

黄力宏,陈易偲,林恒,等.基于Mask RCNN的城市内涝积水深度智能识别研究[J].人民珠江,2026,47(3):32-40.

基于Mask RCNN的城市内涝积水深度智能识别研究

黄力宏¹,陈易偲²,林恒¹,时俊波¹,陈文杰^{1*}

(1.华南农业大学水利与土木工程学院,广东 广州 510642;2.珠江水利委员会珠江水利科学研究院,广东 广州 510611)

摘要:针对传统城市内涝水位监测技术呈现人力成本高,监测区域受限等不足,利用深度学习为基础的目标检测算法Mask RCNN构建积水深度识别模型。模型以积水图片和参照物图像为样本进行训练,训练好的模型可识别积水区域的范围,确定积水覆盖区域的边界;以自行车车轮作为参照物,使用椭圆拟合算法对识别的自行车车轮掩膜进行几何参数提取,根据参数获取淹没比例计算积水水深。结果表明:模型对积水区域和车轮数据集识别定位精确率在90%以上,模型识别积水区域和车轮数据集的掩膜和实际掩膜的IoU(Intersection over Union)在70%以上。模型识别自行车车轮时,正侧面的识别效果优于斜侧面,近处的识别效果优于远处。研究结果可实现城市内涝监测快速响应、监测区域化和智能化,解决传统城市内涝监测的问题。

关键词:城市内涝;深度学习;Mask RCNN;水深识别;椭圆拟合

中图分类号:TV8 **文献标识码:**A **文章编号:**1001-9235(2026)03-0032-09

近年来,受全球气候变化影响,极端天气事件呈现频发态势。在此背景下,叠加城市热岛效应和雨岛效应的协同作用,以及城市规划建设中的系统性缺陷,城市内涝灾害表现出明显的空间扩展性和强度加剧特征。这种现象不仅严重干扰城市系统的正常运转,更对城市可持续发展构成威胁,同时显著提升了市民生命财产安全风险^[1-3]。城市内涝积水深度和积水范围的实时监测和分析,能够量化评估内涝灾害强度,同时为城市规划部门构建排水体系和实施风险预警机制奠定数据基础。传统城市内涝水位监测以人工目测和传感器测量为主^[4]。人工目测监测水位以架设水尺观测读数确定水位,比较灵活和简单方便,但当发生紧急情况时无法及时提供积水情况数据,且具有一定的测量危险;同

时观测受到局部水面风浪、折光效应等影响,具有主观性。传感器测量需要在城市重点积水道路布置传感器,传感器有图像式、压力式等,其测量误差小且及时传输数据,但由于所布置区域过大且位置固定,不够灵活,而且传感器成本高^[5-6]。

针对上述传统方法的不足,以卷积神经网络(Convolutional Neural Network, CNN)为代表的深度学习算法迅速发展,尤其是以CNN为基础的Mask RCNN在目标检测和实例分割领域取得显著成果^[7-8]。廖宇鸿等^[9]利用汽车车轮为参照物,通过拟合椭圆,计算淹没比例获取积水深度。黄国如等^[10]利用汽车车轮作为参照物,依靠高差法和勾股定理计算积水深度。张凌嘉等^[11]利用Mask RCNN和YOLOv5组合模型,识别汽车众多关键部位,对淹没

基金项目:国家自然科学基金(52109018)

收稿日期:2025-07-23 **修回日期:**2025-09-04 **网络首发日期:**2025-10-17

作者简介:黄力宏(2002—),男,主要从事城市水文、洪涝监测方面的研究。

通信作者:陈文杰(1991—),男,博士,副教授,主要从事城市洪涝模拟及防治等工作。

联系作者:致信 rmzj@pearlwater.gov.cn,由期刊转接。

图像中的淹没点位和积水深度进行预测,实现对积水淹没高度的提取。Liang等^[12]开发了V-FloodNet系统,结合图像分割和视频分割技术检测洪水区域,并利用停止标志、人体等参照物,通过模板匹配和淹没比例计算来估算积水深度。以深度学习为代表的目标检测算法在城市内涝的积水深度识别方面有较大发展。

