

# 基于深度学习的城市内涝积水水深预测模型

林凯荣<sup>1,2,3</sup>, 欧阳佳娜<sup>1</sup>, 马旭民<sup>1</sup>, 肖名忠<sup>1</sup>, 冯星昱<sup>1</sup>

(1. 中山大学土木工程学院, 广东 广州 510275; 2. 广东省海洋土木工程重点实验室, 广东 广州 510275; 3. 广东省华南地区水安全调控工程技术研究中心, 广东 广州 510275)

**摘要:**为提高城市内涝模拟计算效率,满足城市内涝预警时效性的要求,利用深度学习方法优势,基于传统水文水动力学模型的模拟结果,以坡度、高程、降水量等城市暴雨内涝致灾链条发展的关键驱动因子作为输入,结合卷积神经网络(CNN)和长短期记忆网络(LSTM),引入注意力机制(ATT),并使用麻雀搜索优化算法进行超参数优选,构建了城市内涝积水水深预测的CNN-LSTM-ATT模型。利用该模型对深圳市大空港新城区内涝积水水深进行预测,结果表明:CNN-LSTM-ATT模型能有效预测暴雨引起的城市内涝积水水深,其在未来30 min内的预测水深与水文水动力学模型模拟结果相近,模型精度在延长预见期后略有下降;与水文水动力学模型相比,CNN-LSTM-ATT模型模拟效率提高近200倍。

**关键词:**城市内涝;水文水动力学模型;深度学习方法;水深预测;深圳市

**中图分类号:**TP183;TV124 **文献标志码:**A **文章编号:**1004-6933(2025)01-0056-08

**Prediction model of urban waterlogging water depth based on deep learning//**LIN Kairong<sup>1,2,3</sup>, OUYANG Jiana<sup>1</sup>, MA Xumin<sup>1</sup>, XIAO Mingzhong<sup>1</sup>, FENG Xingyu<sup>1</sup> (1. School of Civil Engineering, Sun Yat-Sen University, Guangzhou 510275, China; 2. Guangdong Key Laboratory of Marine Civil Engineering, Guangzhou 510275, China; 3. Guangdong Engineering Technology Research Center of Water Security Regulation and Control for Southern China, Guangzhou 510275, China)

**Abstract:** In order to improve the computational efficiency of urban waterlogging simulation and meet the requirement of timeliness of urban flooding warning, the advantage of deep learning method and simulation results of the traditional hydrological-hydrodynamic model were utilized, and the key driving factors for the development of urban rainstorm waterlogging disaster chain, including slope, elevation, and precipitation, were used as inputs. In combination with the convolutional neural network (CNN) and the long short-term memory network (LSTM), a CNN-LSTM-ATT model for urban waterlogging water depth prediction was constructed through introducing the attention mechanism (ATT) and by using the sparrow search algorithm for optimal selection of hyper-parameters. The model was used to predict the waterlogging water depth in Dakonggang new urban area of Shenzhen City, and the results show that the CNN-LSTM-ATT model can effectively predict the water depth of urban waterlogging caused by heavy rain. The predicted water depth with the CNN-LSTM-ATT model in the next 30 min is close to the simulation results of the hydrological-hydrodynamic model, and the accuracy of the model decreases slightly after the prediction period is extended. Compared to the hydrological-hydrodynamic model, the CNN-LSTM-ATT model exhibits a simulation efficiency that is approximately 200 times higher.

**Key words:** urban waterlogging; hydrological-hydrodynamic model; deep learning method; water depth prediction; Shenzhen City

近年来全球变暖趋势明显,极端天气事件频发,引起了全世界学者的密切关注<sup>[1]</sup>。随着城镇化进程的持续推进,城市内不透水面积占比日渐增加<sup>[2]</sup>,与此同时,排水系统设计与建设却存在迟滞现象,内涝问题越来越严重,呈现突发性强、持续时

间长、洪峰大和影响范围广等特征<sup>[3-4]</sup>。研究表明,我国是全球洪涝灾害最频发的国家之一,我国约有2/3的地区存在发生洪涝灾害的可能,且自2000年以来全球受洪灾影响的人口中,仅中国就占55%<sup>[5]</sup>。在城市洪涝灾害管理与防控体系中,城市

**基金项目:**国家优秀青年科学基金项目(51822908);广东省基础与应用基础研究基金项目(2023B1515040028);广东省水文局专项资金项目(440001-2023-10716)

**作者简介:**林凯荣(1980—),男,教授,博士,主要从事水文水资源研究。E-mail:linkr@mail.sysu.edu.cn

内涝预警预报系统是不可或缺的基石,它不仅指导工程性防洪措施的布局与优化,亦为防洪减灾策略规划等非工程性防洪措施提供科学依据与理论支撑。鉴于此,水文学、气象学等相关领域的学者们广泛关注于城市内涝预警预报系统建设<sup>[6]</sup>。对已有研究成果进行梳理后发现,目前常见的城市内涝模拟技术大多对数据精度提出了极高的要求,而计算效率等方面却存在不足,阻碍了其在不同城市环境中的推广应用。随着深度学习技术的飞速进步,不再囿于明确的物理机制,尝试城市内涝模拟新思路,即通过数据驱动直接挖掘并学习输入和输出之间的潜在关系,进而实现对内涝水深的预测,已成为解决现有城市内涝预报关键问题的重要方法。

