

DOI:10.20035/j.issn.1671-2668.2024.05.015

引用格式:彭建忠,李琛琛,刘李彦,等.基于 YOLOv8 的道路路面裂缝智能检测[J].公路与汽运,2024,40(5):89-94+163.

Citation:PENG Jianzhong,LI Chenchen,LIU Liyan,et al.Intelligent detection of road pavement cracks based on YOLOv8[J].
Highways & Automotive Applications,2024,40(5):89-94+163.

基于 YOLOv8 的道路路面裂缝智能检测*

彭建忠¹,李琛琛^{1,2},刘李彦²,杨豪²,张军辉²

(1.浙江交投高速公路建设管理有限公司,浙江 杭州 310024;2.长沙理工大学 交通运输工程学院,湖南 长沙 410114)

摘要:针对路面病害检测中存在的病害尺度差异大、多尺度病害特征提取难、病害在图像中占比小等问题,提出一种基于 YOLOv8 网络的道路路面裂缝智能检测方法,并在自建的道路路面裂缝数据集集中进行模型训练和参数调优。结果表明,n,s,m,l,x 5 种版本 YOLOv8 模型的精确率分别为 90.2%、91.2%、91.1%、92.2%、89.0%,召回率分别为 86.9%、87.8%、89.9%、87.5%、90.1%,综合比较,YOLOv8m 最优,其平均检测精确率和 F_1 分数分别为 94.8%、90.5%,计算量为 78.7,适用于道路工程路面裂缝智能检测。

关键词:公路;路面;裂缝检测;智能检测;YOLOv8

中图分类号:U418.6

文献标志码:A

文章编号:1671-2668(2024)05-0089-06

根据文献[1],截至 2023 年末,中国公路里程为 543.68 万 km。随着车流量的大幅度增加,道路荷载超出额定值,导致道路磨损加剧,路面老化和磨损等问题日益严重,出现路面破损、结构老化等现象,对道路的安全性和可靠性产生负面影响。目前大多数路面检测仍依赖人工操作,辅以自动化设备,检测结果因测量不确定性而产生偏差,数据可靠性降低,影响养护决策和养护效果。因此,及时、准确地检测并修复路面病害,对延长道路使用寿命和确保行车安全具有重要意义^[2-4]。

随着计算机技术的不断发展,深度学习算法在图像处理和识别领域展现出强大优势,开展基于深度学习的病害智能识别已成为一种趋势。相比人工巡检等传统方法,深度学习算法能通过学习病害图像中潜在特征,克服周围环境的各种干扰,实现病害的精确识别^[5]。随着深度学习技术的发展,以其为基础的目标检测算法不断发展,逐渐成为裂缝检测的关键技术手段。诸多学者也对此进行了研究,如 Elghaish F. 等将 Tubelets、深层卷积神经网络(Convolutional Neural Network,CNN)和 Multi-Method 检测结合为统一的环路检测流程,采用卷积神经网络实现了像素设计检测^[6];肖力炆等研发改良版 Mask R-CNN(Mask Region-based Convolutional

Neural Network)模型驱动的道路裂痕辨识技术,创新性设计了 C-Mask RCNN 多水平阈值辨识方案^[7]。YOLO(You Only Look Once)算法是一种实时目标检测系统,它通过一个单一的神经网络实现目标位置和分类的同时预测,能显著提高处理速度,满足实时应用的需求。与传统的多阶段目标检测方法相比,YOLO 将检测任务简化为一个回归问题,直接在网络的输出层预测边界框和类别概率。自其推出以来,YOLO 经历了多次迭代,不断优化其准确性和速度,对实时目标检测技术的发展产生了深远影响。Yang Z. 等提出了一种改进 YOLOv5 算法——PDNet^[8];王丽苹等基于 AlexNet 网络架构设计了一种路面裂缝检测模型,该模型能准确、快速地识别混凝土路面裂缝^[9];Zhang P. 等提出一种优化 YOLOv5s 模型,并用于道路表面裂纹识别^[10];Li M. J. 等基于 YOLOv5 设计一种从边缘到客户端的道路损坏检测系统,该系统具有较好的实时性,但没有针对路面病害的多尺度特性优化网络^[11];周中等在 YOLOX 算法的基础上提出了实时裂缝图像检测算法 YOLOX-G^[12]。实际路面裂缝具有种类多样性和尺寸差异,裂缝特征在空间上表现为多尺度的特性,而现有网络对这种多尺度的路面裂缝病害特征的处理能力不足,无法准确识别尺