本研究基于Mask RCNN框架构建了一种基于视觉的积水深度识别模型,创新性地利用自行车车轮作为参照物进行水深计算。试验数据采集于真实校园环境,通过构建包含积水场景及参照物的专用数据集,训练得到高性能的预训练模型。成果实现了依托城市现有监控网络的低成本、广覆盖内涝监测,为智慧城市水患治理提供了高效的动态监测解决方案^[13-14]。

1 研究方法

1.1 研究框架

本研究以Mask RCNN模型为框架搭建积水深度识别模型,模型分为2个模块,分别为积水范围和参照物识别模块,以及积水深度计算模块。利用爬虫和团队在校园拍摄获取积水和参照物的图像数据,对所获取的数据进行数据预处理,包括尺寸处理、数据标注、数据增强和数据打包等,得到积水和参照物数据集。将积水和参照物数据集按照7:3的比例分为训练集和验证集。根据参考范围设置模型训练参数,模型对训练数据集进行训练得到预训练模型,对预训练模型进行验证。根据预训练模型对验证数据集的验证情况和检测模型效果参数的优劣对模型的训练模式进行调整,优化模型训练,提升模型效果。

当模型具有识别积水区域和参照物自行车车轮的能力时,在此基础上搭建积水深度计算模型。模型识别参照物车轮并提取识别掩膜,对所得掩膜进行最小外接矩形的提取和利用椭圆拟合算法进行拟合椭圆的参数提取,获得能够反映真实车轮的拟合椭圆,计算掩膜比例获取积水深度。

为了进一步验证所构建模型的准确性,研究利用

现场试验的方式来验证模型计算积水深度的精度。研究团队在实验室模拟城市内涝情况,将自行车放置在积水中,拍摄积水图像同时测量积水深度,得到一一对应的图片和水深。同时也利用训练好的模型对图像进行识别和积水深度计算,根据试验测量值计算误差,检验模型的计算效果。研究步骤见图1。

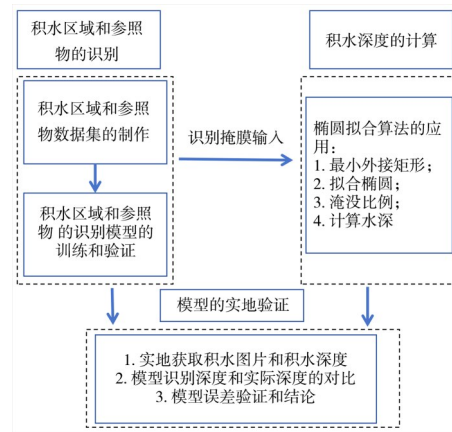


图1 研究框架

Fig. 1 Research framework

1.2 研究方法

1.2.1 Mask RCNN神经网络

Mask RCNN^[15]是由华人学者何凯明等于2017年提出的基于深度学习的目标检测和实例分割的神经网络。该神经网络是Faster RCNN^[16]扩展形成的算法,在其基础上添加一个生成二进制掩码的分支。Mask RCNN可用于目标检测和实例分割,最终输出检测边界框、目标类别和二进制掩膜。Mask RCNN网络采用由ResNet和特征金字塔网络(Feature Pyramid Network, FPN)构建的骨干架构进行多尺度特征提取。通过层级卷积操作生成高维特征图,并由FPN结构实现跨尺度特征融合,将深层语义信息传递至浅层特征图,显著增强模型对不同尺度目标的检测能力,可以应对不同尺度的积水区域的检测。区域提议网络(Regional Proposal Network, RPN)在特征图上生成多尺度候选区域,为每个实例分配唯一标识,可以完成多目标识别,满足研究识别积水区域和车轮的要求。在识别积水区域的任务中,Mask RCNN采用了生成像素级分割图的掩码分支结构,可以有效识别积水区域的边界