深度学习算法在城市内涝模拟中的应用案例正不断涌现。Panda 等<sup>[7]</sup>构建了人工神经网络(artificial neural network, ANN)模型,其预测性能优于 MIKE 11 水动力学模型;Chang 等<sup>[8]</sup>将台北市某水库作为研究区,使用递归神经网络进行暴雨水位预测,研究结果发现其效果优于前馈神经网络。Chen 等<sup>[9]</sup>将长短期记忆网络(long short-term memory, LSTM)应用于传统数值模型,将数值模型模拟的实验结果作为特征数据,用于 LSTM 的训练,该数值模型和深度学习模型相结合的方法兼顾了预测精度和计算效率,展示了深度学习技术在城市内涝模拟中的潜在应用价值。此外,使用单一学习算法在预测精度上有时可能不足以满足需求,也有学者将不同深度学习算法进行组合。周聂等<sup>[10]</sup>运用极限随机树及  $K$  最邻近( $K$ -nearest neighbor, KNN)分类算法,构建了高分辨率山洪灾害快速预报模型,模型可在 10 s 内完成最大淹没情况计算,并输出淹没范围图且精度良好;苑希民等<sup>[11]</sup>结合 LSTM 和灰色模型(grey model, GM)的优势,提出基于 LSTM-GM 神经网络模型的风暴潮增水预报方法。以上研究成果揭示了深度学习技术在洪涝灾害模拟和预测中的潜力,城市内涝是洪涝问题的研究分支,深度学习技术在城市内涝研究中同样具有广阔前景。但目前在城市内涝积水水深预测方面,利用深度学习技术的研究处于起步阶段,相关探索仍较为缺乏。

深度学习算法依赖于数据驱动,目前大部分城市的实测数据存在不同程度的缺失和精度不足等问题。此外,随着城市发展的加速,过去的测量数据与当前的实际情况可能不一致。为此,本文通过引入注意力机制(attention mechanism, ATT),建立耦合卷积神经网络(convolutional neural network, CNN)与 LSTM 的深度学习架构,构建了城市内涝积水水

深预测的 CNN-LSTM-ATT 模型,并通过实例应用对模型的预测精度进行验证,研究结果可为城市洪涝灾害预警预报、避洪转移等工作提供信息支持和科学依据,同时为深度学习在该领域的研究和应用提供参考。

## 1 研究方法

### 1.1 MIKE 模型的构建

为将物理过程融入深度学习算法中,本文利用 MIKE 系列软件构建基于传统水文水动力学的城市暴雨内涝模型(MIKE 模型),模拟不同重现期设计降雨,将得到的淹没水深数据用作训练深度学习模型的样本。MIKE 系列软件由丹麦水力学研究所开发<sup>[12]</sup>,广泛应用于汇水区雨水径流、管网水流等模拟。利用 MIKE 11 可建立一维河道模型,模拟河道内行洪;MIKE URBAN 可用于模拟城市排水系统和汇水区中地表径流、管道内水流等情况;利用 MIKE 21 可推演地表漫流过程。MIKE FLOOD 可将三者动态耦合,计算并存储各自的结果。MIKE 系列软件在众多应用场景中展现出其广泛的适用性,包括城市管网与河流的交互、二维地表水流等,且能够考虑各种人工构筑物的影响。

### 1.2 基于深度学习方法的模型构建

在深度学习领域中,CNN 拥有强大的特征提取能力<sup>[13]</sup>,LSTM 由于其独特的设计<sup>[14]</sup>,能够有效处理时间序列数据,捕捉长期依赖关系,使其在时间序列分析方面表现出色<sup>[15]</sup>。鉴于这两种算法各自的优势和局限性<sup>[16-17]</sup>,本文将 MIKE 模型的内涝模拟结果作为训练样本,通过 CNN 从历史降雨序列中提取有效的局部特征,利用 LSTM 提取水位数据的深层时间特征,引入 ATT,对城市内涝致灾链条发展的关键驱动因子赋予不同权重<sup>[18]</sup>,归一化融合生成内涝时序数据集,构建城市内涝积水水深预测的 CNN-LSTM-ATT 模型,模型依据历史数据分析潜在特征,经过参数学习预测后一时刻的淹没水深。模型训练流程如图 1 所示。

#### 1.2.1 内涝时序数据集生成

将内涝特征、水深预测特征因子(即地形条件、降雨过程等)等数据进行融合与归一化处理,构造有监督的暴雨内涝时序数据,输入到 CNN-LSTM-ATT 模型。

有监督学习是一种在训练过程中利用带有“标签”的数据集进行学习的机器学习方法。“标签”是指数据集中每个样本的输出部分,即期望模型预测的目标值。有监督学习的目标是通过学习输入与输

