

引用格式:王乐,王珂,覃桂锋,等.多模态数据融合配电终端淹没风险快速预测方法[J].电力科学与技术学报,2024,39(6):92-100.

Citation: WANG Le, WANG Ke, QIN Guifeng, et al. A rapid prediction method for flooding risk of distribution terminals based on multimodal data fusion [J]. Journal of Electric Power Science and Technology, 2024, 39(6): 92-100.

多模态数据融合配电终端淹没风险快速预测方法

王 乐^{1,2}, 王 珂³, 覃桂锋³, 张玉波^{1,2}

(1. 广西电网有限责任公司电力科学研究院, 南宁 广西 530023; 2. 广西电力装备智能控制与运维重点实验室, 南宁 广西 530023;
3. 广西电网有限责任公司南宁供电局, 南宁 广西 530029)

摘 要:受气候变化与城市布局影响,城市内涝日趋严重,威胁配电系统可靠供电。探索城市洪涝灾害预测模型,实现配电设备风险预测,可以降低洪涝灾害带来的影响。然而,现有基于水动力模型的方法计算复杂度过高,难以保证大范围淹没模拟预报的时效性,基于数据驱动模型方法的训练数据不足,难以满足快速精准城市内涝预警需求。为解决以上问题,提出基于多模态数据融合的降雨内涝快速预测模型。该方法通过水动力模型生成训练数据以解决训练数据量不足的问题,将高程地图等图像数据与降雨序列时序数据进行融合以提高预测精度,并以桂林市作为研究对象,验证所提方法的有效性。实验结果表明,所提方法在保持较高精度的同时,有较低的计算复杂度,可为配电终端风险评估提供参考。

关 键 词:多源数据融合;深度学习;内涝预测;配电终端风险评估

DOI: 10.19781/j.issn.1673-9140.2024.06.010 中图分类号: TM863 文章编号: 1673-9140(2024)06-0092-09

A rapid prediction method for flooding risk of distribution terminals based on multimodal data fusion

WANG Le^{1,2}, WANG Ke³, QIN Guifeng³, ZHANG Yubo^{1,2}

(1. Electric Power Research Institute, Guangxi Power Grid Co., Ltd., Nanning 530023, China; 2. Guangxi Key Laboratory of Intelligent Control and Maintenance of Power Equipment, Nanning 530023, China; 3. Nanning Power Supply Bureau, Guangxi Power Grid Co., Ltd., Nanning 530029, China)

Abstract: Due to climate change and urban layout, urban waterlogging disasters are becoming increasingly severe, posing a serious threat to the stable power supply of the distribution system. In order to minimize the impact of flood disasters, it is urgent to explore urban flood disaster prediction models to achieve distribution equipment risk prediction. However, the existing hydrodynamic model-based method has high computational complexity and is difficult to guarantee the timeliness of large-scale flooding simulation forecast. The data-driven model-based method has insufficient training data, which is insufficient to meet the requirements of fast and accurate urban waterlogging warnings. To this end, a rapid waterlogging prediction model based on multimodal data fusion is proposed. This method generates training data through a hydrodynamic model to solve the problem of insufficient training data and integrates image data such as elevation maps with rainfall sequence time series data to improve prediction accuracy. Furthermore, Guilin City is used as the research object to verify the effectiveness of the proposed method. The experimental results show that the proposed method maintains high accuracy while reducing computational complexity. This method can provide a reference for risk assessment of distribution terminals.

Key words: multimodal data fusion; deep learning; waterlogging prediction; risk assessment of distribution terminal

收稿日期: 2023-10-07; 修回日期: 2024-02-27

基金项目: 广西电网有限责任公司科技项目(GXKJXM20220107)

通信作者: 王 乐(1986—), 女, 硕士, 高级工程师, 主要从事输变电设备防灾减灾研究; E-mail: happywle@163.com

由于全球升温,极端降水事件强度和频率剧增^[1-2]。配电网设备数量众多,且选址受用户限制,防涝等级较低,雨涝淹没风险增大,给电网的安全稳定运行造成了极大危害。2020年6月,受强降雨影响,广西电网超100条10 kV及以上配电线路停运,25万用户停电。2021年10月,山西暴雨造成超五百多条10 kV及以上配电线路停运^[3]。研究暴雨内涝时可准确预测配电设备雨涝淹没风险的方法,能避免城市雨涝灾害影响供电可靠性。

城市雨涝实时预报不仅要考虑暴雨因素,更要综合考虑城市地形、下垫面等因素^[4]。因此,城市雨涝预报的关键是需要建立能对整个暴雨洪涝过程进行精细化模拟的城市洪涝预报模型。由于城市雨涝致灾机理的复杂性、城市下垫面的高度空间异质性、城市降雨的高时空变异性等原因,城市洪涝实时预报面临巨大挑战^[5]。近年来,随着算力的提升与机器学习技术的发展,国内外学者在城市洪涝实时预报方面取得了一定成果。城市洪涝实时预报系统按照其建模机理,可分为物理建模法与数据驱动法。