信息,同时此模型增添了ROI Align层,任意尺寸的候选区域映射至固定维度的特征图,有效消除ROI

Pooling的量化误差,进一步减少了积水区域边界定位误差。Mask RCNN网络结构见图2。




图2 Mask RCNN模型结构

Fig. 2 Mask RCNN model structure

1.2.2 椭圆拟合算法

在车轮识别任务中,Mask RCNN所构建的识别模型,只能识别露在水面以上的部分车轮,此形状不是完整的椭圆,而是近似半椭圆,此半椭圆无法确定淹没比例的数量关系。为了确定淹没比例的数量关系,本研究采用AAMED算法,此算法可以检测半椭圆上的边缘弧段,利用相邻边缘弧段之间的几何关系,来构建相应的矩阵,解矩阵来拟合完整的椭圆。

Meng等^[17]提出的AAMED椭圆检测法,其主要步骤为:首先,提取边缘弧段,使用自适应Canny算法检测边缘,根据自适应阈值去除过短的弧段;然后,应用多边形逼近算法对边缘进行逼近,由相关数学关系进行分割,以提取出一组弧段;任取2段弧段,通过首尾点是否满足曲率和凸性等条件来判定这2个弧段是否相连,从而确定AAM矩阵元素及其邻接属性。重复所有的弧段取得邻接矩阵AAM。由生成的AAM元素,查找节点中所有弧段组合,再用数学公式判断弧段的椭圆性质,获取所有弧段中的候选组合。椭圆一般方程见式(1):

$$\alpha_1 x^2 + 2\alpha_2 xy + \alpha_3 y^2 + 2\alpha_4 x + 2\alpha_5 y + \alpha_6 = 0 \quad (1)$$

上述问题可转化为求解方程 $S\alpha = \lambda C\alpha$,其中 S 为一个 6×6 实对称矩阵, C 为一个 6×6 约束矩阵。由两次特征分解来求解 α ,得到候选椭圆。对拟合出的椭圆,需要验证其真实性。算法会对每个采样点使用形状指标、位置指标、梯度指标和加权指标

等4个指标计算验证得分,当验证得分超过设定阈值时,认定该椭圆为真椭圆,否则视为虚假椭圆。通过椭圆聚类来剔除重复椭圆,得到所需的试验结果。

1.3 模型构建

1.3.1 积水识别模型的构建

在不同路段发生内涝时,由于各个路段的地表覆盖类型不同,积水区域的识别受到的漂浮物遮挡和过往行人车辆等的干扰也不同,为了增大模型的泛化能力,收集了发生在各种路段的积水数据。本研究利用各大网站平台如微博、百度、新浪等收集城市发生内涝的积水情况图,获得820张图像,同时在校内积水路段拍摄积水图像,获得330张图像,总积水图像为1150张。接着,对这1150张原始图像进行图像预处理,把所有原始图像统一缩放至 512×512 像素,使用labelme标记工具对预处理的图像进行积水区域多边形顶点标记,形成初始数据集,为了避免因为数据过少导致过拟合风险,对初始数据集进行7种变换(图3),进行数据增强,使用翻转、颜色变换、添加噪声、旋转 45° 、旋转 90° 、调整亮度和图像缩放把初始数据集放大至原来的8倍,获得总的训练图像9200张,根据深度学习的要求,把数据集按7:3的比例分为训练集和验证集。训练集数据量为6640张,验证集数据量为2760张。

特征图上每个像素生成设定尺寸和长宽比的锚点框,锚点框受限于预设的尺寸和长宽比。锚点的尺寸和长宽比影响目标检测和实例分割的精度。

本研究的研究对象是积水区域,积蓄在道路上的水形成的水面由道路的形状和大小决定,不具备规则的几何形状,形状复杂且尺寸大小不一。通过K-means 聚类分析发现,原始Mask RCNN 预设的锚点宽高比[0.5, 1, 2]与积水区域真实空间分布存在显著偏差,导致候选框与目标几何特征匹配度不足。本试验利用K-means 聚类算法设定7个聚类中心来获取新的锚点长宽比,为[0.40, 0.60, 0.75, 0.82, 1.10, 1.90, 2.50]。锚点的初始尺寸能够覆盖目标,因此锚点的尺寸沿用初始设定的尺寸。




