189-193.

[12] HUNG V H, DUC H N, XUAN H L, et al. Multi-step-ahead water level forecasting for operating sluice gates in Hai Duong, Vietnam[J]. Environmental Monitoring and Assessment, 2022, 194: 442.

[13] GRAVES A. Supervised sequence labelling with recurrent neural networks[M]. Berlin: Springer-Verlag, 2012.

[14] 白盛楠, 申晓留. 基于LSTM循环神经网络的PM<sub>2.5</sub>预测[J]. 计算机应用与软件, 2019, 36(1): 67-70.

[15] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[16] 陈红花, 岑健, 刘溪, 等. 深度学习在化学流程工业故障诊断的研究进展[J]. 计算机工程与应用, 2022, 58(13): 48-62.

[17] 浙江省住房和城乡建设厅. 关于发布浙江省工程建设标准《城镇内涝防治技术标准》的公告(DB 33/T 1109-2020)[S]. 杭州: 浙江省住房和城乡建设厅, 2020.