* 基金项目:浙江省交通运输厅重大研发项目(ZJXL-SJT-202316A)

寸差异较大的裂缝。为提高多尺度裂缝的识别精度,本文提出一种基于 YOLOv8 网络的道路路面裂缝智能检测算法。

1 YOLOv8 模型

YOLOv8 网络架构由输入 (Input)、骨干网络 (Backbone)、特征增强 (Neck) 和解耦头 (Head) 组成。与传统 C3 模块不同的是, YOLOv8 的骨干网络采用 CSP (Cross Stage Partial) 概念和轻量级 CSP_2Conv 模块。骨干网络以广泛采用的 SPPF (Spatial Pyramid Pooling with Factorized Convolutions) 模块结束, 有助于提高特征提取能力。在特征增

强部分, 采用 PAN-FPN (Path Aggregation Network-Feature Pyramid Network) 的双向路径^[13-14]。该特征金字塔网络通过上采样的通道融合集成 3 个下采样输入, 最后输出被送入 3 个分支, 将其引向解耦头。解耦头负责分离回归和预测分支。回归分支中, 损失计算涉及类别和本地化组件。采用 VFL (Varifocal Loss) 损失作为分类损失, 采用二进制交叉熵 BCE (Binary Cross Entropy) 损失函数计算全局的类别损失。定位损失由分布聚焦损失 DFL (Distribution Focal Loss) 和完全交并比 CIOU (Complete Intersection Over Union Loss) 构成。图 1 为 YOLOv8 网络架构。

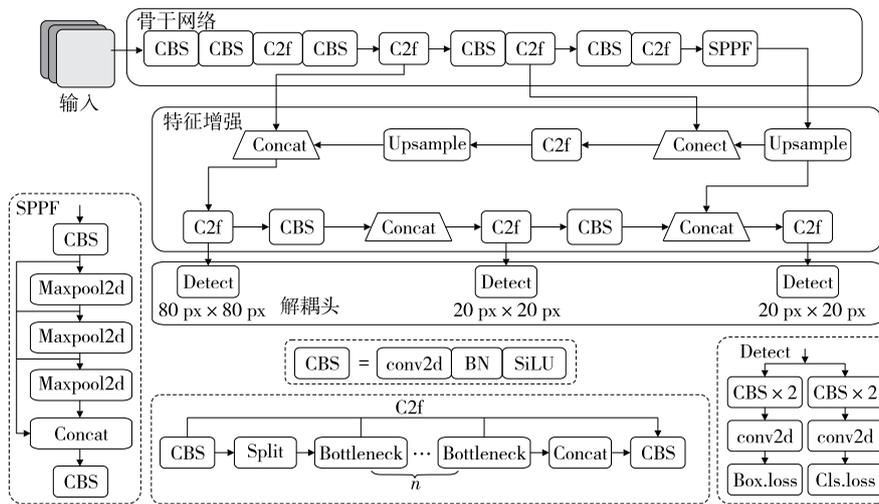


图 1 YOLOv8 模型架构

1.1 主干特征提取网络

主干特征提取网络主要用于对输入的图片进行特征提取, 相比于 YOLOv5、YOLOv7, YOLOv8 的主干网络连接结构更密集, 对图像的特征提取能力更强。图像输入至主干特征提取网络后, 经过多个卷积、标准化、激活函数进行特征提取, 最终输出 3 个大小分别为 13 px x 13 px, 26 px x 26 px, 52 px x 52 px 的有效特征层。13 px x 13 px 特征层经过 SPPF 模块 (见图 2) 扩大感受野, 进一步进行特征提取。