图 3 积水图像数据增强

Fig. 3 Water accumulation image data augmentation

本研究使用TensorFlow 框架来构建积水识别的Mask RCNN 模型,参数设计为基础学习率为0.001,批次大小为1,训练周期为50,迭代次数为10 000,学习衰减周期为30、40,学习衰减系数为0.1。

1.3.2 车轮识别模型的构建

构建积水计算模型需要一个目标参照物,以此参照物来计算积水深度。参照物的形态特征与空间分布特征直接影响积水深度计算精度,本研究拟定参照物遴选的3个原则:①参照物具有明确的边缘特征和尺寸信息,以便识别和计算;②参照物应该是日常常见的物体,尤其是在发生城市内涝的路段;③参照物具有规则的几何形状。基于上述标准,选择自行车车轮为城市内涝积水深度计算的参照物。城市内大量布置共享单车,具有场景泛化性,且车轮为规则的圆形,由其半径便获得几何特

征参数。

团队从各大网站收集自行车图像,以及自行拍摄自行车图像,一共收集450张图像,对其进行统一预处理尺寸为512×512像素,使用labelme 标记工具进行类别标注及自行车车轮多边形顶点标注。为了避免数据过少发生过拟合,对初始图像进行3种变换。对预处理的450张图像进行数据增强,通过旋转45°、对比度调整和添加噪点的方法获得1 800张图像,由于自行车车轮在监控摄像头下形成的图像中所占像素比例较小,为了适应监控摄像头下识别环境,再把所得所有图像缩小一倍,总共获得3 600张图像(图4)。

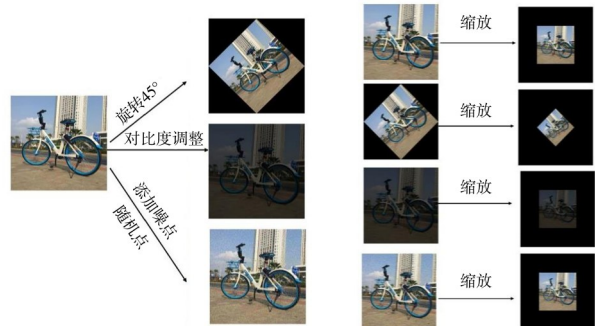


图 4 车轮数据增强

Fig. 4 Wheel image data augmentation

本研究使用TensorFlow 框架来构建车轮识别的Mask RCNN 模型,设置基础学习率0.002,批次大小1,训练周期数80,迭代次数12 000,学习衰减周期50、70,学习衰减系数0.1。

1.3.3 积水水深计算模型

利用OpenCV4.5库中的cv2.minAreaRect() 函数对二进制车轮掩膜进行最小外接矩形检测,得到最小外接矩形的像素高度和宽度。对二进制车轮掩膜进行椭圆拟合,得到拟合圆心的坐标。假定水面为等高水平面,车轮掩膜检测的最小外接矩形下边缘与其贴合,检测的最小外接矩形的高度为车轮露在水面以上的像素高度 h_p ,拟合椭圆圆心到最小外接矩形上边缘的高度为车轮的像素半径 h_o ,车轮的像素直径 $h_v=2h_o$,车轮实际直径为 H_v ,得道路积水水深计算公式:

$$H_w = (1 - \frac{h_p}{2h_o})H_b \quad (2)$$

式中： H_w 为实际淹没深度，亦即道路的实际积水深度； H_b 为车轮的实际轮胎直径； h_p 为车轮露出水面部分的像素高度； h_o 为拟合椭圆圆心到最小外接矩形上边缘的像素高度(图5)。椭圆拟合过程见图6。




