引文格式:薛丰昌,杨鋆霞,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.DOI:10.13203/j.whugis20240290

Citation:XUE Fengchang,YANG Yunxia,CHEN Xiaojuan,et al.Constructing an Urban Waterlogging Depth Grade Assessment Model Using Images Captured by the Public[J].Geomatics and Information Science of Wuhan University,2026,51(1):46-54.DOI:10.13203/j.whugis20240290

利用社会公众拍摄图像构建城市内涝深度等级评估模型

薛丰昌[1,2] 杨鋆霞[1] 陈笑娟[3] 吕 鑫[2] 成沿年[1]

1 南京信息工程大学气象灾害地理信息工程实验室,江苏 南京,210044

2 中国气象局流域强降水重点开放实验室,湖北 武汉,430205

3 河北省气象灾害防御和环境气象中心,河北 石家庄,050021

摘 要:衡量城市内涝严重程度的标准除了积水范围外,积水深度是更为重要的一个指标。面向城市内涝积水状态的传统监测方法存在成本高昂、监测范围有限以及仅能针对特定易涝区域进行监测的局限性,提出了一种利用社会公众拍摄的图像信息构建的城市内涝深度等级评估模型。利用爬虫技术,以“城市内涝”和“车辆受淹”等词语作为关键词,从互联网上收集社会公众拍摄的包含涉水小型车辆的图像和视频来构建样本集,采用车辆淹没深度作为参照标准,将内涝深度划分为安全([0,20]cm)、不安全((20,60]cm)和危险(>60 cm)3个等级,并为这些等级创建了相应的标签。应用YOLOv8模型构建了YOLOv8l、YOLOv8m、YOLOv8n和YOLOv8s 4组不同网络复杂度的模型,训练过程中,利用混淆矩阵的精确度和召回率、平均精度、平均精度均值4种精度指标对模型的准确性进行了综合评估。实验结果证实,YOLOv8算法能够有效识别不同场景下车辆的淹没状态,能够作为一种有效的工具监测和评估城市内涝的积水深度等级,不仅提高了内涝灾害评估的时效性和准确性,还拓展了社会信息在灾害管理中的应用,为未来的城市灾害管理提供了一种人工智能与社会公众信息相结合的解决方案。

关键词:城市内涝;公众图像;人工智能;评估模型

中图分类号:P208;P237 **文献标识码**:A **收稿日期**:2024-10-27

DOI:10.13203/j.whugis20240290 **文章编号**:1671-8860(2026)01-0046-09

Constructing an Urban Waterlogging Depth Grade Assessment Model Using Images Captured by the Public

XUE Fengchang[1,2] *YANG Yunxia*[1] *CHEN Xiaojuan*[3] *LÜ Xin*[2] *CHENG Yannian*[1]

1 Laboratory of Geographic Information Engineering for Meteorological Disasters, Nanjing University of Information Science and Technology, Nanjing 210044, China

2 Key Open Laboratory of Heavy Precipitation over Basin of China Meteorological Administration, Wuhan 430205, China

3 Hebei Province Meteorological Disaster Prevention and Environmental Meteorology Center, Shijiazhuang 050021, China

Abstract: **Objectives**: In addition to the extent of water accumulation, the depth of water accumulation is a more important criterion for measuring the severity of urban waterlogging. In response to the limitations of traditional urban waterlogging monitoring methods, such as high costs, limited monitoring range, and the ability to only monitor specific flood-prone areas, a model for assessing the depth grade of urban waterlogging using images captured by the public has been proposed. **Methods**: We use web crawling techniques with keywords like urban waterlogging and vehicles submerged to collect images and videos from the internet that include small vehicles in water, creating a sample set. Using the depth of vehicle submersion as a reference

基金项目:中国气象局流域强降水重点开放实验室基金(2023BHR-Y29);河北省省级科技计划(22375421D);河北省资源环境灾变机理及风险监控重点实验室开放基金(FZ248101)。