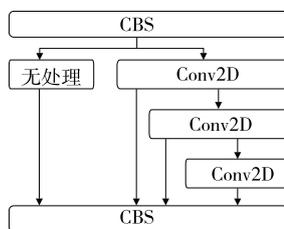


图 2 SPPF 模块结构

YOLOv8 融合 YOLOv7 的 ELAN (Effective Long-Range Aggregation Network) 设计理念^[15-16], 用 CSP 结构取代 YOLOv5 的 C3 结构。CSP 模块可将联合收割机高级特征与上下文信息相结合, 通过增加额外的跳跃连接增强模型的梯度流和网络的特征表达能力, 从而提高检测精度。在 CSP 模块中, YOLOv8 将 YOLOv7 的 3 次卷积简化为 2 次卷积, 并在第一次卷积后将通道数扩充为原来的 2 倍, 随后进行通道上的对半分。这种方法不仅继承了 YOLOv7 多堆叠结构的优点, 而且通过减少 1 次卷积进一步降低了模型的计算负担, 使网络在保持较高检测性能的同时运行效率得到提升。图 3 为 CSP 模块结构。

此外, YOLOv8 摒弃了 YOLOv5 的 Focus 结构和 YOLOv7 的 3 次卷积方法, 采用简单有效的步长为 2 的 3 x 3 卷积核进行特征提取, 在减少计算复杂性的同时, 能较快处理图像数据, 适应需要快速反

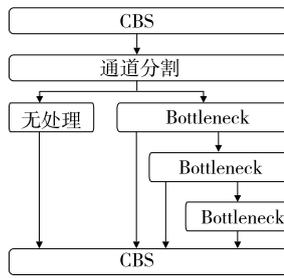


图 3 CSP 模块结构

应的应用场景。

1.2 加强特征提取网络

YOLOv8 的特征提取网络采用 3 个不同深度的特征层(中间层、中下层、底层),通过多层级的设计,有效增强模型对不同尺寸物体的检测能力。在特征融合方面,YOLOv8 利用特征金字塔网络(FPN)结构,通过上下采样和 CSP 模块对特征层进行融合和优化,从而提高检测精度和模型的表达能力。另外,YOLOv8 并未对主干网络得到的 3 个有效特征层进行卷积操作,而是直接进行上采样和叠加,进一步提高了模型的检测速度。

1.3 损失函数

YOLOv8 在目标检测预测中分离了回归和分类任务。对于回归任务,使用 DFL 损失和 CIOU 损失。对于分类任务,使用 BCE 损失。

CIOU 量化了实际框与预测框之间的距离,而 DIOU(Distance Intersection Over Union)测量的是两个检测框中心之间的欧氏距离。CIOU 在 DIOU 的基础上加入检测框宽高比的考量:

$$R_{CIOU} = \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \tag{1}$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \tag{2}$$

$$\alpha = \frac{v}{(1 - R_{IOU}) + v} \tag{3}$$

式中: ρ 为预测框中心和实际框中心之间的欧氏距离; b, b^{gt} 分别代表预测框和实际框的中心; c 为能同时包含预测框和实际框的最小闭合区域的对角线距离; α 为权重函数; v 用于衡量宽高比的相似性; R_{IOU} 为实际框与预测框之间的交并比。

2 数据集构建

2.1 数据采集

采用大疆经纬 M600 Pro 无人机作为路面裂缝病害数据采集设备,其技术参数见表 1。无人机在

飞行过程中要尽量避免道路上的障碍物。另外,由于飞行高度和飞行速度等因素对路面病害图像成像质量有很大影响,飞行中需调整飞行参数,保证公路病害图像的高分辨率。

表 1 大疆经纬 M600 Pro 无人机的技术参数

参数名称	参数值
推荐最大起飞质量/kg	15.5
最大旋转角速度/[$(^\circ) \cdot s^{-1}$]	俯仰轴:300;航向轴:150
最大俯仰角度/ $(^\circ)$	25
最大上升速度/[$m \cdot s^{-1}$]	5
最大下降速度/[$m \cdot s^{-1}$]	3
最大可承受风速/[$m \cdot s^{-1}$]	8
最大水平飞行速度/[$km \cdot h^{-1}$]	65(无风环境)
适配 DJI 云台	如影 RX 三轴云台
飞控系统	A3 Pro