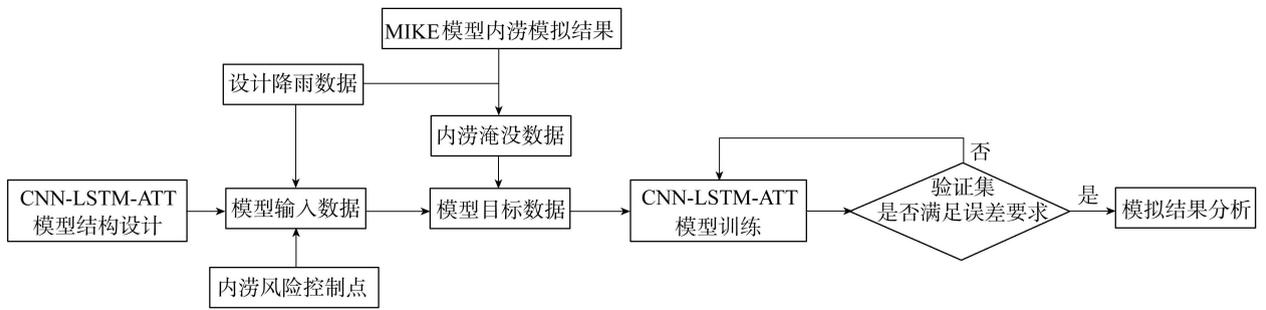


图1 CNN-LSTM-ATT 模型训练流程

Fig. 1 Flow chart of CNN-LSTM-ATT model training

出之间的映射关系,使模型对未见过的新数据进行准确预测<sup>[19]</sup>。其表达式为

$$Y = f(U) \quad (1)$$

式中: $U$ 为输入变量; $Y$ 为“标签”; $f$ 为两者间的映射函数关系。

### 1.2.2 模型架构

本文构建的 CNN-LSTM-ATT 模型包含 1 个卷积层、1 个 LSTM 层、2 个拼接层、3 个全链接层,最后一个全链接层中包含一个激活函数层,如图 2 所示。CNN-LSTM-ATT 模型输入层为降雨数据、水深时序数据和地形数据等,输出层为内涝控制点未来时刻的淹没水深值。根据已有的研究,前期降水量是影响城市内涝淹没水深的主要因素,且城市对降雨的响应迅速,内涝现象常在降雨开始后 1 h 内发生<sup>[20]</sup>。本文综合考虑研究区的管网密度、地形条件等因素,采用某时刻前 1 h 的降雨和历史淹没水深模拟该时刻的淹没水深;在测试集中,进一步通过滚动预测的方式,模拟接下来 30、60 min 内每分钟的淹没水深。

### 1.2.3 模型超参数确定

针对批处理规模、学习率、优化器等超参数,本文选择麻雀搜索优化算法(sparrow search algorithm, SSA)<sup>[21]</sup>进行超参数优化以提升模型性能。考虑到卷积核、全链接层的输入和输出大小的改变会对 ATT 的参数造成影响,因此采用手动调参。

SSA 具有全局搜索能力强、收敛速度快等优点<sup>[22]</sup>。其执行步骤为:①CNN-LSTM-ATT 模型对来自 SSA 的参数数据进行解码,获得批处理规模、学习率等参数数值;②利用训练数据集对 CNN-LSTM-ATT 模型进行训练,并使用验证集对已训练模型进行评估,计算出内涝控制点淹没水深预测值与 MIKE 模型模拟值之间的均方误差(MSE);③将误差值反馈给 SSA,用于计算个体的适应度,进而促进种群向更优解迭代更新。SSA 优化 CNN-LSTM-ATT 模型的流程如图 3 所示。

### 1.3 模型评价指标

本文采用了平均相对误差(MRE)、平均绝对误差(MAE)、均方根误差(RMSE)、皮尔逊相关系数( $r$ )等指标对模型的精度进行评价。

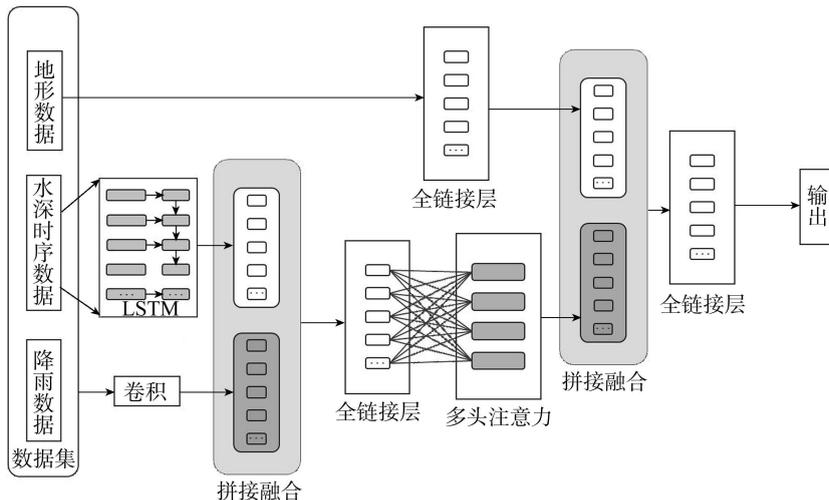


图2 CNN-LSTM-ATT 模型架构

Fig. 2 Structure of CNN-LSTM-ATT model

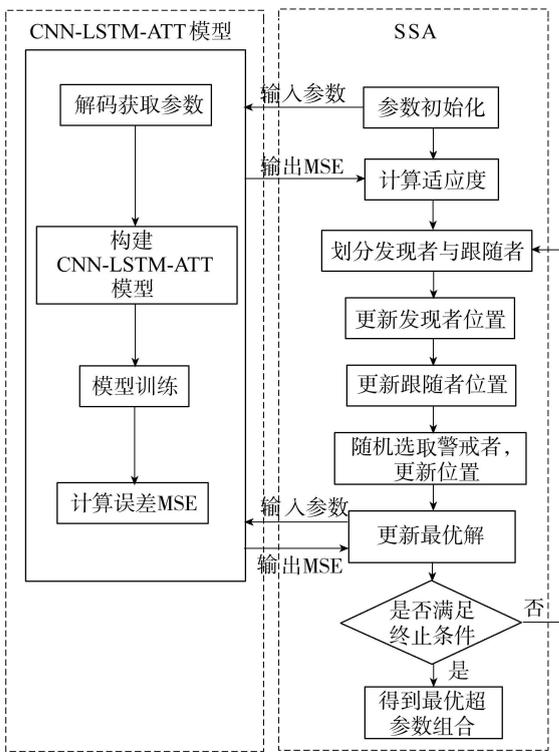


图3 SSA优化CNN-LSTM-ATT模型流程  
Fig. 3 Flow chart of using SSA to optimize CNN-LSTM-ATT model