第一作者:薛丰昌,博士,教授,主要从事气象GIS、气象灾害监测预警与风险管理、城市内涝数值模拟、灾害遥感等研究。001968@nuist.edu.cn

通信作者:陈笑娟,硕士,高级工程师。juan2044335@163.com

standard, we divide the waterlogging depth into three levels: Safe ([0,20] cm), unsafe ((20,60] cm), and dangerous (>60 cm), and create corresponding labels for these levels. We apply the YOLOv8 model to construct four models of different network complexities that are YOLOv8l, YOLOv8m, YOLOv8n, and YOLOv8s. During training, we use a confusion matrix and four accuracy metrics that are precision, recall, average precision (AP), and mean AP (mAP) to comprehensively evaluate the model's accuracy. **Results:** (1) For the training set, all four YOLOv8 models converge after about 40 training epochs, with precision and mAP50 values stabilizing around 60%~70%, recall values around 50%~60%, and mAP50: 95 values around 35%. (2) In the test set, for the precision metric, YOLOv8m scores the highest for the safe class at 80.7%, YOLOv8l for the unsafe class at 55.4%, and YOLOv8s for the dangerous class at 84.8%. For the recall metric, YOLOv8m scores the highest for both the safe and unsafe classes at 66.3% and 68.8%, respectively, while YOLOv8n scores the highest for the dangerous class at 68.3%. For the mAP50 metric, YOLOv8s scores the highest for all classes, with 74.4% for safe, 61.7% for unsafe, and 76.2% for dangerous. For the mAP50: 95 metric, YOLOv8m scores the highest for the safe class at 43.1%, while YOLOv8s scores the highest for both the unsafe and dangerous classes at 37.7% and 36.7%, respectively. **Conclusions:** (1) The depth and width of the network, as well as feature extraction capability, have a significant impact on model performance. Although increasing network width and depth substantially increases the number of model parameters and computational load, not all evaluation metrics improve with the increase in network width and depth. Although the YOLOv8l model is the most complex, its precision and mAP50 scores are not superior, ranking fourth (69.3%) and third (68.0%), respectively. Although the YOLOv8n model has the fewest parameters and computational load, its mAP50 score still achieves second place. Overall, YOLOv8m performs the best on the validation set, achieving the highest scores in precision, mAP50, and mAP50: 95, with precision and mAP50 being 2.2% and 2.6% higher than the second-ranked model, respectively, without significant sacrifice in recall, making it the optimal model in terms of comprehensive performance. (2) In the validation set, the detection accuracy of the four models for the unsafe class is lower than that for the other two classes. On one hand, this is due to the imbalance in sample sizes. On the other hand, it is also due to certain limitations in the model's detection performance. To address this issue, future research will focus on employing targeted data augmentation techniques for sample processing to improve the model's recognition capability for unsafe class samples, and introducing attention mechanism modules into the model's network structure to enhance its ability to learn key features.

Key words: urban waterlogging; public images; artificial intelligence; assessment model

衡量城市内涝严重程度的标准除了积水范围外,积水深度是更为重要的一个指标。物联网技术与地理信息系统(geographic information science, GIS)建模相结合在城市内涝积水监测中取得了显著进展,GIS技术结合电子水尺、雨量计等工具实现了对城市积水水位的实时监测和数据自动采集[1-7]。但这些技术在应用中仍存在局限性:(1)城市内涝的复杂性要求积水传感监测设施必须具有足够的代表性、准确性和覆盖度,而高精度积水传感监测设备购置成本、安置和维修成本都很高,很难实现在城市中大规模布设。(2)独立积水传感监测设备只能针对易涝点进行监测,难以覆盖大范围地段。小型汽车作为城市主要的交通工具,在城市内涝监测中也发挥着重要作用。社会公众拍摄的图像信息包含城市众多内涝信息,小型车辆在城市洪涝发生时有很高的出现几率,适合作为判断城市洪涝严重等级的动态参照物。

YOLOv8是2023年被提出的一个全新的最优模型,是目标检测领域中YOLO系列的最新模型。YOLOv8抛弃了传统的基于锚点的检测方式,直接预测物体的中心点和尺寸,简化了检测流程,并减少了超参数的调整,提高了检测的准确性和效率。YOLOv8引入了新的网络主干和颈部架构,能够更有效地提取图像特征,从而提高目标检测的性能。YOLOv8还引入了新的损失函数,有助于在训练过程中更有效地优化模型参数,进一步提升检测精度[8]。与快速基于区域的卷积神经网络模型相比,YOLOv8在准确性和速度方面表现更优;与EfficientDet模型相比,在相同数据场景的评估中,交并比为50%时,Effi-

cientDet的平均精度均值(mean average precision, mAP)为47%,低于YOLOv8的62%[9-10]。

本文基于YOLOv8提出了一个成本低、具有广泛适用性的城市内涝积水深度监测方法,具体思路是利用YOLOv8目标检测模型对图像中涉水车辆的状态进行识别,不同涉水状态对应不同的积水深度等级,从而借助车辆这一参照物来表达积水深度。该方法可以广泛应用社会公众拍摄的视频和图像为城市内涝深度的监测提供有益方法。

1 数据集与实验环境

本文的主要目的是对图像中的城市内涝环境下的小型涉水车辆的淹没状态进行目标检测,使用Python爬虫技术以"城市内涝""车辆淹没"为关键词在网络上爬取图片,爬取了2 314张社会公众拍摄的图片,经过人工目视解译,筛选出了1 141张图片进行标注。依据积水深度对城市内涝风险等级进行划分[11]。随着涉水深度的变化,汽车的驾驶安全等级也在变化。相关资料显示,普通小轿车和运动型多用途汽车的轮胎半径大小为33~38 cm,引擎进气口高度为50~65 cm。以此为参考,本文将积水深度分为安全([0,20] cm)、不安全((20,60] cm)和危险(>60 cm)3个等级,数据集的分类标准如图1所示,3类样本数据如图2所示。

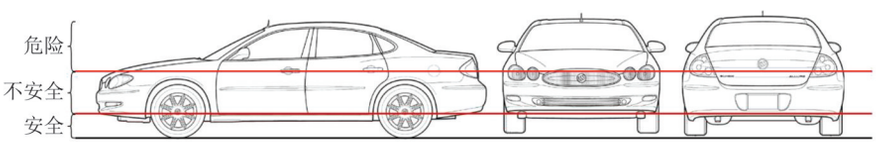


图1 积水深度等级划分标准

Fig. 1 Classification Standard for Ponding Depth Levels



(a) 安全类样本



(b) 不安全类样本



(c) 危险类样本

图2 样本实例

Fig. 2 Sample Instances

根据上文确定的数据集划分标准,利用Labellmg工具手动标注边界框,标注完成后会生成一个XML格式文件,里面包含了图片中所标注的边界框4个顶点的坐标位置,边界框的中心坐标、宽度和高度,以及该边界框选择物体的类别。