2.2 数据集处理

利用无人机对多条道路进行病害检测,得到包含 1 150 张初始路面裂缝图像的数据集,图 4 为部分裂缝图像。该数据集包含道路的复杂背景、明亮及灰暗光照条件等多种情况,具有较高的代表性。由于网络训练需要大量路面裂缝图像,采用随机旋转、水平和垂直翻转、光照调节、色温变化、噪声、模糊等方法扩充数据集,最终构建包含 2 000 张道路裂缝图像的数据集,图 5 为操作过程。将数据集按照 8 : 1 : 1 的比例进行划分,得到训练集 1 600 张图像、验证集 200 张图像、测试集 200 张图像。训练

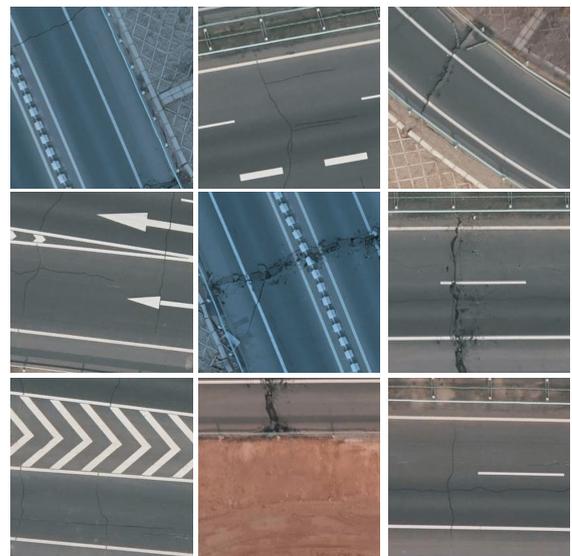


图 4 部分路面裂缝图像

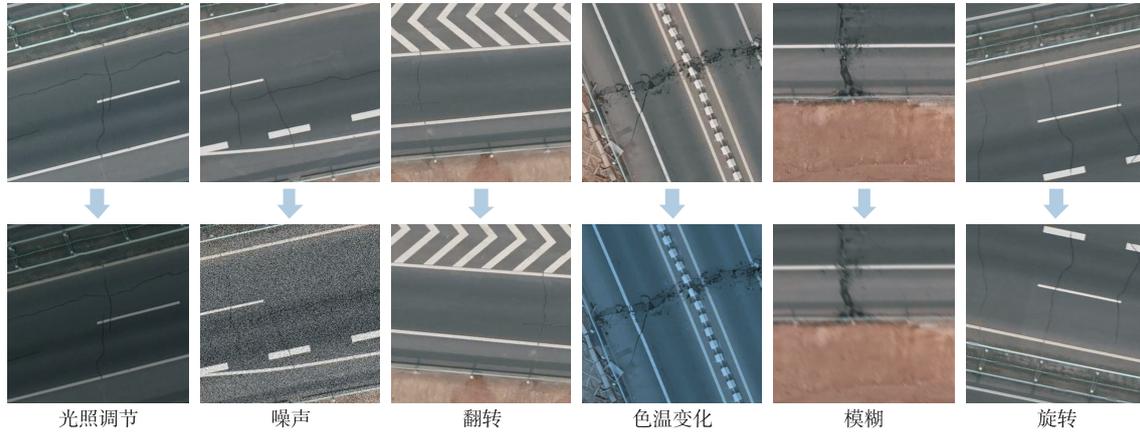


图 5 路面裂缝图像数据增强方法

集用于网络训练;验证集用于判断网络是否收敛,防止网络出现过拟合;测试集用于对训练好的网络进行测试。

2.3 数据集标注

使用 LabelImg 对数据集图像进行标注,并将其转换为 VOC 格式。LabelImg 可以对目标进行位置和大小加框标注,生成目标位置和大小文件,用于网络训练。考虑到路面裂缝的连续性和整体性,对不同形状的裂缝,在标注时对单一裂缝采用单一矩形框进行标注。图 6 为裂缝标注示例。