物理建模法借助精细化数值模型,以真实地理环境为基础,对水流在城区的流动过程进行全程精细化模拟^[6-10]。根据所采用数值模型的不同,物理建模法可分为水文水动力模型和简化模型。水文水动力模型主要采用流体力学的基本方程与物理模型描述水流的汇流过程,具有物理意义明确、准确度较高的优点^[11]。但是,该方法需要求解高阶微分方程,预测速度较低,仅模拟3 h降雨就可能花费10 h以上的计算时间。随着城市下垫面的日新月异,建模时间呈几何式增长^[12],因此,该模型难以满足电网公司的应急预警时效要求。为提升模型的预测效率,相关模型忽略地表径流的具体过程,依据地形和水量平衡原理来预测淹没区域。该类方法在快速评估城市洪涝风险方面取得了一定成就,但是简化模型的物理意义模糊导致其在实践中仍然会长期受到质疑和争论^[13]。总的来说,物理建模法的预测精度较高,但受限于计算量过大,该类方法实时性较差,难以在实践中应用。

不同于物理建模法建立不同物理模型模拟城市洪涝形成的方式,数据驱动法采用黑箱法,直接建立降雨量、积水图像等输入数据与积水点水深、范围等输出数据的回归模型,实现城市洪涝的快速精准预报^[14-18]。得益于多源遥感技术与人工智能技术的发展,天空地多源遥感技术为经验模型的建立

提供了详细的数据源^[19],云计算技术与机器学习技术为高效学习输入与输出之间的关联模型奠定了基础,其建模方法包括前馈神经网络、反向传播(back propagation, BP)神经网络、卷积神经网络(convolutional neural network, CNN)^[20-23]等。总的来说,数据驱动法的预测速度相比于物理建模法有极大提升,可满足当前智慧城市背景下的精准应急管理决策需求,是近年来的研究热点。该方法需要精准的数据学习输入输出关系,故如何获取稳定可靠的数据是该方法需要着重解决的问题。

数据驱动法是解决洪涝灾害快速及时播报的有效方法,然而,受限于城市下垫面的复杂性、实测验证数据的匮乏、降雨预报数据和城市洪涝模型的不确定性等原因,其仍然存在很多需要研究和完善的问题。主要表现如下。1)预测模型仍不完善。数据驱动法可满足智慧城市背景下的实时预测需要,但目前关于暴雨内涝积水深度的预测主要使用降雨序列等时序数据,未考虑城市地形、下垫面差异与径流系数等因素,模型的预测精度有待提高。2)水文监测传感器布置不足,数据量不够。现有水文监测传感器主要分布在河流主干道,地面监测传感器较少,而采用遥感技术采集地表积水信息受云层与高楼干扰较大,导致可用的地表积水信息数据严重不足。而数据驱动法需要大量数据进行训练,数据的不足成为限制城市洪涝预报研究进一步发展的重要因素。

基于以上问题与挑战,本文考虑残差网络(residual network, ResNet)能有效提取降雨的空间特征,但对于长期序列可能无法捕捉时序信息间的时间相关性和长期依赖关系,提出添加长短期记忆(long short term memory, LSTM)网络来对时间序列长期依赖关系进行挖掘。通过ResNet和LSTM融合模型,更全面地理解和处理多模态数据,提升模型的预测精度;其次,考虑数据驱动法需要大量数据进行训练,本文收集地表数据,采用二维水动力模型进行城市内涝模拟,得到降雨-内涝分布样本,可解决数据收集难、数据量不够的问题;最后,所提模型被应用于配电设备内涝风险预测,建立配电终端淹没风险模型,为配电终端雨涝灾害风险评估提供科学指导。

1 基于多模态数据融合的降雨内涝快速预测

暴雨内涝的积水深度与降雨量、地面高程、地

表粗糙度和雨洪的径流系数等参数存在密切关系。基于此,拟采用多模态融合方法,将降雨序列时序数据与高程地图、地表粗糙度图和径流系数图像数据融合,采用不同网络结构学习不同模态的数据特征,提升积水深度预测的准确性,其方法框架如图1所示。首先,采用LSTM方法从降雨序列中提取降雨时序特征,采用ResNet18网络从高程地图、地表粗糙度和径流系数分布图中提取地表特征;其次,采用多模态特征融合方法将降雨时序特征与地表特征融合;最后,通过全连接层对积水深度进行预测。

LSTM网络是循环神经网络(recurrent neural network, RNN)的变体,可作为复杂的非线性单元用于构造更大型深度神经网络^[24]。与RNN相比,LSTM网络能有效捕捉长序列之间的语义关联,解决了RNN的长期依赖问题,缓解了训练RNN时BP神经网络带来的梯度消失或爆炸现象,被广泛应用于时间序列预测^[25]、分类^[26]、翻译^[27]等领域。基于以上优势,本文选取LSTM提取降雨序列的时序特征。LSTM通过门结构控制,门结构主要包括遗忘门、输入门与输出门,如图2所示。