将1 141张图片按照9:1的比例划分训练集和测试集,再将训练集按照9:1的比例划分成训练集子集和验证集,最终得到训练子集图像923张、验证集图像103张和测试集图像115张。其中,安全类别总共1 659个边界框,不安全类别总共1 128个边界框,危险类别总共1 884个边界框。

实验采用Windows 10操作系统、PyTorch 1.10深度学习框架,在GPU NVIDIA RTX4080(16 GB)完成网络的训练,批次大小设置为16,学习率设置为0.001,使用随机梯度下降优化器,迭代次数设为100次。

2 研究方法

2.1 YOLOv8网络模型

YOLOv8主要由4个部分组成,分别是输入端、主干特征提取网络、加强特征提取网络和检测头。

2.1.1 输入端结构

YOLOv8网络模型输入端包括图片自适应缩放、马赛克数据增强、自适应锚框计算和混合数据增强[12]。其中,马赛克数据增强的方法流程如图3所示,包括马赛克增强、随机缩放和色彩空间的调整。本文中,一张图片中不同区域的积水深度会不一样,而远处小目标车辆的受淹状态往往难以识别,马赛克数据增强方法先从一个批次中取出4张图片进行随机缩放、裁剪、打乱分布,然后重新拼接,可以有效解决小目标车辆受淹状态难以识别的问题。自适应锚框计算会为识别目标设定最适合其尺寸大小的锚框,混合数据增强会随机选取两个样本及其对应的标签进行特征线性插值,作为模型引入的先验知识,以提升模型的泛化性。

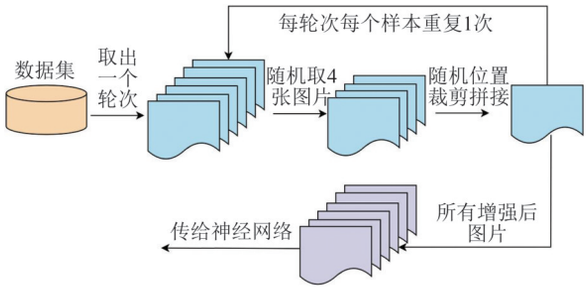


图 3　马赛克数据增强方法

Fig. 3　Mosaic Data Augmentation Method

2.1.2　主干网络与加强特征提取网络

YOLOv8 主干网络与加强特征提取网络主要由跨阶段局部网络(cross stage partial network, CSPNet)、注意力模块和空间金字塔池化结构组成。CSPNet 借鉴了 YOLOv7 的多堆叠结构[13],并将 YOLOv5 的 C3 网络替换成了 C2f 网络,其中卷积-批归一化-激活模块是卷积层,而瓶颈层部分使用了 1×1 的卷积,针对不同尺度的模型调整了通道数,能使模型保持轻量化的同时获得更加丰富的梯度流信息,从而使网络学习到更多的特征。加强特征提取网络模块采用了路径聚合网络和特征金字塔网络,对主干网络提取的特征进行上采样和下采样跨层连接,使特征充分融合[8],增强多个尺度上的语义表达和定位能力。检测头结构采用了解耦检测头[14],将检测与分类分离,解决了分类和定位关注侧重点不同的问题。同时采取了无锚框目标检测方法,提升了检测速度。

2.1.3　任务对齐学习

在深度学习目标检测任务中,正负样本不平衡是一个常见问题[15],本文的任务是识别图像中是否存在被积水淹没的车辆,并且定位其位置。在这个过程中,正样本是包含受淹车辆的图像区域,而负样本是不包含受淹车辆的图像区域,两个样本的不平衡体现在几个方面:(1)样本分布不均衡。存在受淹车辆的区域往往远小于没有受淹车辆的区域,导致样本分布不均匀。(2)训练不稳定。模型可能更偏向于学习负样本,因为在数量上负样本占主导地位,而对于正样本的学习相对困难。(3)影响性能评估。当模型测试表现良好但未能准确识别少数类别目标时,可能会掩盖模型对于整体性能的真实表现。

针对上述问题,YOLOv8 采取了任务对齐学习[16]的动态分配策略,根据训练的进展和样本的特点动态调整权重。任务对齐学习根据分类和回归的分数加权选择正样本,样本的分配能力可以随着训练不断地增强,让模型更加专注正样本的学习,核心计算公式为:

$$t=s^{\alpha}\times u^{\beta} \tag{1}$$

式中,t 为任务对齐指标;s 为分类得分;u 为交并比的值;α 和 β 为权重超参数。利用式(1)可以衡量预测框和真实框的对齐程度。

2.2　评价指标

2.2.1　精度评价指标

本文采用精确度、召回率、平均精度(average precision, AP),mAP 进行精度评价,AP 的值为精确度和召回率曲线所围成区域的面积;mAP50 表示交并比取值为 50% 时的总类别 AP,mAP50:95 表示不同交并比取值(从 50% 到 95%,步长 5%)的 AP。

2.2.2　损失函数

YOLOv8 的损失函数由分类损失和回归损失构成,分类损失使用的是二元交叉熵损失,回归损失中的完全交并比损失和计算交并比的思想类似,是描述预测框和真实框之间重合度的一种方式,通过比值来衡量框的回归程度。而当模型引入了无锚框目标检测方法的中心点预测后,输出锚框大小偏移量变成了预测框左、上、右、下边框与中心点的距离,因此 YOLOv8 引入了分布焦点损失[17-18],它以交叉熵的形式优化与标签最接近的左右两个位置的概率,从而让网络更快地聚焦到目标位置及邻近区域。