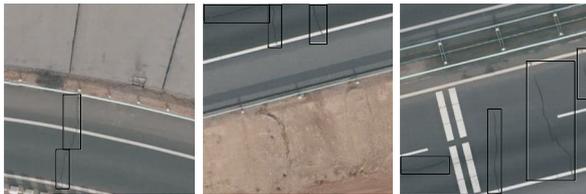


图 6 路面裂缝标注过程

3 试验环境与方法

3.1 试验环境配置

试验环境与相关参数见表 2。

表 2 试验环境

项目	参数
操作系统	Windows10
CPU	13 th Gen Intel(R) Core(TM) i9-13900F
内存/GB	64
显卡	NVIDIA GeForce RTX 4070
显存/GB	12
计算机编程语言	Python3.8.18
深度学习版本	Pytorch1.13.1

3.2 模型训练超参数设置

选用 n、s、m、l、x 5 种版本 YOLOv8 网络模型,在同一数据集上进行训练,训练次数为 200 次,确保其能达到收敛状态。网络训练参数设置见表 3。

表 3 网络训练超参数

参数名称	参数值
图片尺寸(Image)/px	416
训练次数(Epochs)/次	200
批处理大小(Batch Size)/个	32
优化器	SGD
初始动量(Momentum)	0.937
优化器的权重衰减(Weight Decay)	0.000 5
初始学习率	0.01

3.3 模型评价指标

为评价模型对路面裂缝的检测性能,选择准确率 P (Precision)、召回率 R (Recall)、准确率与召回率的调和平均值 F_1 分数 (F_1 -score)、平均精度 (mean Average Precision, mAP)、模型的计算量即浮点运算次数 FLOPs (Floating Point Operations) 作为模型评价指标,计算公式如下:

$$P = \frac{T_P}{T_P + F_P} \tag{4}$$

$$R = \frac{T_P}{T_P + F_N} \tag{5}$$

$$F_1 = \frac{2PR}{P + R} \tag{6}$$

$$P_{AP} = \int_0^1 P(R) dR \tag{7}$$

$$P_{mAP} = \frac{1}{N} \sum_{i=0}^N P_{APi} \tag{8}$$

式中: T_P 为检测正确的病害目标数量; F_P 为检测错误的病害目标数量; F_N 为未检测到的病害目标数量; $P(R)$ 为以 R 为横坐标、 P 为纵坐标的曲线; N 代表类别的数量, 这里 N 取值为 1; P_{APi} 表示第 i 类的平均精度值。

交并比是衡量预测框与真实标记框重叠程度的指标。理想状态下, 这两者应完全重合, 交并比为 1。通常情况下, 交并比达到或超过 0.5 即较理想。浮点运算次数是指执行一次网络模型所需进行的浮点运算总次数, 反映模型在单次前向传播中执行的浮点运算次数, 用来衡量模型的计算效率及处理速度。该指标对于理解和优化模型性能至关重要。

4 试验结果及分析

4.1 YOLOv8 模型试验分析

YOLOv8 网络主要包括 n、s、m、l、x 5 个版本, 其网络深度、宽度、参数量及主干特征提取网络的最大通道数不同, 其中 x 版本的参数量最大。不同版本网络主要通过深度倍数 d 、宽度倍数 w 和比例 r 3 个参数进行调节, 从而控制网络的卷积层数、每层通道数及计算效率。各版本网络模型的参数见表 4。