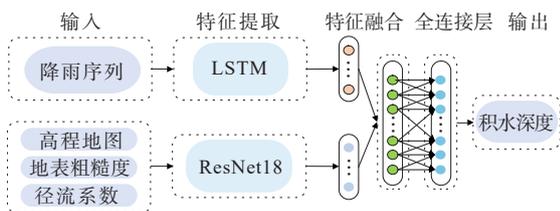


图1 基于多模态数据融合的积水深度预测框架

Figure 1 Framework for predicting water depth based on multimodal data fusion

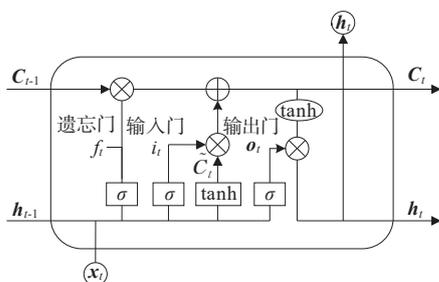


图2 LSTM的网络结构

Figure 2 Network structure of LSTM

遗忘门 f_t 决定是否记忆先前单元状态信息,计算如下:

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

式中, W_f 、 b_f 分别为遗忘门权重矩阵与偏置项矩阵; σ 为sigmoid激活函数; $[h_{t-1}, x_t]$ 为前时刻单元输出 h_t

和当前输入 x_t 组成的矩阵。

输入门 i_t 控制更新前一单元和当前单元中输入哪些信息,计算如下:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (4)$$

式中, W_i 、 b_i 分别为输入门权重矩阵、偏置项矩阵; W_c 、 b_c 分别为更新值的权重、偏置项; \tilde{C}_t 为状态中的候选值; \tanh 为候选细胞信息的激活函数; C_t 为更新的细胞状态。

输出门 o_t 决定单元状态中哪些信息记忆为输出状态 h_t ,计算如下:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \tanh(C_t) \quad (6)$$

式中, W_o 、 b_o 分别为输出门的权重矩阵和偏置项矩阵。

LSTM网络中, W_f 、 W_i 和 W_o 为权值矩阵, b_f 、 b_i 和 b_o 为偏置值,可将训练数据置入模型训练网络,通过梯度下降法迭代更新,直到模型收敛,确定参数的最终值。设置两层的隐藏层,节点数分别为100与50。将模型最后一层隐藏层的输出状态 h_t 作为特征矩阵,输入到后续的特征融合层。

卷积网络是提取图像类数据的有力工具。通过卷积池化与正则化等操作,提取出图像中 useful 信息,近年来在图像分类、图像语义分割与异常检测等领域应用广泛。从最基础的卷积神经网络,到后续改进的GoogLeNet、ResNet等网络,卷积类网络在各项任务上都取得了优异的成绩^[27-29]。考虑ResNet网络在特征提取时可有效避免梯度的消失,本文采用ResNet18网络提取图像类数据的特征。ResNet18网络包括17层卷积层和最后1层全连接层。本文去掉ResNet18最后1层全连接层,选取前面17层卷积层提取高地图、地表粗糙度图和径流系数图像的地表特征,其结构如图3所示。

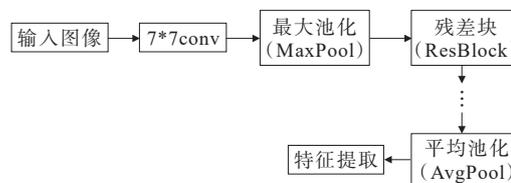


图3 ResNet18图像特征提取结构

Figure 3 ResNet18 structure for image feature extraction

ResNet18的主要模块为残差块(ResBlock)。

残差块是由多个卷积层和批归一化层组成的,通过引入跳跃连接,将输入直接传递到输出,使得网络可以学习残差,以避免丢失信息,其结构如图 4 所示。

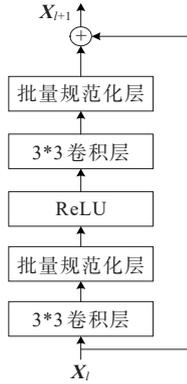


图 4 ResNet18 残差块结构

Figure 4 ResNet18 residual block structure

对于输入矩阵 X_i , 经过残差块后的输出 X_{i+1} 可表示为

$$X_{i+1} = X_i + F(X_i * W_i) \quad (7)$$

式中, F 为包含卷积操作、归一化操作与激活函数 ReLU 的复合函数; W_i 为权值矩阵; 卷积操作用来提取图像中的信息:

$$s(i, j) = (X * W)(i, j) = \sum_{m=1}^m \sum_{n=1}^n x(i+m, j+n) \omega(m, n) \quad (8)$$

式中, W 为权值矩阵; X 为输入图像; m 、 n 分别为图像的长和宽。归一化操作可加快模型训练收敛速度, 避免梯度爆炸或梯度消失, 计算如下:

$$u_B = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n x(i+m, j+n) \quad (9)$$

$$\sigma_B^2 = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [x(i, j) - u_B]^2 \quad (10)$$

$$\hat{x}(i, j) = (x(i, j) - u_B) / \sqrt{\sigma_B^2 + \xi} \quad (11)$$

式(9)~(11)中, u_B 为图像块的均值; σ_B^2 为图像块的方差; ξ 为一个很小的常数, 作用为避免 $\sigma_B^2=0$ 时分母为 0。

激活函数 ReLU 为分段线性函数, 可用来提高模型稀疏性和增强模型非线性能力:

$$y = \max(0, \mathbf{w}^T x + b) \quad (12)$$

式中, \mathbf{w} 为权值矩阵; b 为偏置向量; $\max()$ 为取最大值操作。

2 基于二维水动力模型的样本生成

由于城市气象水文过程十分复杂, 训练城市洪

涝实时预报网络需要大量高精度数据作支撑。然而, 由于内涝监测数据难以获取, 实际可用的数据量非常少。近年来, 由于二维水动力模型的推动与发展, 有多个模拟软件实现了洪水淹没深度的准确模拟, 如 FloodArea 与 HEC-RAS 等。该类软件可为训练城市洪涝实时预报模型提供必要的基础数据。考虑 FloodArea 操作性较强、可靠性较高, 本文将用于仿真暴雨过程。FloodArea 为基于 GIS 栅格数据与二维非恒定流水动力学模型构建的淹没模拟软件, 可计算洪水淹没的深度与范围, 已在二十多个国家的洪水雨涝淹没相关决策、分散式防洪领域及科研和工程中得到应用^[31]。基于 FloodArea 的暴雨模拟具体过程如图 5 所示。

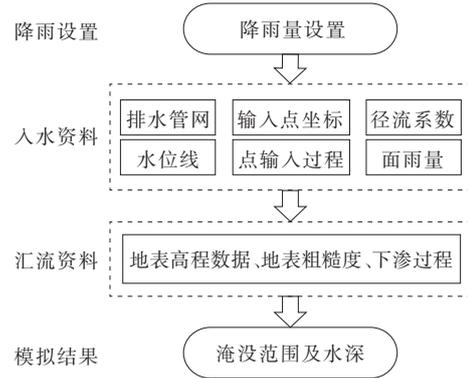


图 5 基于 FloodArea 的暴雨模拟过程

Figure 5 Rainstorm simulation process based on FloodArea

首先, 基于降雨强度计算降雨量并按常用的芝加哥雨型每小时的分配雨量比例进行分配。降雨强度公式为

$$q = \frac{167A_1(1 + C \lg P)}{(t + b)^n} \quad (13)$$

式中, q 为暴雨强度, $L/S \cdot 104 \text{ m}^2$; P 为设计重现期, 取值范围为 0.25~100, a ; t 为降雨历时, min。 A_1 、 b 、 C 、 n 则是受地方暴雨特性影响的相关的参数, 不同地区的取值往往不同, 可以查找相关资料确定。

其次, 设置入水资料, 包括排水管网、坐标与径流系数等。径流系数代表径流量与降雨量间的关系, 即任意时段内径流深度与同时段内降水量之比。值越大表示地表形成的径流越大, 下渗越小。

再次, 设置汇流资料, 包括地表高程数据、地表粗糙度与下渗过程:

$$K_{st} = \frac{1}{n} \quad (14)$$

式中, n 为各类地物的曼宁糙率系数, 表征对水流阻力影响的综合性无量纲数, 数值越大粗糙度越大, 数

值越小粗糙度越小,可根据曼宁糙率系数值表确定。

最后,基于以上数据,采用水动力原理进行模拟计算,同时考虑1个栅格周围的8个单元,利用式(3)计算流入邻近栅格单元的水量^[28]:

$$V = K_{st} \cdot r_{hy}^{2/3} \cdot I^{1/2} \quad (15)$$

式中, V 为水量; K_{st} 为地表粗糙情况对水流的影响系数; r_{hy} 为水力半径; I 为地形坡度。水流深度由单元之间的最低水位和最高地形高程之间的差决定,对每个单元都进行模拟计算,得到每个单元格特定时间的淹没范围和积水深度。

排水是城市积涝过程模拟的重要环节,本文通过对模拟结果进行调整来体现排水对积涝过程的影响,其基本思想为通过城市建设雨水管网的设计重现期计算该重现期下的积涝结果,以此模拟结果作为排水量,将日常降雨量模拟后得到的积涝结果减去设计重现期下的积涝结果,得到最终的积涝模拟结果。

3 仿真分析

本文以桂林市为例,验证所提出的基于多模态数据融合的降雨内涝快速预测模型的性能。首先,基于FloodArea进行各种降雨模式下的淹没仿真,生成降雨-内涝训练样本,并进行预处理;其次,将训练样本数据所提出的基于多模态数据融合的降雨内涝快速预测模型,确定模型中的参数;最后,使用验证数据对训练好的模型进行验证,并与多个模型进行比较,突出所提方法的性能。

3.1 训练数据生成

城市洪涝实时预报研究所需数据可分为基础数据和验证数据两大类,基础数据主要包括降雨、下垫面、粗糙度等;验证数据主要包括河道水位、积水水深及范围等。基于文2所述原理,根据桂林历史降雨与地形图,生成训练数据。首先,根据桂林历史降雨,设置降雨量大小,得到降雨量时间序列,10年一遇与50年一遇曲线如图6所示。

其次,获取桂林市地表高程地图、地表粗糙度分布图与径流系数图。高程地图可从地图软件中获取。对于地表粗糙度分布图,可根据中国自然资源部发布的30 m空间分辨率全球地表覆盖数据得出。其中,地表类型包括耕地、林地、草地、水体和人造地5种类型,根据相关资料,其粗糙度分别为25、18、20、50与6^[32]。径流系数主要受淹没地区的地形、流域特性因子、平均坡度、地表植被