## 2 实例分析

### 2.1 研究区概况与数据来源

本文以深圳市大空港新城区为研究区(图4),研究区位于  $22^{\circ}40'N \sim 22^{\circ}46'N$ 、 $113^{\circ}46'E \sim 113^{\circ}52'E$ ,总面积约为  $25.45 \text{ km}^2$ ,该区域地处南沙、前海、蛇口3大自贸区战略节点,地理区位优势明显,不仅是广州、深圳、香港核心发展走廊和东西向



图4 研究区概况  
Fig. 4 Overview of study area

发展轴的重要组成部分,更占据粤港澳大湾区湾顶的核心地位。研究区处于亚热带海洋性季风气候带,全年高温湿润,雨量丰沛,石岩水库雨量站长期降雨数据统计表明,多年平均降水量为  $1606 \text{ mm}$ ,年际雨量变化较大,分布极不均匀。夏秋季节该地区常受到台风的影响,进一步增加了降雨的不确定性和极端性。

本文采用的雨水管网数据、河道断面及DEM数据来源于华东勘测设计研究院,实测气象资料来源于深圳水务局,下垫面遥感数据来源于中国科学院计算机网络信息中心地理空间数据云平台(<http://www.gscloud.cn>)。

### 2.2 降雨情景设计

根据《深圳市暴雨强度公式及查算图表(2015版)》相关规定,针对不同的重现期,采用相应的暴雨强度公式设计暴雨情景,得到不同重现期(2、3、5、10、20、30、50、100年一遇)下的降雨过程:

$$i = A / (t + b)^n \quad (2)$$

式中: $i$ 为暴雨强度; $t$ 为降雨历时,文中 $t = 180 \text{ min}$ ;  $A$ 为雨力参数; $b$ 为降雨历时修正参数; $n$ 为暴雨衰减指数。不同降雨重现期各参数取值见表1。

表1 不同降雨重现期参数取值

Table 1 Parameter values for different rainfall return periods

重现期/a	$A/\text{mm}$	$b/\text{min}$	$n$
2	14.768	12.688	0.654
3	14.839	12.544	0.629
5	14.914	12.388	0.602
10	14.004	11.305	0.557
20	13.568	10.178	0.529
30	13.318	9.657	0.514
50	13.007	9.058	0.495
100	12.587	8.298	0.470

### 2.3 结果与分析

#### 2.3.1 MIKE模型内涝模拟

深圳市大空港新城区一维管网模型见图5(a),区域共有1654根管线、1652处检查井和52个排水口,划分了1652个子汇水区,汇水区不透水参数主要参考GB50014—2021《室外排水工程设计规范》的径流系数规范确定,忽略了初损和水文衰减系数,不透水系数约等于径流系数。参考文献[23-25],确定了草地、道路、建筑用地的不透水系数范围,分别为10%~20%、80%~90%、85%~95%。

一维河道模型包括一条截流河干流和南、北两条连通渠,连通德丰围涌、石围涌、下涌、沙涌、和二涌、沙福涌、塘尾涌、玻璃围涌共8条上游河涌。初

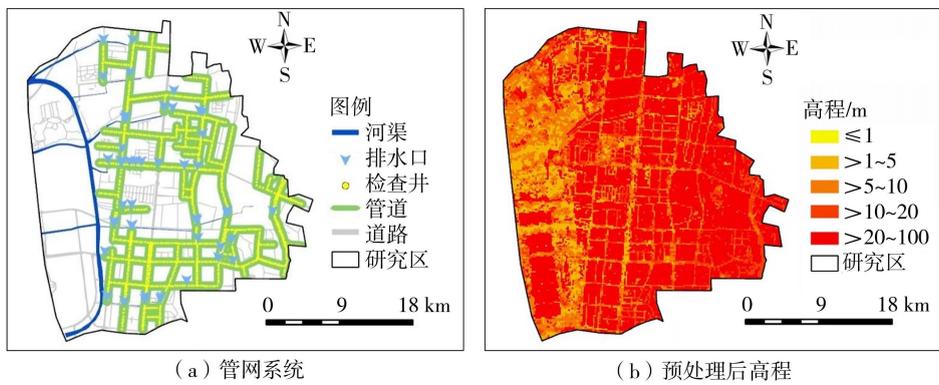


图5 研究区管网系统及高程

Fig. 5 Pipe network system and elevation of study area

始流量设置为接近于 0,河道糙率取值为 0.028 ~ 0.033。

考虑到模型精度要求及人工构筑物高度对二维模型的影响,本文在 ArcGIS 中对地形数据进行了处理,对获取的 1 : 1000 地形图高程数据进行插值得到精度为 10 m 的网格数据,并将建筑所在位置的高程统一提高 40 m,道路所在位置的高程降低 0.15 m,如图 5(b) 所示。模拟时间步长与 MIKE URBAN 中保持一致,均为 1 min。干湿边界临界值设为 0.002 和 0.003。