3　城市内涝深度等级评估实验与分析

对 YOLOv8 的 YOLOv8l、YOLOv8m、YOLOv8n 和 YOLOv8s 4 种不同大小的网络算法训练过程中的变化指标和对测试集进行预测的结果指标进行分析,以评估模型在车辆受淹状态识别时的应用表现。各模型训练参数变化如图 4 所示,随着训练轮次的增加,各模型算法在最终训练轮次达到 40 次左右时都能趋于收敛,并且随着迭代次数的增加,4 项指标都呈现出振荡上升的状态,到训练结束时 4 个模型的精确度和 mAP 值都维持在 60%~70%,召回率都维持在 50%~60%,mAP50:95 值都维持在 35% 左右。在整个训练周期中,YOLOv8m 的 4 项指标变化与 YOLOv8l 最为接近,YOLOv8n 的 4 项指标都表现得最低。

将 4 种 YOLOv8 模型整个训练过程中对验证集进行测试的各类别混淆矩阵进行可视化展示,

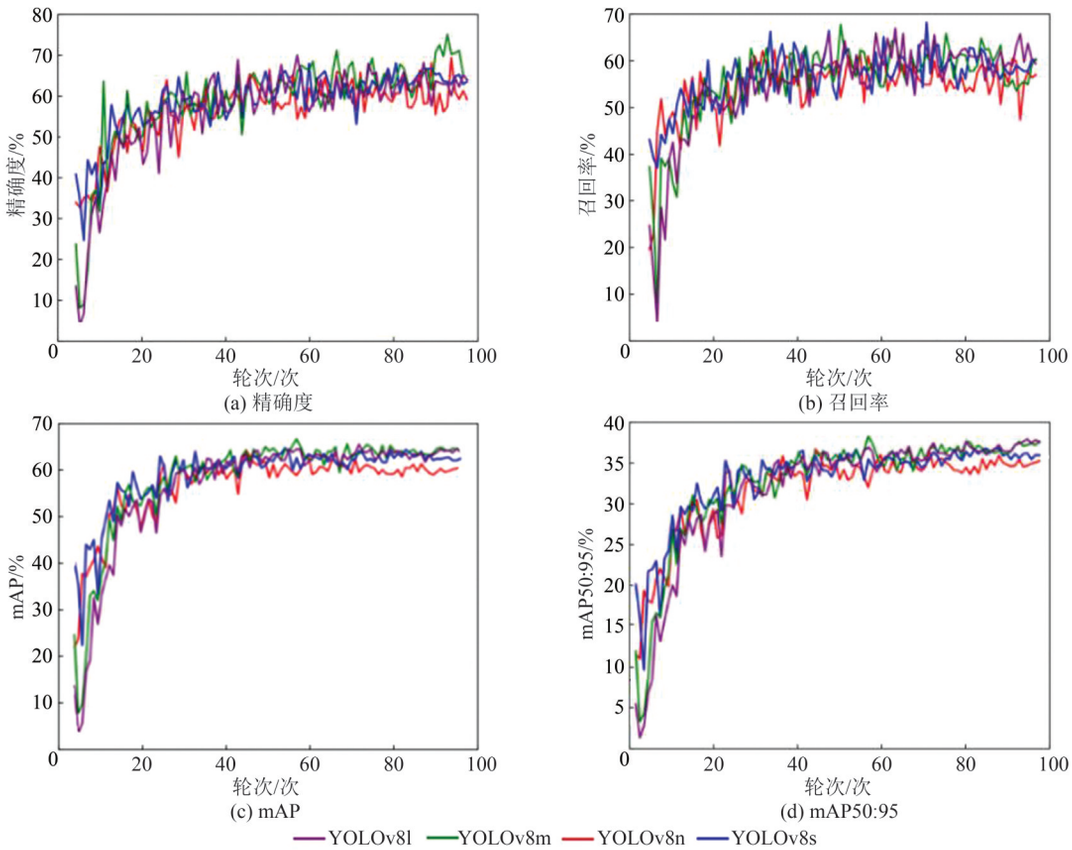


图4 各模型训练参数变化

Fig. 4 Variation of Training Parameters for Each Model

如图5所示,图例表示识别精度在整体样本识别结果中出现的概率。在验证集中,4个模型均对危险类检测正确的概率最高,安全类次之,不安全类最低,其中3个模型都对危险类的漏检概率最高,分别是YOLOv8n、YOLOv8s、YOLOv8m模型。由于拍摄过程中多数车辆处于行动状态,容易将地面的积水溅起水花,这种情况下人眼也难以判别积水等级。此外,当积水淹没至轮胎半径高度附近时,不安全类容易和安全类混淆;当积水淹没至引擎排气口附近时,不安全类容易与危险类混淆,所以正确检测不安全类的概率最低。

将4种YOLOv8模型整个训练过程中验证集3个样本类别的精确度、召回率、mAP50和mAP50:95 4个指标求平均,并且计算出各模型的参数量和计算量,结果如表1所示。可以看出,随着网络宽度和深度的增加,模型参数量和计算量都在大幅度增加,但并不是所有的评价指标都随着网络宽度和深度的增加而增加。其中,虽然YOLOv8l模型最为复杂,但其精确度和mAP50评分都不具优势,在4个模型中分别以69.3%和68.0%排第4和第3;尽管YOLOv8n模型参数量和计算量最小,但其mAP50评分在4个模型中排第2。整体来看,YOLOv8m在验证集上表现最好,其精确度、mAP50和mAP50:95指标在4个模型中均排第1,其中精确度和mAP50分别比第2名高2.2%和2.6%,并且没有太多召回率的牺牲,综合评分最优。