情况及土壤特性等的影响。根据土地利用类的分布和城市建筑分布特征,设定耕地、林地、草地、水体和人造地的径流系数分别为0.35、0.20、0.40、0.10与0.80。

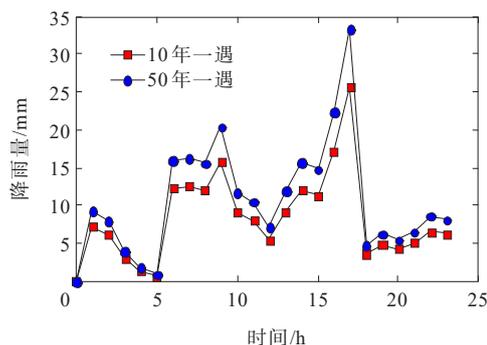


图6 10年一遇与50年一遇降雨时间序列

Figure 6 Rainfall time series of 10 years and 50 years return periods

根据相关规程规范,城区常住人口在50万以下的小城市按2年一遇标准设计排水管渠^[20],因此将2年重现期得到的积涝结果作为管网最大排水能力。

基于以上数据,通过FloodArea软件模拟桂林降雨过程,可得到降雨后地面积水深度。

后续深度学习网络的训练数据中,降雨序列、高程地图、地表粗糙度分布图与径流系数图作为输入,积水深度作为输出。考虑不同传感器采集的数据范围差异较大,使用该类数据进行训练时易导致模型难以收敛。因此,本文对采集的数据进行归一化处理:

$$x' = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (16)$$

式中, x' 为归一化后的数据; x 为原始数据; x_{\min} 为该类型数据最小值; x_{\max} 为该类型数据最大值。

3.2 网络训练设置

选取桂林市的主城区作为研究对象,研究区域包括桂林市主城区与部分近郊区域,面积约为160 km²。桂林市高程地图等图像数据的原始分辨率为11 688×8 271,考虑图像分辨率过大,本文采用滑动窗法对图像数据进行裁剪。首先,基于ResNet18网络的输入图像大小为224×224,将图像尺寸缩放为11 648×8 288,并采用滑动窗法将图像分成1/2重叠的尺寸为224×224的小块,共得到52×37×4=7 696个图像块。其次,在降雨量上,设置降雨等级为10年一遇、50年一遇与100年一遇3种类型,故可得到3种降雨时间序列。总共生成7 696×3=23 088个训练样本。选取80%作为训练

样本,20%作为预测样本,训练与预测数据量如表 1 所示。

表 1 训练与预测样本数量

Table 1 Number of training and prediction samples

训练样本数	预测样本数	总数
18 470	4 618	23 088

为降低训练难度,减少训练过程中的参数,本文将 ResNet18 网络的前 8 层网络固定。在特征提取网络中,底层网络主要功能为提取图像的主要结构。对于不同的图像类型,其底层网络的参数差异较小,因此,固定 ResNet18 网络的底层网络参数是可行的。在训练期间,训练的批量大小设置为 20,迭代次数设置为 60,学习率设置为 0.1,优化器使用 Adam 优化器,损失函数采用均方误差(mean square error, MSE),表达式为

$$e_{MSE} = \sum_{i=1}^N (y_{(i)} - y'_{(i)})^2 / N \quad (17)$$

式中, N 为训练样本数; $y_{(i)}$ 为真实的积水水位值; $y'_{(i)}$ 为预测水位值。

3.3 预测结果与对比分析

桂林市部分低洼位置变电站进行了站外滞水水位监测,可记录每 0.5 h 的内涝水位。选择 2023 年 5 月 22 日强降雨数据进行淹没预测。降雨过程 24 h 内涝深度实际值与所提方法预测值的对比效果如图 7 所示。从图 7 中可以看出,预测值与实际值走势一致,且高度贴合,没有偏差较大的情况出现,这说明所提方法可以准确地预测洪涝灾害时的积水深度。

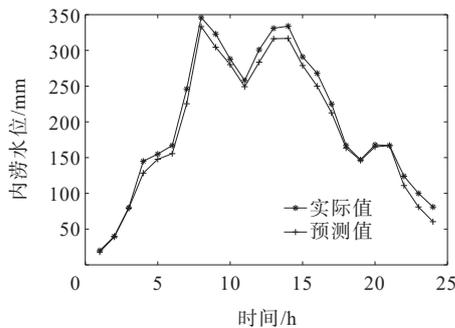


图 7 所提方法的预测值与实际值对比

Figure 7 Comparison of predicted of proposed method and actual values

为验证所提网络的性能,将所提网络的 LSTM 时序特征提取网络转换成 BP 神经网络与 RNN, ResNet 换成 CNN、AlexNet 与视觉几何组 (visual

geometry group, VGG) 网络 VGG-16, 其网络设置如表 2 所示。在训练时,所有网络的迭代次数都设置为 60,学习率设置为 0.1。将所提网络中的 LSTM 与 ResNet 特征提取网络转换成以上网络,并计算各网络的性能。在对比中,采用均方根误差 (root-mean-square error, RMSE)、平均绝对误差 (mean absolute error, MAE) 与决定系数作为性能指标,其中 RMSE 与 MAE 的值越小、决定系数 R^2 (R -squared) 越大,则性能越好,对比结果如表 3 所示。由表 3 可见,所提网络 (LSTM+ResNet) 的 RMSE 与 MAE 指标数值最小, R^2 指标值最大,表明所提网络预测精度最高。其主要原因是 ResNet 可以解决梯度消失或爆炸现象。在高程地图与粗糙度图像中,图像变化较为缓慢,若采用 CNN 与 VGG 等普通卷积网络,在训练时易导致梯度消失,预测效果不佳,而 ResNet 采用跳连方式,解决了梯度消失问题,使预测效果大幅上升。