图5 车轮几何参数对应分析

Fig. 5 Wheel's geometric parameter correspondence analysis



图6 拟合椭圆步骤

Fig. 6 Steps for elliptical fitting

2 结果与讨论

2.1 积水区域与车轮识别结果

为了评估积水区域的识别效果,本研究利用已训练完成的模型对未经过训练和验证的图像做测试。模型对输入的2张图像进行端到端的处理,输出积水区域的掩膜。同时采用二值化处理技术将掩膜图转化为黑白掩膜图(0-1矩阵)来提升掩膜可视化对比,其中白色区域表征模型评定的积水区域,黑色区域表征非积水区域(图7)。试验结果表明,二进制掩膜和真实积水区域在空间分布上呈现高度重叠,平均定位精确率达到了96.4%,这表明模型在定性识别上具有一定的效果。研究定量计算这张图像识别的二进制掩膜与真实的积水区域的重叠程度,对其二次处理,对识别掩膜像素进行提取和标注的积水区域的像素进行提取,计算交并比,得到交并比分别为91.31%和90.5%。这进一步表明模型能够对积水区域进行识别。

研究利用验证集对模型的泛化能力进行系统性验证。本文将积水区域划分为3类具有不同积水

特征的典型场景:城市主干道、支路积水、桥涵积水。验证集从网络和校园中遴选获取,包含以上3种典型场景。预训练模型对验证集进行验证,试验结果表明:在积水区域定位任务中,模型在复杂的城市环境下表现出优异的空间感知能力,积水验证集的平均定位精确率为94.3%,模型预测积水区域生成的掩膜和实际积水区域平均交并比达到78.0%。该可视化例子和定量分析共同证实,本文提出的模型训练能够在复杂的水文场景下进行有效识别。




图7 积水区域识别步骤

Fig. 7 Steps for water accumulation zone detection

为验证模型对参照物车轮的识别效果,图8展示了车轮识别的效果。在车轮的验证集中,对车轮图像进行对比度调整、添加噪点干扰等处理,使其符合自行车雨天行驶环境。在验证集上的评估结果表明:模型在自行车验证集上的平均定位精度达到95.2%,其生成的车轮掩膜与实际车轮掩膜的平均交并比为71.0%,说明模型在复杂的雨天环境下具有一定的识别能力。



图8 车轮识别效果对比

Fig. 8 Wheel recognition performance comparison

2.2 水深识别结果

本研究基于自行车车轮的积水深度识别方法在实际应用中受到多重环境干扰因素的影响,主要表现为以下3个方面:①环境风力扰动及周边车辆行驶引起的水面波动会导致积水表面不稳定,直接影响水深识别;②当自行车在高于积水区域的人行道上行驶时,道路高程差异会影响实际水深计算;③自行车在积水区行驶时车轮发生较大倾斜,影响水深计算。为系统验证车轮识别法的理论可行性,本研究控制试验环境,主动排除了上述干扰因素。

本研究选取网络中获取的3张积水场景照片对积水水深计算模型进行验证(图9)。将3张图片输入模型后,模型分别输出置信度为0.997、1.000和0.997的识别结果。提取图中自行车车轮的掩膜后,模型对其进行了最小外接矩形提取与椭圆拟合。输入估计的车轮半径(26 cm),模型分别计算得到3张图片对应的积水深度为5.5、10.2、30.1 cm。由于图像来源于网络,无法获得图中自行车的真实轮径及实际积水深度,但从图像观察的积水情况来看,模型计算结果具有一定的合理性。该试验验证了从图像掩膜分割到几何建模以估算积水水深的处理流程的可行性与有效性。