利用 MIKE FLOOD 将一维排水管网模型、一维河道模型、二维地表漫流模型耦合。根据 MIKE 模型,结合 2018 年“山竹”台风事件对参数进行调试和校验。在率定过程中,选择海上田园站作为主要分析点,该站记录的最大降雨强度为 26.3 mm/h,24 h 累积降水量为 124.2 mm,低于 2 年一遇的水平。潮位数据参考赤湾站,同期记录的最高潮位达到 3.15 m,相当于 200 年一遇的水平。台风“山竹”在该地区产生的总降水量接近 119.97 mm,持续时间大约为 24 h。

在验证过程中,采用了 4 个易涝点的淹没水深数据和截流河南、北段的最高水位进行验证。结果显示,模拟水位与实测水位大致吻合,如表 2 所示。此外,模型模拟研究区的积水情况也与实际情况相一致。因此,认为模型具有良好的精度<sup>[26]</sup>。

### 2.3.2 CNN-LSTM-ATT 模型内涝预测

#### 2.3.2.1 试验数据集划分

8 场降雨数据的特征信息如表 3 所示。考虑深度学习模型的泛化能力,本文选择 20 年一遇的设计降雨情景作为测试集,用于评估模型的性能。其余 7 场降雨作为模型训练的数据集,按照 5 : 2 的比例进行多次轮换划分,每轮 5 场用于模型的学习,其余 2 场用于性能评估,从而更全面地测试模型在不同数据上的表现,减少性能评估的偏差。

表 2 水位模拟结果与实测结果对比

Table 2 Comparison of water level simulation and measurement results

指标	水位测点	实测值/m	模拟值/m	MRE/%
淹没水深	和二社区	0.15	0.1643	9.53
	建安路与永福路交汇处	0.60	0.6823	13.72
	德的工业园	0.50	0.4711	-5.78
	松福大道(荔园路—凤塘大道段)	0.30	0.3320	10.67
最高水位	截流河北段	1.70	1.8600	9.41
	截流河南段	2.00	2.1600	8.00

表 3 降雨特征信息

Table 3 Characteristic information of rainfall

降雨重现期/a	降雨峰值/mm	总降水量/mm
2	2.7	159.6
3	2.9	178.1
5	3.1	200.6
8	3.5	230.1
10	3.8	253.7
20	3.9	266.6
50	4.1	283.5
100	4.4	306.7

#### 2.3.2.2 超参数优化结果

依据 MIKE 模型的结果,综合社会经济状况、人口和交通流量等因素,选定了 10 个关键的内涝风险控制点,如图 4 所示。经过多次迭代、优化后,确定 CNN-LSTM-ATT 模型的超参数优选结果,如表 4 所示。

表 4 超参数优选结果

Table 4 Results of hyper-parameter optimization

参数	取值范围	优选结果
Conv1 卷积核大小	1, 3, 5	3
优化器	RMSProp, Adam, SGD	SGD
学习率	0.0001, 0.0005, 0.001	0.0001
动量	0.5, 0.7, 0.9	0.9
Fc1 神经元个数		192
Fc2 神经元个数	64, 128, 192	64
Fc3 神经元个数		64
批处理规模	10, 20, 30, 40	20
激活函数	relu, sigmoid	relu

表5 CNN-LSTM-ATT 模型精度评价结果

Table 5 Accuracy evaluation results of CNN-LSTM-ATT model

控制点 编号	未来 30 min 内				未来 60 min 内			
	MRE/ %	MAE/ m	RMSE/ m	$r$	MRE/ %	MAE/ m	RMSE/ m	$r$
1	0.51	0.01	0.01	0.90	0.48	0.01	0.01	0.83
2	4.54	0.03	0.03	0.82	3.77	0.03	0.03	0.80
3	3.21	0.01	0.02	0.44	5.76	0.03	0.03	0.37
4	4.26	0.03	0.03	0.85	2.88	0.02	0.02	0.76
5	3.39	0.01	0.01	0.89	4.22	0.02	0.02	0.84
6	6.03	0.03	0.03	0.88	5.5	0.03	0.03	0.83
7	6.12	0.01	0.01	0.87	5.03	0.01	0.01	0.83
8	9.92	0.09	0.09	0.88	11.46	0.11	0.12	0.84
9	0.85	0.01	0.01	0.89	2.28	0.02	0.02	0.24
10	7.97	0.01	0.02	0.80	14.52	0.03	0.03	0.76

### 2.3.2.3 模型精度评价

为验证 CNN-LSTM-ATT 模型的科学性和合理性,对比分析 MIKE 模型与 CNN-LSTM-ATT 模型在测试集中的淹没水深模拟和预测结果,部分控制点的结果如图 6 所示。结果表明,CNN-LSTM-ATT 模型在预测内涝积水水深方面表现良好,成功模拟了未来城市内涝情况。特别是在预测未来 30 min 内的淹没水深时,CNN-LSTM-ATT 模型与 MIKE 模型结果符合度较高。尽管随着预测时间的增加,深度学习模型和 MIKE 模型的偏差逐渐加大,但仍能有效预测暴雨引起的城市内涝积水水深,验证了 CNN-LSTM-ATT 模型的可靠性和应用价值。