表 2 对比网络参数设置

Table 2 Parameters setting of compared network

模型	网络设置
BP	包含 2 个隐藏层,其隐藏层节点数分别设置为 100 与 50
RNN	包含 2 个隐藏层,其隐藏层节点数分别设置为 100 与 50
CNN	包含 3 个卷积层,2 个池化层
AlexNet	包含 5 个卷积层,3 个池化层
VGG-16	包含 13 个卷积层,5 个池化层

表 3 各模型的预测精度对比

Table 3 Comparison of prediction accuracies of models

模型	RMSE/mm	MAE/mm	R^2 /mm
BP+ResNet	46.43	28.83	0.75
RNN+ResNet	43.35	26.45	0.77
LSTM+CNN	45.57	27.37	0.82
LSTM+AlexNet	32.36	25.87	0.83
LSTM+VGG-16	28.87	23.43	0.86
LSTM+ResNet	25.54	21.35	0.88

为更深层次地探究所提方法的性能,本文对在不同降雨等级下所提方法的预测性能进行了研究。其中,降雨等级包括 5 年一遇、10 年一遇与 50 年一遇 3 种类型,模型的预测精度如表 4 所示。从表 4 中可以看出,5 年一遇的降雨等级下模型预测性能最好,50 年一遇的预测性能最差。其原因主要有两点:首先,5 年一遇的积水深度比 50 年一遇的积水深

度低,因此,其RMSE与MAE指标性能更好;其次,5年一遇的积水深度在降雨时其变化速度相对于50年一遇的变化速度慢,模型能更好地跟踪降水量的变化,使其 R^2 指标性能更好。

表4 在不同降雨等级下所提方法的预测性能

Table 4 Prediction performance of proposed method under different rainfall levels

降雨等级	RMSE/mm	MAE/mm	R^2 /mm
5年一遇	21.55	18.63	0.91
10年一遇	24.46	20.32	0.89
50年一遇	28.21	24.27	0.86

其次,预测耗时是评估模型效果的重要指标。为比较各模型的计算复杂度,在50年一遇降雨量下,将所有模型预测积水深度的耗时作为指标。为比较水动力模型与数据驱动模型的预测耗时,引入FloodArea水动力模型仿真时间作为比对。以上实验是在12代Intel i7处理器,12GRAM下运行,结果如表5所示。由表5可得,基于数据驱动模型的计算耗时差距不大,计算耗时均显著低于需要求解大量微分方程水动力模型。

表5 各模型的预测耗时对比

Table 5 Comparison of prediction time of models

模型	耗时/h
BP+ResNet	0.36
RNN+ResNet	0.46
LSTM+CNN	0.39
LSTM+AlexNet	0.51
LSTM+VGG-16	0.55
LSTM+ResNet	0.58
水动力模型	105.00

由以上分析可知,所提模型在获得较高预测精度的同时拥有较低计算复杂度。基于FloodArea软件的预测结果拥有较高预测性能,但是该类方法预测速度非常低,难以满足时效性需求。本方法的提出为解决洪涝灾害的实时预测奠定了基础。

得到降雨积水淹没深度预测值后,需要结合配电房结构特征确定是否淹没停电。根据配电房典型设计规范,一般要求配电房设置30~50 cm的基础高度进行通风^[32]。由于工程上一般在淹没配电房基础高度时主动拉停电源,可将预测淹没深度大于50 cm区域设定为淹没停电风险突出的配电房,并采取有针对性的应急措施。

4 结语

本文针对城市暴雨洪涝灾害预警面临的问题,提出了一种基于多源模态数据融合的城市降雨内涝快速预测方法。主要研究工作及创新点总结如下。

1) 本文提出采用二维水动力模型仿真不同降雨条件下的暴雨积水过程,生成降雨-内涝训练样本数据,解决现有方法中训练数据量不足的问题。

2) 本文提出同时利用降雨时序数据和高程地图、地表粗糙度、径流系数等空间数据的多源模态数据融合方法。其中,降雨时间序列通过LSTM网络提取时序特征,图像数据通过ResNet18网络提取空间特征,并将时空信息融合,提高模型的预测精度。

3) 本文结合桂林市实际数据,应用所提出的模型进行降雨洪涝预测。结果表明,所提方法可以在保持较高预测精度的同时具有较低的计算复杂度。

综上所述,本文通过数据驱动和多源信息融合的方式,提出了一种适用于城市环境的降雨洪涝快速预测方法,可为提高城市水害预警水平提供有效支撑,具有较好的应用前景。然而,本方法未充分考虑城市排水对积水深度的影响,后续将进一步扩大模型的适用性,丰富模型输入信息,并在更多地区的配电网进行测试验证。