图9 积水水深计算模型的验证

Fig. 9 Validation of water accumulation depth calculation model

2.3 现场试验验证

人眼目测图片得到的积水深度具有很大的主观性,模型计算积水深度虽然有一定的合理性但不能准确确定识别效果,无法合理评估模型的识别效果和应用性。为了使研究合理且科学,本研究选取广东省水利水电科学研究院飞来峡水利试验基地开展模型验证试验,重点评估城市内涝场景下道路积水深度计算的适用性。试验通过特定水槽模

拟城市道路积水环境,设置15.0、21.0、26.0、27.5 cm 4种水深。采用半径26 cm的自行车作为标准测量载体,基于城市内涝监控场景的真实需求,特别设计以下试验条件:①在低照度环境中模拟雨天较昏暗的环境;②设置5~8 m拍摄距离复现道路监控的视距;③多角度拍摄确保数据空间分布的普适性。最终获取4种水深共计116张试验样本见表1。

表1 模型识别积水水深和实际水深误差

Tab. 1 Error between water accumulation depth identified by model and actual water depth

样本组	总样本数	平均误差/cm	均方根误差/cm	样本数		
				误差小于2 cm	误差小于3 cm	误差小于5 cm
第一组	29	3.4	3.42	4	8	17
第二组	30	3.9	3.93	8	13	9
第三组	27	4.1	4.09	6	12	9
第四组	30	4.2	4.23	5	12	13

研究数据表明,模型在4组不同水深条件下的平均绝对误差均控制在5 cm以内,误差主要集中在4 cm。这验证了其在城市内涝积水场景下的适用性。结果表明:模型在第一组(水深15 cm)水深计算中的平均绝对误差最小,平均误差为3.4 cm,均方根误差为3.42 cm;而在第四组(水深27.5 cm)平均误差最大,平均误差为4.2 cm,均方根误差为4.23 cm。

通过对比不同水深条件下的模型计算结果发现,积水深度越大,预测水深误差越大。水深加剧时,由于水面的折射导致水面呈现的车轮虚像将影响对车轮的识别和拟合椭圆,这进一步增大了误差。模型对正侧面的轮胎图像具有更优的识别效果。当轮胎处于正侧面时,轮胎的几何形状表现得更加完整,模型可以更加有效地进行识别和拟合椭圆。近处的识别效果优于远处,当处在远处时,由于近大远小,导致车轮在图像中所占像素面积较小,增加了模型的识别难度,导致识别时和拟合椭圆时出现较大偏差。

3 结论

本研究基于 Mask R-CNN 深度学习算法构建了积水区域与参照物(自行车车轮)的识别模型,并在此基础上开发了积水水深计算模型。模型能够对输入图像中的积水区域和车轮进行识别,并输出相应的积水深度估算结果。研究为城市内涝背景下的积水深度识别提供了一种可行的技术路径,为防灾减灾工作提供了理论与技术支持。

a)模型在积水验证集上的平均定位精度为 94.3%,生成的积水区域掩膜与实际区域的平均交并比为 78.0%;在车轮验证集上的平均定位精度为 95.2%,车轮掩膜与真实掩膜的平均交并比为 71.0%。模型对车轮的识别效果表现出一定差异:正侧面识别优于斜侧面,近距离优于远距离。

b)模型在 116 张图像上完成了积水水深计算,预测值与实测值的平均绝对误差为 3.90 cm。随着水深增加,水面反射增强,导致模型误差逐渐增大。车轮识别质量直接影响水深估算精度,其中正侧面和近距离车轮识别所带来的计算误差小于斜侧面和远距离识别结果。

本研究仍存在不足之处。目前仅选取一种型号的自行车作为参照物,而实际车轮尺寸存在较大差异,后续需扩展车轮尺寸范围以提高模型适应性。此外,由于训练数据有限,模型在识别与计算精度方面仍有提升空间。

参考文献:

- [1] 宋晓猛,徐楠涛,张建云,等. 中国城市洪涝问题:现状、成因与挑战[J]. 水科学进展, 2024, 35(3): 357-373.
SONG X M, XU N T, ZHANG J Y, et al. Urban flooding in China: current status, causes and challenges [J]. Advances in Water Science, 2024, 35(3): 357-373.
- [2] 武晶. 闽江流域特大洪涝干旱风险识别[J]. 人民珠江, 2024, 45(4): 115-123.
WU J. Risk identification of severe flood and drought in Minjiang River Basin [J]. Pearl River, 2024, 45(4): 115-123. (in Chinese)
- [3] 程建中,黄永俊,许冰清. 基于地-管-河耦合模型的南宁市城区洪涝灾害模拟及淹没影响研究[J]. 人民珠江, 2024, 45(11):

24-33.