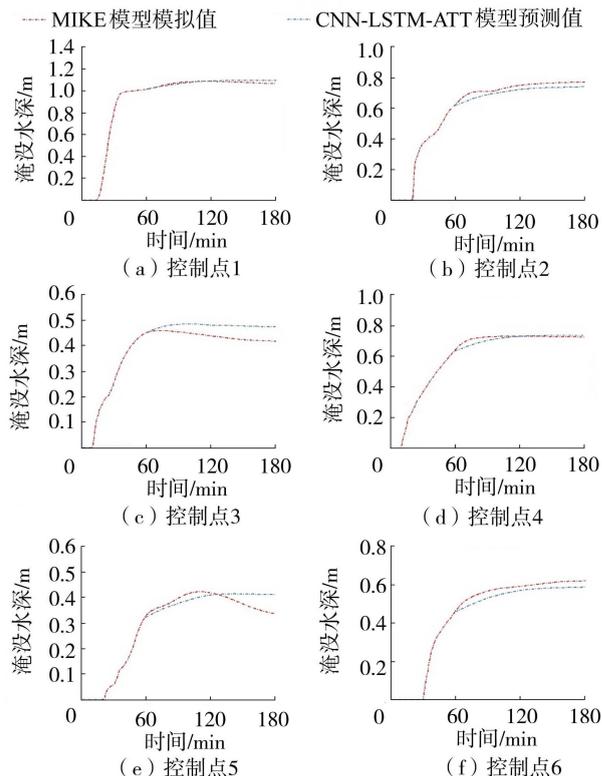


图6 部分控制点水深模拟和预测值对比

Fig. 6 Comparison of water depth prediction and simulation results for selected control points

采用统一的评价指标,在测试集上对训练后的 CNN-LSTM-ATT 模型进行测试,并对 CNN-LSTM-ATT 模型结果的精确度进行评估,评价结果如表 5 所示。

由表 5 可以看出,CNN-LSTM-ATT 模型对未来 30 min 内的内涝积水水深预测精度较高,MRE、MAE、RMSE 均较小,皮尔逊相关系数较大,表示基于深度学习的 CNN-LSTM-ATT 模型具有较高的可靠性,能够较好地预测未来 30 min 内的内涝控制点积水情况;随着预报时间增加,模型的预测精度随之下降,MRE、MAE、RMSE 均有所增大,皮尔逊相关系

数降低,表示随着预见期的延长,CNN-LSTM-ATT 模型对未来城市暴雨内涝情况的解释力度变弱。

### 2.3.2.4 模型运行效率对比

本文的模拟计算在配备了 i5-12400f 处理器 (4.4 GHz) 和 NVIDIA GeForce GTX4070 显卡 (12GB 专用显存) 的计算机上进行。MIKE 模型在模拟 20 年一遇的降雨事件时,内涝淹没模拟大约耗时 3495 s;在遭遇更长历时或更复杂降雨情况下,模拟时间可能延长至数小时,这样的处理速度难以满足城市暴雨内涝预警的时效性需求。相比之下,CNN-LSTM-ATT 模型利用 GPU 进行加速,发挥了深度学习的性能优势,在模拟时间上大幅领先,将模拟时长缩短至 18 s。与 MIKE 模型相比,CNN-LSTM-ATT 模型的效率提高了近 200 倍,大幅缩短了模型运行时间,这不仅能有效应对城市内涝的快速响应难题,也为实时模拟和预测城市内涝提供了技术支持。

## 3 结论

a. CNN-LSTM-ATT 模型在模拟淹没水深方面具有良好的性能,可应用于内涝风险评估。CNN-LSTM-ATT 模型预测的淹没水深与 MIKE 模型的模拟结果相近;MRE、MAE、RMSE、皮尔逊相关系数等指标均较理想。但随着预报时间增加,CNN-LSTM-ATT 模型的模拟性能出现一定的下降。

b. CNN-LSTM-ATT 模型能够在 18 s 内完成预测,而传统的 MIKE 模型则需要 3495 s,CNN-LSTM-ATT 模型的运行效率比 MIKE 模型提高了近 200 倍。CNN-LSTM-ATT 模型显著降低了内涝预警和预报所需的时间,使得实时模拟城市内涝成为可能,有助于城市防洪和紧急避险的快速决策。