参考文献:

- [1] IPCC. Climate change 2021: The physical science basis [R].2021.
- [2] BEARD L M, CARDELL J B, DOBSON I, et al. Key technical challenges for the electric power industry and climate change[J]. IEEE Transactions on Energy Conversion,2010,25(2):465-473.
- [3] 王津宇,兰光宇,卢明,等.面向变电站防汛的熵权分配混杂风险评估[J].电力系统及其自动化学报,2023,35(7):74-82.
WANG Jinyu, LAN Guangyu, LU Ming, et al. Hybrid risk assessment of entropy weight allocation for substation flood control[J]. Proceedings of the CSU-EPSCA, 2023, 35(7):74-82.
- [4] 夏军,王惠筠,甘瑶瑶,等.中国暴雨洪涝预报方法的研究进展[J].暴雨灾害,2019,38(5):416-421.
XIA Jun, WANG Huiyun, GAN Yaoyao, et al. Research progress in forecasting methods of rainstorm and flood disaster in China[J]. Torrential Rain and Disasters, 2019, 38(5):416-421.

- [5] 黄华兵,王先伟,柳林.城市暴雨内涝综述:特征、机理、数据与方法[J].地理科学进展,2021,40(6):1048-1059.
HUANG Huabing,WANG Xianwei,LIU Lin.A review on urban pluvial floods:characteristics,mechanisms,data,and research methods[J].Progress in Geography,2021,40(6):1048-1059.
- [6] 胡传博,游兰,林琿.面向过程的城市公共安全风险评估建模方法[J].测绘学报,2018,47(8):1062-1071.
HU Chuanbo,YOU Lan,LIN Hui.A process-oriented risk monitoring and assessment modeling approach in urban public safety[J].Acta Geodaetica et Cartographica Sinica,2018,47(8):1062-1071.
- [7] 陈慧忠,汪博炜,黄锋.基于FloodArea淹没模型的一次暴雨过程洪涝灾害模拟[J].广东气象,2019,41(1):40-42.
CHEN Huizhong,WANG Bowei,HUANG Feng.Simulation of flood disaster in a rainstorm process based on FloodArea flooding model[J].Guangdong Meteorology,2019,41(1):40-42.
- [8] 于汪洋,江春波,刘健,等.水文水力学模型及其在洪水风险分析中的应用[J].水力发电学报,2019,38(8):87-97.
YU Wangyang,JIANG Chunbo,LIU Jian,et al.Hydrologic-hydrodynamic model and its application in flood risk analysis[J].Journal of Hydroelectric Engineering,2019,38(8):87-97.
- [9] 王旭滢,王梦园.基于水动力模型与三维实景模型的城市“智”水思路探究[J].智能城市,2021,7(3):44-45.
WANG Xuying,WANG Mengyuan.Research on urban “smart” water thinking based on hydrodynamic model and three-dimensional real-life model[J].Intelligent City,2021,7(3):44-45.
- [10] 宋利祥,徐宗学.城市暴雨内涝水文水动力耦合模型研究进展[J].北京师范大学学报(自然科学版),2019,55(5):581-587.
SONG Lixiang,XU Zongxue.Coupled hydrologic-hydrodynamic model for urban rainstorm water logging simulation:recent advances[J].Journal of Beijing Normal University (Natural Science),2019,55(5):581-587.
- [11] 胡伟贤,何文华,黄国如,等.城市雨洪模拟技术研究进展[J].水科学进展,2010,21(1):137-144.
HU Weixian,HE Wenhua,HUANG Guoru,et al.Review of urban storm water simulation techniques[J].Advances in Water Science,2010,21(1):137-144.
- [12] NKWUNONWO U C,WHITWORTH M,BAILY B.A review of the current status of flood modelling for urban flood risk management in the developing countries[J].Scientific African,2020,7:e00269.
- [13] 邵月红,林炳章,叶金印,等.基于Elman动态神经网络的降雨-径流模拟研究[J].大气科学学报,2014,37(2):223-228.
SHAO Yuehong,LIN Bingzhang,YE Jinyin,et al.Application of rainfall-runoff simulation based on Elman recurrent dynamic neural network model[J].Transactions of Atmospheric Sciences,2014,37(2):223-228.
- [14] HAMZIC A,AVDAGIC Z,OMANOVIC S.A sequential approach for short-term water level prediction using nonlinear autoregressive neural networks[C]//2016 XI International Symposium on Telecommunications (BIHTEL).Sarajevo,Bosnia and Herzegovina.IEEE,2016:1-7.
- [15] 邓红雷,周晨,夏桥,等.基于多维极值分布的风雨荷载下输电线路风偏放电概率分析[J].电力科学与技术学报,2021,36(2):67-75.
DENG Honglei,ZHOU Chen,XIA Qiao,et al.Probability analysis of windage yaw discharge under wind and rain loads based on the multidimensional extreme value distribution[J].Journal of Electric Power Science and Technology,2021,36(2):67-75.
- [16] 张梦,赵靛芳,全星.PSO-ESN在城市内涝点降雨积水预测中的应用[J].中国农村水利水电,2019(6):56-59+65.
ZHANG Meng,ZHAO Liangfang,QUAN Xing.Application of echo state network in the prediction of water level at urban waterlogging point[J].China Rural Water and Hydropower,2019(6):56-59+65.
- [17] 黄丹萍,白龙.南宁城市内涝分布特征及其监测预警系统应用分析[J].防灾科技学院学报,2019,21(4):84-89.
HUANG Danping,BAI Long.Distribution characteristics of urban waterlogging in Nanning and application of its monitoring and early warning system[J].Journal of Institute of Disaster Prevention,2019,21(4):84-89.
- [18] 薛丰昌,宋肖依,唐步兴,等.视频监控的城市内涝监测预警[J].测绘科学,2018,43(8):50-55+61.
XUE Fengchang,SONG Xiaoyi,TANG Buxing,et al.Urban waterlogging monitoring based on urban video image[J].Science of Surveying and Mapping,2018,43(8):50-55+61.
- [19] BERKHAHN S,FUCHS L,NEUWEILER I.An ensemble neural network model for real-time prediction of urban floods[J].Journal of Hydrology,2019,575:743-754.
- [20] 李海宏,吴吉东,王强,等.基于机器学习方法的上海市暴雨内涝灾情预测模型研究[J].自然灾害学报,2021,30(1):191-200.
LI Haihong,WU Jidong,WANG Qiang,et al.A study on rainstorm waterlogging disaster prediction models in Shanghai based on machine learning[J].Journal of Natural Disasters,2021,30(1):191-200.
- [21] 白岗岗,侯精明,韩浩,等.基于深度学习的道路积水智能监测方法[J].水资源保护,2021,37(5):75-80.
BAI Ganggang,HOU Jingming,HAN Hao,et al.