CHENG J Z, HUANG Y J, XU B Q. Urban flood disaster simulation and inundation impact on Nanning based on land-pipe-river coupling model [J]. Pearl River, 2024, 45(11): 24-33. (in Chinese)

- [4] 薛丰昌,杨黎霞,陈笑娟,等. 利用社会公众拍摄图像构建城市内涝深度等级评估模型[J]. 武汉大学学报(信息科学版), 2026, 51(1): 46-54.
XUE F C, YANG J X, CHEN X J, et al. Constructing an urban waterlogging depth level assessment model using images captured by the public [J]. Geomatics and Information Science of Wuhan University, 2026, 51(1): 46-54. (in Chinese)
- [5] 徐青林,王海鹏,张斐. 道路积水监测设备的研究[J]. 山西科技, 2016, 31(6): 74-77.
XU Q L, WANG H P, ZHANG F. Research on monitoring equipment of road water [J]. Shanxi Science and Technology, 2016, 31(6): 74-77. (in Chinese)
- [6] 庄红波,高瑞泉,饶华炎. 城市内涝监测技术的应用研究[J]. 气象科技, 2013, 41(2): 378-383.
ZHUANG H B, GAO R Q, RAO H Y. Application of urban waterlogging monitoring technology [J]. Meteorological Science and Technology, 2013, 41(2): 378-383. (in Chinese)
- [7] 鄢琳. 耦合计算机视觉及高精度雨洪数值模拟的城市内涝实时减灾研究[D]. 广州:广州大学, 2024.
YAN L. Real-time disaster reduction of urban flood using computer vision coupled with high-precision rain-flood numerical simulation [D]. Guangzhou: Guangzhou University, 2024. (in Chinese)
- [8] 吕鑫. 基于深度学习的城市内涝监测预报方法研究[D]. 南京:南京信息工程大学, 2024.
LYU X. Research on urban waterlogging monitoring and forecasting methods based on deep learning [D]. Nanjing: Nanjing University of Information Science & Technology, 2024. (in Chinese)
- [9] 廖宇鸿,黄国如. 基于深度学习和椭圆检测的城市道路积水深度监测方法研究[J]. 人民珠江, 2023, 44(6): 1-8, 17.
LIAO Y H, HUANG G R. Research on monitoring method of urban road waterlogging depth based on deep learning and ellipse detection [J]. Pearl River, 2023, 44(6): 1-8, 17. (in Chinese)
- [10] 黄国如. 城市暴雨内涝防控与海绵城市建设辨析[J]. 中国防汛抗旱, 2018, 28(2): 8-14.
HUANG G R. Discrimination of relationship between urban storm waterlogging prevention and sponge city construction [J]. China Flood & Drought Management, 2018, 28(2): 8-14. (in Chinese)