### 参考文献:

[1] 张金良,罗秋实,王冰洁,等. 城市极端暴雨洪涝灾害成

- 因及对策研究进展[J]. 水资源保护, 2024, 40(1): 6-15. (ZHANG Jinliang, LUO Qiushi, WANG Bingjie, et al. Research progress on causes and countermeasures for extreme rainstorm-induced urban flood disasters [J]. Water Resources Protection, 2024, 40(1): 6-15. (in Chinese))
- [2] 徐宗学, 陈浩, 任梅芳, 等. 中国城市洪涝致灾机理与风险评估研究进展[J]. 水科学进展, 2020, 31(5): 713-724. (XU Zongxue, CHEN Hao, REN Meifang, et al. Progress on disaster mechanism and risk assessment of urban flood/waterlogging disasters in China[J]. Advances in Water Science, 2020, 31(5): 713-724. (in Chinese))
- [3] 李超超, 程晓陶, 申若竹, 等. 城市化背景下洪涝灾害新特点及其形成机理[J]. 灾害学, 2019, 34(2): 57-62. (LI Chaochao, CHENG Xiaotao, SHEN Ruozhu, et al. New characteristics and formation mechanism of flood and waterlogging disasters in the context of rapid urbanization [J]. Journal of Catastrophology, 2019, 34(2): 57-62. (in Chinese))
- [4] 卢兴超, 徐宗学, 李永坤, 等. 基于SWMM与LISFLOOD-FP耦合模型的城市街区内涝模拟研究[J]. 水资源保护, 2024, 40(3): 98-105. (LU Xingchao, XU Zongxue, LI Yongkun, et al. Research on urban block waterlogging simulation based on coupling model of SWMM and LISFLOOD-FP[J]. Water Resources Protection, 2024, 40(3): 98-105, 124. (in Chinese))
- [5] CRED, UNDRR. The human cost of disasters: an overview of the last 20 years (2000-2019) [EB/OL]. (2020-10-16) [2024-06-10]. <https://www.undrr.org/publication/human-cost-disasters-overview-last-20-years-2000-2019>.
- [6] ANDIMUTHU R, YANDASAM P, MUDGAL B V, et al. Performance of urban storm drainage network under changing climate scenarios: flood mitigation in Indian coastal city[J]. Scientific Reports, 2019, 9(1): 7783.
- [7] PANDA R K, PRAMANIK N, BALA B. Simulation of river stage using artificial neural network and MIKE 11 hydrodynamic model [J]. Computers & Geosciences, 2010, 36(6): 735-745.
- [8] CHANG F J, CHEN P A, LU Y R, et al. Real-time multi-step-ahead water level forecasting by recurrent neural networks for urban flood control[J]. Journal of Hydrology, 2014, 517: 836-846.
- [9] CHEN Jian, LI Yaowei, ZHANG Changhui, et al. Urban flooding prediction method based on the combination of LSTM neural network and numerical model [J]. International Journal of Environmental Research and Public Health, 2023, 20(2): 1043.
- [10] 周聂, 侯精明, 陈光照, 等. 基于机器学习的山洪灾害快速预报方法[J]. 水资源保护, 2022, 38(2): 32-40. (ZHOU Nie, HOU Jingming, CHEN Guangzhao, et al. A rapid forecasting method for mountain flood disaster based on machine learning algorithms [J]. Water Resources Protection, 2022, 38(2): 32-40. (in Chinese))
- [11] 苑希民, 黄玉啟, 田福昌, 等. 基于LSTM-GM神经网络模型的风暴潮增水预报方法[J]. 水资源保护, 2023, 39(6): 8-15. (YUAN Ximin, HUANG Yuqi, TIAN Fuchang, et al. Research on forecasting method of storm surge based on LSTM-GM neural network model[J]. Water Resources Protection, 2023, 39(6): 8-15. (in Chinese))
- [12] PATRO S, CHATTERJEE C, MOHANTY S, et al. Flood inundation modeling using MIKE FLOOD and remote sensing data[J]. Journal of the Indian Society of Remote Sensing, 2009, 37(1): 107-118.
- [13] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [14] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [15] 宋天宇. 基于长短时记忆网络的山丘区洪水预报研究[D]. 大连: 大连理工大学, 2020.
- [16] 张荣, 李伟平, 莫同. 深度学习研究综述[J]. 信息与控制, 2018, 47(4): 385-397. (ZHANG Rong, LI Weiping, MO Tong. Review of deep learning [J]. Information and Control, 2018, 47(4): 385-397. (in Chinese))
- [17] 石卓, 史东华, 姚成, 等. 基于径流模数的LSTM模型在无资料嵌套流域的应用[J]. 河海大学学报(自然科学版), 2024, 52(3): 51-57. (SHI Zhuo, SHI Donghua, YAO Cheng, et al. Application of runoff modulus-based LSTM in ungauged nested watersheds [J]. Journal of Hohai University (Natural Sciences), 2024, 52(3): 51-57. (in Chinese))
- [18] TREISMAN A M, GELADE G. A feature-integration theory of attention [J]. Cognitive Psychology, 1980, 12(1): 97-136.
- [19] MIORELLI R, KULAKOVSKIY A, CHAPUIS B, et al. Supervised learning strategy for classification and regression tasks applied to aeronautical structural health monitoring problems [J]. Ultrasonics, 2021, 113: 106372.
- [20] FLETCHER T D, ANDRIEU H, HAMEL P. Understanding, management and modelling of urban hydrology and its consequences for receiving waters; a state of the art [J]. Advances in Water Resources, 2013, 51: 261-279.
- [21] XUE Jiankai, SHEN Bo. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [22] 成霄楠. 基于改进麻雀搜索算法及组合模型的光伏发电功率超短期预测研究[D]. 保定: 河北大学, 2023.
- [23] 谭雨欣, 吴端炜. 基于MIKE URBAN的大亚湾澳头圆盘区域内涝模拟及排涝对策[J]. 人民珠江, 2023, 44