将训练完成的4组模型均选择最优权重对115张测试集进行预测,绘制出的混淆矩阵如图6所示。4个模型对于危险类的漏检率都比较高,但相对的对于危险类正确检测的概率也较高,均高于65%。YOLOv8n和YOLOv8s正确检测不安全类的概率相较于其他两类样本最低,分别为46%和60%;YOLOv8m和YOLOv8l正确检测安全类的概率相较于其他两类样本最低,均为63%。整体来看,4个模型对正样本正确识别的概率都较好,AP能够达到60%以上。

将训练完成的4组模型均选择最优权重,对115张测试集进行预测,并计算3个类别的精确度、召回率、mAP50和mAP50:95评价指标,结果如表2所示。分析可知,在测试集中各指标的评分并不是随着模型复杂度和计算量的增加而增加。对于精确度指标,YOLOv8m对安全类的评分最高,达到了80.7%,YOLOv8l对不安全类的

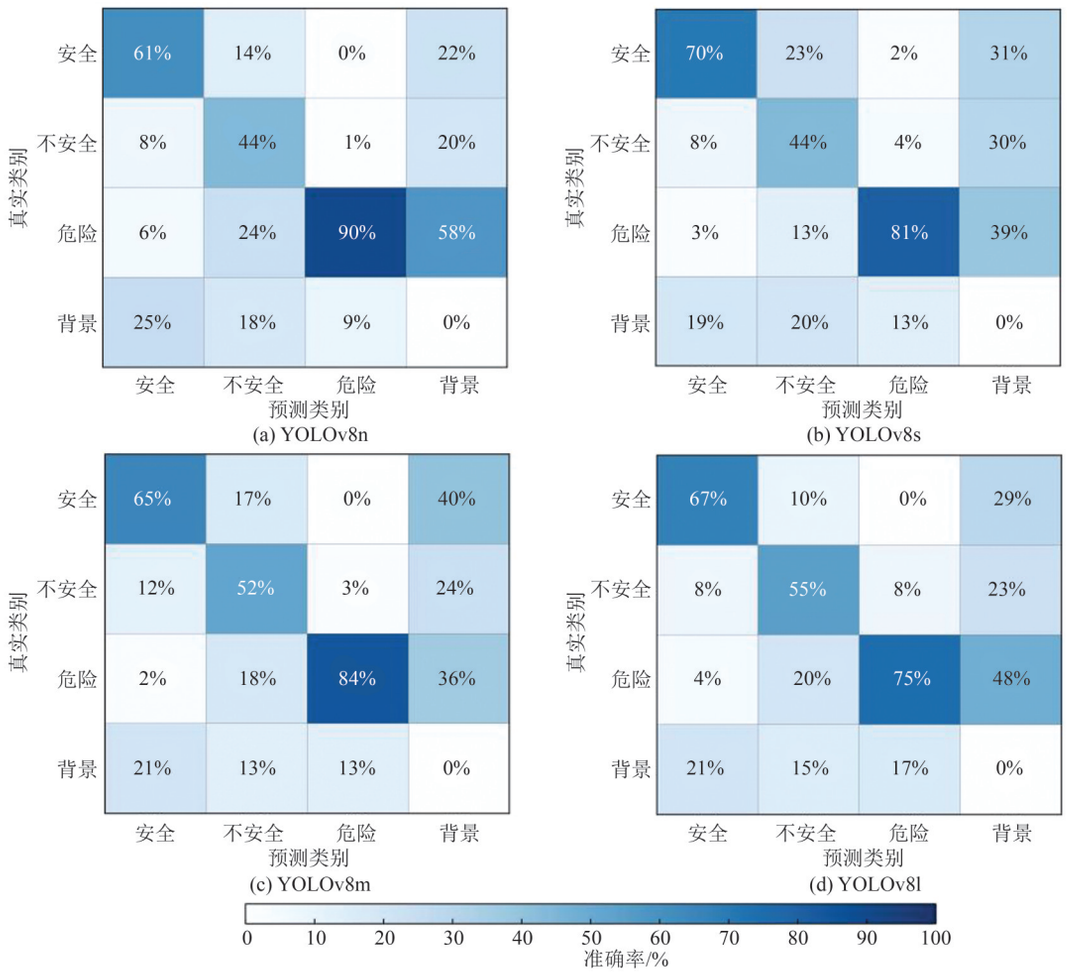


图 5　验证集混淆矩阵对比

Fig. 5　Comparison of Confusion Matrices for Validation Set

表 1　验证集各指标精度对比

Table 1　Precision Comparison of Metrics for Validation Set

模型	精确度/%	召回率/%	mAP50/%	mAP50:95/%	参数量/10^7个	浮点运算次数/10^{10}次
YOLOv8n	70.4	59.3	68.1	37.2	3.0	8.2
YOLOv8s	71.9	59.1	67.8	37.3	11.1	28.7
YOLOv8m	74.1	60.5	70.7	38.8	25.9	79.1
YOLOv8l	69.3	61.0	68.0	38.4	43.6	165.4