- [11] 张凌嘉,周欣磊,许月萍,等. 基于YOLOv5和Mask-RCNN组合模型的社交媒体内涝灾害分析[J]. 浙江大学学报(工学版),2024,58(9):1822-1831.
ZHANG L J, ZHOU X L, XU Y P, et al. Analysis of inundation from social media based on integrated YOLOv5 and Mask-RCNN model [J]. Journal of Zhejiang University (Engineering Science), 2024, 58(9): 1822-1831. (in Chinese)
- [12] LIANG Y Q, LI X, TSAI B, et al. V-FloodNet: A video segmentation system for urban flood detection and quantification [J]. Environmental Modelling & Software, 2023, 160. DOI:10.1016/j.envsoft.2022.105586.
- [13] 王哲. 智慧城市视角下城市内涝监测预警系统的构建研究[D]. 北京:北京建筑大学,2024.
WANG Z. Study on the construction of urban Waterlogging monitoring and early warning system from the perspective of smart city [D]. Beijing: Beijing University of Civil Engineering and Architecture, 2024. (in Chinese)
- [14] 宋丽丽,吴巍,王高旭,等. 基于CKAN的水利数据共享平台研究[J]. 人民珠江,2024,45(4):18-25,86.
SONG L L, WU W, WANG G X, et al. Sharing platform of water conservancy data based on CKAN [J]. Pearl River, 2024, 45(4): 18-25, 86. (in Chinese)
- [15] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]// 2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017: 2961-2969.
- [16] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [C]// Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal, Canada: NeurIPS, 2015: 91-99.
- [17] MENG C, LI Z X, BAI X Z, et al. Arc adjacency matrix-based fast ellipse detection [J]. IEEE Transactions on Image Processing, 2020, 29: 4406-4420.

Intelligent Recognition of Urban Flood Depth Based on Mask RCNN

HUANG Lihong¹, CHEN Yisi², LIN Heng¹, SHI Junbo¹, CHEN Wenjie^{1*}

(1. College of Water Conservancy and Civil Engineering, South China Agricultural University, Guangzhou 510642, China; 2. Pearl River Water Resources Research Institute, Pearl River Water Resources Commission, Guangzhou 510611, China)

Abstract: Urban waterlogging has become a frequent challenge in many cities, posing significant threats to public safety and urban infrastructure. Traditional methods for monitoring water levels, which often rely on physical sensors or manual inspection, are increasingly recognized as inefficient due to their high operational costs, limited spatial coverage, and inability to provide real-time responses. To overcome these shortcomings, this study introduced an intelligent and automated approach for waterlogging depth estimation using a deep learning-based computer vision framework. The proposed model utilized the Mask RCNN architecture to detect and segment both flooded areas and reference objects in images. A key innovation lies in the use of bicycle wheels as a reference scale object, enabling quantitative water depth estimation through geometric analysis. This approach enhances adaptability in complex urban environments and significantly reduces dependency on expensive specialized equipment. The model was trained on a custom dataset consisting of images of water accumulation scenes under various environmental conditions, along with corresponding reference objects. After training, the system could accurately identify the boundaries of inundated regions and precisely locate bicycle wheels even in complex and occluded scenes. An ellipse-fitting algorithm was then applied to the masked regions of detected wheels to derive geometric parameters such as semi-major and semi-minor axes. These parameters were used to calculate the submergence ratio of the wheel, which correlated directly with the water depth based on pre-established hydraulic relationships. Furthermore, the integration of multi-scale feature extraction within the network improved detection performance across different distances and perspectives. Extensive experiments demonstrate that the model achieves high performance in both detection and segmentation tasks. It attains a precision exceeding 90% for localizing waterlogged areas and bicycle wheels, while the intersection over union (IoU) between predicted masks and ground-truth masks surpasses 70%. The results also indicate that detection accuracy is higher for bicycle wheels viewed from a frontal or lateral perspective compared to angled views, and performance is better for nearer objects compared to those farther from the camera. This research contributes to the field by offering a scalable, cost-effective, and intelligent

solution for urban waterlogging monitoring. The proposed model supports large-area coverage and continuous monitoring capabilities, facilitating rapid emergency response and better urban water management. The approach is not only applicable in real-time urban disaster mitigation but also adaptable for integration with smart city platforms, thereby enhancing urban resilience to climate-induced hazards. Future work will focus on optimizing computational efficiency for embedded deployment and incorporating temporal dynamics for flood progression forecasting.

Keywords: urban waterlogging; deep learning; Mask RCNN; water depth monitoring; elliptical fitting

(责任编辑:程 茜)