- (5): 18-25. (TAN Yuxin, WU Duanwei. Waterlogging simulation and drainage countermeasures of Aotou Yuanpan area in Daya Bay based on MIKE URBAN[J]. Pearl River, 2023, 44(5): 18-25. (in Chinese))
- [24] 卓小燕, 孙翔. 基于 MIKE 模型的城市内涝风险评估与整治方案效果研究[J]. 水利规划与设计, 2023(10): 34-40. (ZHUO Xiaoyan, SUN Xiang. Risk assessment of urban waterlogging based on MIKE model and study on the effect of remediation scheme [J]. Water Resources Planning and Design, 2023(10): 34-40. (in Chinese))
- [25] 侯俊, 陈诚, 郑玉磊, 等. 基于 MIKE FLOOD 模型的平原水网地区内涝治理效果模拟研究[J]. 水利水电科技进展, 2024, 44(6): 41-47. (HOU Jun, CHEN Cheng, ZHENG Yulei, et al. Simulation study on effectiveness of waterlogging control in plain water network areas based on MIKE FLOOD model [J]. Advances in Science and Technology of Water Resources, 2024, 44(6): 41-47. (in Chinese))
- [26] 方煜铭, 马旭民, 林凯荣, 等. 基于 MIKE FLOOD 的深圳市大空港片区暴雨内涝模拟分析[J]. 人民珠江, 2024, 45(5): 88-95. (FANG Yuming, MA Xumin, LIN Kairong, et al. Simulation analysis of rainstorm waterlogging in Shenzhen Dakonggang area based on MIKE FLOOD[J]. Pearl River, 2024, 45(5): 88-95. (in Chinese))
- (收稿日期: 2024-08-14 编辑: 施业)
- 
- (上接第 55 页)
- [24] 陈文学, 穆祥鹏, 崔巍. 南水北调中线工程桥墩壅水特性研究[J]. 水利水电技术, 2015, 46(11): 121-125. (CHEN Wenxue, MU Xiangpeng, CUI Wei. Study on backwater characteristics of bridge-piers of Mid-Route of South-to-North Water Diversion Project [J]. Water Resources and Hydropower Engineering, 2015, 46(11): 121-125. (in Chinese))
- [25] 何国建, 方红卫, 府仁寿. 桥墩群对河道水流影响的三维数值分析[J]. 水动力学研究与进展, 2007, 22(3): 345-351. (HE Guojian, FANG Hongwei, FU Renshou. Three-dimensional numerical analysis on water flow affected by piers[J]. Journal of Hydrodynamics, 2007, 22(3): 345-351. (in Chinese))
- [26] 武玉涛, 任华堂, 夏建新. 圆柱绕流研究进展及展望[J]. 水运工程, 2017(2): 19-26. (WU Yutao, REN Huatang, XIA Jianxin. Research progress and prospects on flow across cylinder[J]. Port & Waterway Engineering, 2017(2): 19-26. (in Chinese))
- [27] 刘明潇, 王泽众, 朱勇杰, 等. 大型输水隧洞出口扩散段非稳流态研究[J]. 灌溉排水学报, 2023, 42(12): 107-116. (LIU Mingxiao, WANG Zezhong, ZHU Yongjie, et al. Unsteady flow in diffusion section at the outlet of large water conveyance tunnel [J]. Journal of Irrigation and Drainage, 2023, 42(12): 107-116. (in Chinese))
- [28] 杨小亭, 霍跃东, 徐孝平. 南水北调中线工程桥墩水力学试验研究[J]. 武汉水利电力大学学报, 2000, 33(6): 16-19. (YANG Xiaoting, HUO Yuedong, XU Xiaoping. Hydraulic experimental study of piers for middle route scheme of South-to-North Water Transfer Project [J]. Journal of Wuhan University of Hydrodynamics & Electric Engineering, 2000, 33(6): 16-19. (in Chinese))
- [29] 刘松, 符松. 串列双圆柱绕流问题的数值模拟[J]. 计算力学学报, 2000, 17(3): 260-266. (LIU Song, FU Song. Numerical simulation of flow past two cylinders in tandem arrangement [J]. Chinese Journal of Computational Mechanics, 2000, 17(3): 260-266. (in Chinese))
- [30] 廖俊, 景思睿. 高雷诺数下双圆柱绕流的数值模拟[J]. 水动力学研究与进展. 2001, 16(1): 101-110. (LIAO Jun, JING Sirui. Numerical simulation of flow around two cylinders at high Reynolds number [J]. Journal of Hydrodynamics, 2001, 16(1): 101-110. (in Chinese))
- [31] 王玉波, 张亚红. 不同流态下淡水壳菜附着能力的影响研究: 以南水北调中线沙河渡槽为例[J]. 城镇供水, 2023(增刊1): 119-124. (WANG Yubo, ZHANG Yahong. Study on influence of different flow patterns on the attachment capacity of Limnoperna fortunei: a case study on the Shahe Aqueduct in the Middle Route of South-to-North Water Diversion Project [J]. City and Town Water Supply, 2023(Sup1): 119-124. (in Chinese))
- [32] 天津大学水利水电工程系. 淡水壳菜附着对典型渠道、输水建筑物(渡槽、倒虹吸)断面糙率的影响及措施建议报告[R]. 天津: 天津大学水利水电工程系, 2022.
- [33] 杨开林, 汪易森. 渠道糙率率定误差分析[J]. 水利学报, 2012, 43(6): 639-644. (YANG Kailin, WANG Yisen. Error analysis of roughness coefficient calibration for channels [J]. Journal of Hydraulic Engineering, 2012, 43(6): 639-644. (in Chinese))
- [34] 杨开林, 汪易森. 提高渠道糙率率定精度的方法[J]. 南水北调与水利科技, 2011, 9(6): 1-4. (YANG Kailin, WANG Yisen. Improvement of calibration precision of channel roughness [J]. South-to-North Water Transfers and Water Science & Technology, 2011, 9(6): 1-4. (in Chinese))
- [35] 王媛, 张志慧, 任杰, 等. 基于动态权重云模型的大型渡槽安全综合评价[J]. 河海大学学报(自然科学版), 2023, 51(2): 56-63. (WANG Yuan, ZHANG Zhihui, REN Jie, et al. Comprehensive evaluation of large-scale aqueduct safety based on dynamic weight-cloud model [J]. Journal of Hohai University (Natural Sciences), 2023, 51(2): 56-63. (in Chinese))
- (收稿日期: 2024-08-28 编辑: 施业)