- Intelligent monitoring method for road inundation based on deep learning[J]. *Water Resources Protection*,2021,37(5):75-80.
- [22] 李超然,肖飞,樊亚翔,等.一种基于LSTM-RNN的脉冲大倍率工况下锂离子电池仿真建模方法[J]. *中国电机工程学报*,2020,40(9):3031-3042.
LI Chaoran, XIAO Fei, FAN Yaxiang, et al. An approach to lithium-ion battery simulation modeling under pulsed high rate condition based on LSTM-RNN[J]. *Proceedings of the CSEE*,2020,40(9):3031-3042.
- [23] 张志行,韩雪冰,冯旭宁,等.面向不同电流工况的锂离子电池改进EECM研究[J]. *电力工程技术*,2023,42(4):2-12.
ZHANG Zhihang, HAN Xuebing, FENG Xuning, et al. Improved EECM for lithium-ion batteries under different current conditions[J]. *Electric Power Engineering Technology*,2023,42(4):2-12.
- [24] 欧阳红兵,黄亢,闫洪举.基于LSTM神经网络的金融时间序列预测[J]. *中国管理科学*,2020,28(4):27-35.
OUYANG Hongbing, HUANG Kang, YAN Hongju. Prediction of financial time series based on LSTM neural network[J]. *Chinese Journal of Management Science*,2020,28(4):27-35.
- [25] 王礼敏,严倩,李寿山,等.基于双通道LSTM模型的用户性别分类方法研究[J]. *计算机科学*,2018,45(2):121-124.
WANG Limin, YAN Qian, LI Shoushan, et al. User gender classification with dual-channel LSTM[J]. *Computer Science*,2018,45(2):121-124.
- [26] 刘婉婉,苏依拉,乌尼尔,等.基于LSTM的蒙汉机器翻译的研究[J]. *计算机工程与科学*,2018,40(10):1890-1896.
LIU Wanwan, SU Yila, WU Nier, et al. Mongolian-Chinese machine translation based on LSTM[J]. *Computer Engineering & Science*,2018,40(10):1890-1896.
- [27] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, USA. IEEE,2015:1-9.
- [28] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. IEEE,2016:770-778.
- [29] BERNET D B, ZISCHG A P, PRASUHN V, et al. Modeling the extent of surface water floods in rural areas: lessons learned from the application of various uncalibrated models[J]. *Environmental Modelling & Software*,2018,109:134-151.
- [30] 鄢仁武,林穿,宋微浪,等.基于EEMD和卷积神经网络的高压断路器故障诊断[J]. *高压电器*,2022,58(4):213-220.
YAN Renwu, LIN Chuan, SONG Weilang, et al. Research on circuit breaker fault diagnosis based on EEMD and convolutional neural network[J]. *High Voltage Apparatus*,2022,58(4):213-220.
- [31] 薛丰昌,朱一晗,顾人颖,等. Floodarea模型的城市内涝可视化数值模拟[J]. *测绘科学*,2020,45(8):181-187+198.
XUE Fengchang, ZHU Yihan, GU Renying, et al. Visual numerical simulation of urban waterlogging based on Floodarea model[J]. *Science of Surveying and Mapping*,2020,45(8):181-187+198.
- [32] 中华人民共和国住房和城乡建设部. 35 kV~110 kV变电站设计规范:GB 50059—2011[S]. 北京:中国计划出版社,2012.
Ministry of Housing and Urban-Rural Development of the People's Republic of China. Code for design of 35 kV~110 kV substation: GB 50059—2011[S]. Beijing: China Planning Press,2012.