评分最高,达到了 55.4%,YOLOv8s 对危险类评分最高,达到了 84.8%。对于召回率指标,YOLOv8m 对安全类和不安全类的评分均最高,分别达到了 66.3% 和 68.8%,YOLOv8n 对危险类评分最高,达到了 68.3%。对于 mAP50 指标,YOLOv8s 对安全类、不安全类和危险类的评分均最高,分别达到了 74.4%、61.7% 和 76.2%。对于 mAP50:95 指标,YOLOv8m 对安全类评分最高,达到了 43.1%,YOLOv8s 对于不安全类和危险类评分均最高,分别达到了 37.7% 和 36.7%。整体来看,各模型对不安全类的检测效果一般,整体的 mAP50 均值超过了 60%,说明模型在较为宽松的匹配标准下表现良好;整体的 mAP50:95 均值在 30%~40%,说明各模型在精确定位这些类别目标方面还存在不足。

为了更加直观地展现模型的检测效果,选取几组具有代表性的不同场景的汽车淹没图片进行预测。图 7 是多尺度混合场景下的汽车淹没状况图,多尺度体现在:(1)淹没状况多尺度,目视解译可以明显看出近距离的车辆受淹程度较低,远距离的车辆受淹状况较为严重,说明近拍摄地处积水较浅,远处积水较深。(2)车辆形态多尺度,近距离车辆拍摄不完整,远距离车辆拍摄完整。(3)车辆大小多尺度,车辆由于拍摄距离远近

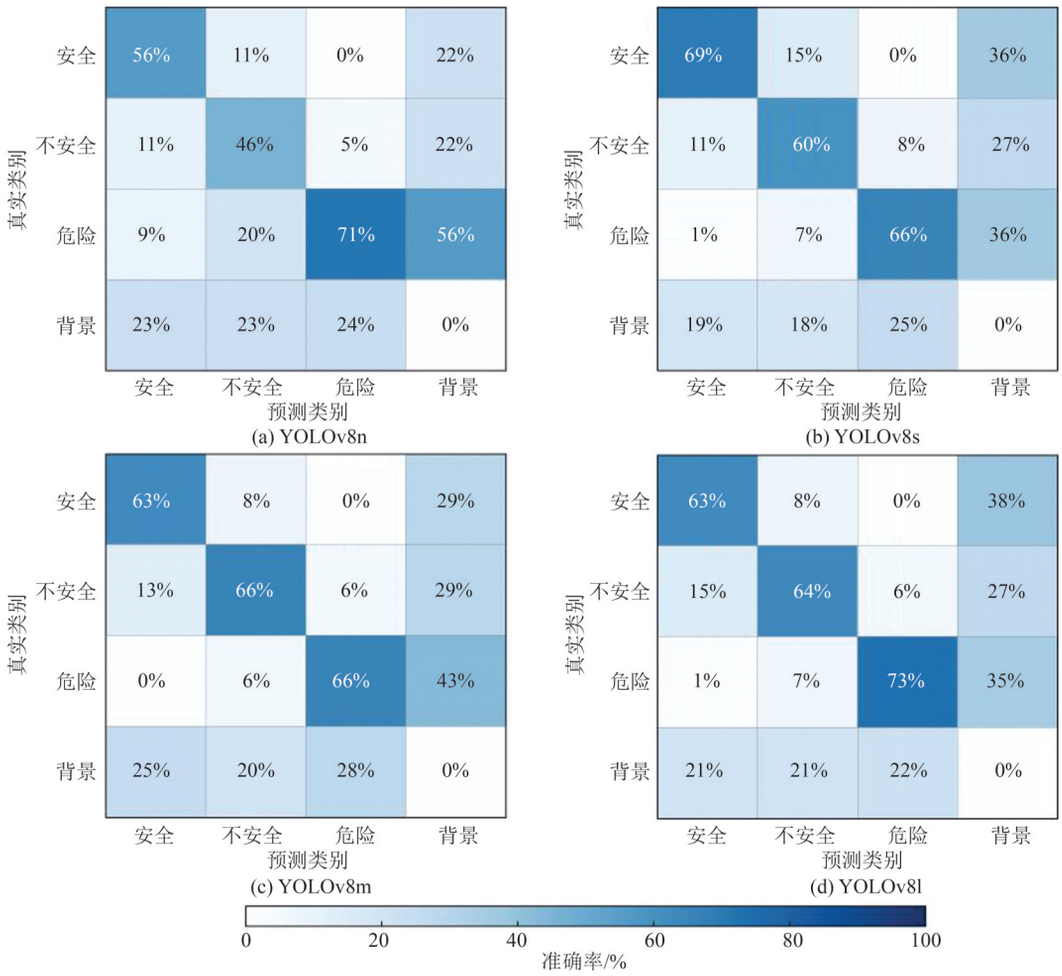


图6 测试集混淆矩阵对比

Fig. 6 Comparison of Confusion Matrices for Test Set

表2 测试集各指标精度对比/%

Table 2 Precision Comparison of Metrics for Test Set /%

模型	类别	精确度	召回率	mAP50	mAP50:95	mAP50均值	mAP50:95均值
YOLOv8n	安全类	75.1	56.9	66.4	35.4	61.4	31.1
	不安全类	49.4	50.0	50.4	26.7		
	危险类	69.7	68.3	67.5	31.3		
YOLOv8s	安全类	74.4	65.7	74.4	41.9	70.8	38.8
	不安全类	53.9	65.6	61.7	37.7		
	危险类	84.8	64.7	76.2	36.7		
YOLOv8m	安全类	80.7	66.3	73.0	43.1	68.3	36.6
	不安全类	51.8	68.8	55.9	30.6		
	危险类	83.2	66.0	75.9	36.2		
YOLOv8l	安全类	77.1	62.3	72.1	41.1	68.9	36.7
	不安全类	55.4	62.5	58.3	32.5		
	危险类	84.4	67.0	76.2	36.4		

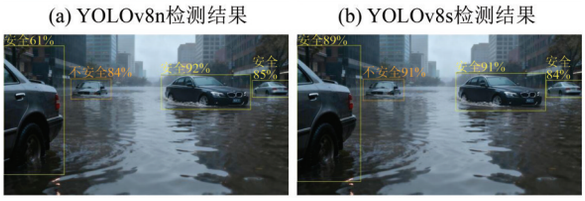
呈现出不同的大小。

由图7(a)可见,YOLOv8n未能有效识别图像中远处、淹没程度较深的车辆。相比之下,YOLOv8s能够较为准确地检测到大多数受淹车辆,但对于距离较远的目标仍存在误判,将实际处于不安全状态的车辆错误识别为安全状态(见图7(b))。YOLOv8m与YOLOv8l均能够正确检测不同车辆的受淹状态,并在处理图像左下角因拍摄不完整而导致形态缺失的车辆时保持了更高的鲁棒性,将其正确识别为不安全类样本。综合分析可知,不同规模的YOLOv8模型在复杂场景下表现出显著差异:轻量化模型在远距离与



(a) YOLOv8n检测结果

(b) YOLOv8s检测结果



(c) YOLOv8m检测结果

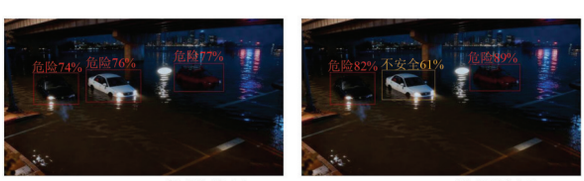
(d) YOLOv8l检测结果

图7　多尺度混合场景下检测效果对比

Fig. 7　Comparison of Detection Effects in Multi-scale Mixed Scenarios

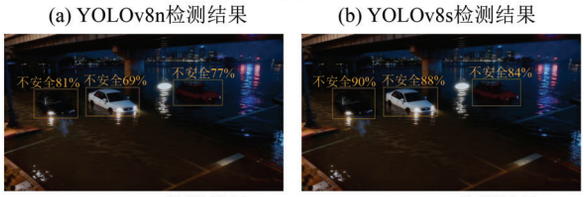
高淹没度目标的识别中存在明显局限,而中大型模型在目标完整性不足等条件下仍展现出较好的识别能力。

如图8所示,该图像拍摄于夜间,淹没区域位于立交桥下方,整体光照较弱,且受路灯反射影响,部分受淹车辆的轮廓难以通过目视准确辨识。在此条件下,YOLOv8n受到昏暗光照的干扰,对图中轿车均出现误检情况,将实际处于不安全状态的车辆错误识别为危险类。YOLOv8s仅能正确识别图像中央受淹车辆状态,但其预测置信度相对偏低。相比之下,YOLOv8m与YOLOv8l均准确判定车辆的淹没程度,其中YOLOv8l在整体识别置信度方面表现更为突出。



(a) YOLOv8n检测结果

(b) YOLOv8s检测结果



(c) YOLOv8m检测结果

(d) YOLOv8l检测结果

图8　夜间场景下检测效果对比

Fig. 8　Comparison of Detection Results in Nighttime Scenarios

4　结　语

本文利用社会公众拍摄的包含小型涉水车辆的图像构建了训练样本,采用车辆淹没深度作为参照标准,将内涝深度划分为安全([0,20] cm)、不安全((20,60] cm)和危险(>60 cm)3个等级,采用精确度、召回率、mAP、AP作为识别精度评价指标,对YOLOv8的4种模型YOLOv8l、YOLOv8m、YOLOv8n和YOLOv8s进行积水深度识别性能做了比较分析,结论如下:

1)模型的网络深度、网络宽度、特征提取能力对模型性能有重要影响,随着网络宽度和深度的增加,模型参数量和计算量都在大幅度增加,但并非所有的评价指标都随着网络宽度和深度的增加而增加。其中,虽然YOLOv8l模型最为复杂,但其精确度和mAP50评分都不具优势,在4个模型中分别以69.3%和68.0%排第4和第3。尽管YOLOv8n模型参数量和计算量最小,但其mAP50评分在4个模型中排第2。整体来看,YOLOv8m在验证集上表现最好,其精确度、mAP50和mAP50:95在4个模型中均排第1,其中精确度和mAP50分别比第2名高2.2%和2.6%,且没有太多召回率的牺牲,综合评分最优。

2)4种模型对于不安全类样本的检测精度均低于其他两个等级,这是由于样本数量不均衡,且模型检测性能还存在一定的局限性,如处于行动状态的车辆容易将地面的积水溅起水花,导致模型误判积水等级,因此正确检测不安全类的概率最低。对于这一问题,在未来的研究中,一方面,对于样本的处理研究应具有针对性的数据增强技术,提高模型对不安全类样本的识别能力;另一方面,在模型网络结构中应引入注意力机制模块,增强模型对关键特征的学习能力。

参　考　文　献

[1]　于朝阳. 基于物联网的城市内涝在线监测与精细化治理系统建设思路探索[J]. 中国建设信息化, 2023(24): 63-67.
YU Chaoyang. Discussion on the Construction of an Online Monitoring and Cause Analysis System for Urban Waterlogging Based on the Internet of Things [J]. *Informatization of China Construction*, 2023 (24): 63-67.

[2]　HUANG H B, WANG X W, LIU L. A Review on Urban Pluvial Floods: Characteristics, Mechanisms, Data, and Research Methods[J]. *Progress in Geography*, 2021, 40(6): 1048-1059.

[3]　罗诗琦, 罗斌, 苏鑫, 等. 利用模拟数据进行遥感图像目标检测模型训练[J]. 武汉大学学报(信息科学版), 2023, DOI: 10.13203/j.whugis20230149.
LUO Shiqi, LUO Bin, SU Xin, et al. Leveraging Synthetic Data for Object Detection in Remote Sensing Images [J]. *Geomatics and Information Science of Wuhan University*, 2023, DOI: 10.

13203/j.whugis20230149.

[4] 徐美,刘舒,孙杨,等.利用洪涝模型进行城市内涝风险快速识别与预警[J].武汉大学学报(信息科学版),2020,45(8):1185-1194.
XU Mei, LIU Shu, SUN Yang, et al. Rapid Identification and Early Warning of Urban Waterlogging Risk Using Flooding Model[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(8): 1185-1194.

[5] 朱晓寒,李向阳,刘昭阁.大数据环境下城市内涝灾害的情景维度模型构建[J].武汉大学学报(信息科学版),2020,45(11):1818-1828.
ZHU Xiaohan, LI Xiangyang, LIU Zhaoge. Constructing Scenario Dimension Model of City Waterlogging Under Big Data Environment[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(11): 1818-1828.

[6] 薛丰昌,吕鑫,陈笑娟.基于改进DeeplabV^{3+}的城市内涝监测方法[J].测绘科学,2023,48(10):216-224.
XUE Fengchang, LÜ Xin, CHEN Xiaojuan. Urban Flood Monitoring Method Based on Improved DeeplabV3+[J]. *Science of Surveying and Mapping*, 2023, 48(10): 216-224.

[7] 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.
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.

[8] SWATHI Y, CHALLA M. YOLOv8: Advancements and Innovations in Object Detection[C]// International Conference on Smart Computing and Communication, Denpasar, Indonesia, 2024.

[9] SOHAN M, SAI RAM T, RAMI REDDY C V. A Review on YOLOv8 and Its Advancements[M]// JACOB I J, PIRAMUTHU S, FALKOWSKI-GILSKI P. Data Intelligence and Cognitive Informatics. Singapore: Springer, 2024: 529-545.

[10] TERVEN J, CÓRDOVA-ESPARZA D, ROMERO-GONZÁLEZ J. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS[J]. *Machine Learning and Knowledge Extraction*, 2023, 5(4): 1680-1716.

[11] 央广网.北京发布城市积水内涝风险地图4个风险等级辅助市民汛期出行[EB/OL].(2022-07-07)[2024-08-10]. https://www.163.com/dy/article/HBMMGDHU0514R9NP.html.
CNR Online. Beijing Releases Urban Waterlogging Risk Map with Four Risk Levels to Assist Citizens in Travel During the Flood Season[EB/OL].(2022-07-07)[2024-08-10]. https://www.163.com/dy/article/HBMMGDHU0514R9NP.html.

[12] 赵师震.基于改进YOLOv8的轻量型火灾检测算法研究[D].大庆:东北石油大学,2025.
ZHAO Shizhen. Research on Lightweight Fire Detection Algorithm Based on Improved YOLOv8[D]. Daqing: Northeast Petroleum University, 2025.

[13] 刘瑞锦,何章鸣.基于YOLOv8的卫星遥感图像快速目标检测方法[J].空间控制技术与应用,2023,49(5):89-97.
LIU Ruijin, HE Zhangming. A Fast Target Detection Method for Satellite Remote Sensing Images Based on YOLOv8[J]. *Aerospace Control and Application*, 2023, 49(5): 89-97.

[14] 张潇艺,杨胜龙.基于YOLOv8的民用船舶影像分类方法研究[J].工业控制计算机,2024,37(4):72-73.
ZHANG Xiaoyi, YANG Shenglong. Research on Civil Ship Image Classification Method Based on YOLOv8[J]. *Industrial Control Computer*, 2024, 37(4): 72-73.

[15] 康睿,徐海祥,冯辉,等.基于改进YOLOv8的航海雷达图像目标检测算法[J].大连海事大学学报,2024,50(3):23-30.
KANG Rui, XU Haixiang, FENG Hui, et al. Target Detection Algorithm of Marine Radar Image Based on Improved YOLOv8[J]. *Journal of Dalian Maritime University*, 2024, 50(3): 23-30.

[16] SONG G L, LIU Y, WANG X G. Revisiting the Sibling Head in Object Detector[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, USA, 2020.

[17] 胡惠娟,秦一锋,徐鹤,等.面向无人机航拍图像的YOLOv8目标检测改进算法[J].计算机科学,2025,52(4):202-211.
HU Huijuan, QIN Yifeng, XU He, et al. An Improved YOLOv8 Object Detection Algorithm for UAV Aerial Images[J]. *Computer Science*, 2025, 52(4): 202-211.

[18] 程换新,矫立浩,骆晓玲,等.改进YOLOv8的遥感图像检测算法[J].无线电工程,2024,54(5):1155-1161.
CHENG Huanxin, JIAO Lihao, LUO Xiaoling, et al. Improved YOLOv8 for Remote Sensing Image Detection[J]. *Radio Engineering*, 2024, 54(5): 1155-1161.