表 4 YOLOv8 网络各版本的参数

模型	d	w	r
YOLOv8n	0.33	0.25	2.0
YOLOv8s	0.33	0.50	2.0
YOLOv8m	0.67	0.75	1.5
YOLOv8l	1.00	1.00	1.0
YOLOv8x	1.00	1.25	1.0

为选取适合路面裂缝数据集的网络, 利用包含 2 000 张路面裂缝图像的数据集, 分别对 5 个版本 YOLOv8 网络模型进行训练, 得到各模型的性能评估指标值(见表 5)。

由表 5 可知: 5 个模型中, YOLOv8n 的体积最小, 其平均精度、召回率和计算复杂度均最小; YOLOv8x 为最大模型, 其召回率和计算量最大, 精确率最低; YOLOv8s 表现出色, 其精确率较高, 召回率和计算复杂度较小。在路面裂缝检测中, 考虑模型的检测精度与速度的平衡, YOLOv8n 的计算消耗最低, 但其精确度较低; YOLOv8x 的计算量大, 精确度亦偏低; YOLOv8l 的检测精度最高, 但其

表 5 不同 YOLOv8 模型的性能评价指标

模型	$P/\%$	$R/\%$	$F_1/\%$	$P_{mAP}/\%$	$N_{FLOPs}/次$
YOLOv8n	90.2	86.9	88.5	92.3	8.1
YOLOv8s	91.2	87.8	89.5	94.7	28.4
YOLOv8m	91.1	89.9	90.5	94.8	78.7
YOLOv8l	92.2	87.5	89.8	94.3	164.8
YOLOv8x	89.0	90.1	89.5	93.5	257.4

注: N_{FLOPs} 为浮点运算次数。

计算负担较大, 仅低于 YOLOv8x 模型。5 个模型的训练效果均较好, 平均精确率均超过 92%, 其中 YOLOv8m 的平均精确率最高, F_1 分数也最高, 对路面裂缝的识别准确度最高, 综合性能最好。YOLOv8n 是 YOLOv8 框架内的一个轻量级迭代, 有助于减轻模型的存储和加载成本。在裂缝检测中, 快速模型部署是一个关键考虑因素, 特别是在需要对裂缝做出快速响应的情况下。无人机道路路面裂缝检测通常需要实时结果, 以便快速决策和及时实施相应措施。轻量级模型通常具有更高的推理速度, 满足实时要求。

4.2 检测结果分析

为进一步对比不同模型的性能, 选取 3 张具有代表性的路面裂缝图像进行对比(见图 7~12)。



图 7 路面裂缝原图

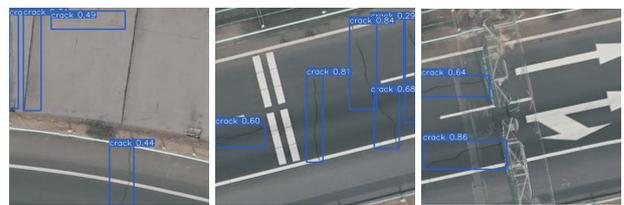


图 8 YOLOv8n 检测结果

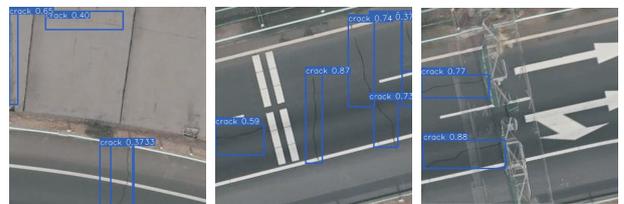


图 9 YOLOv8s 检测结果

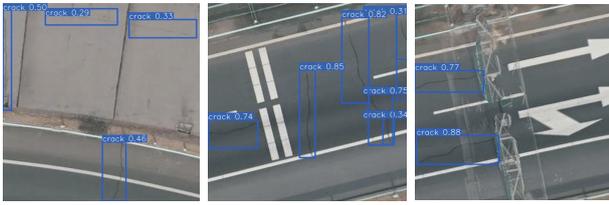


图 10 YOLOv8m 检测结果

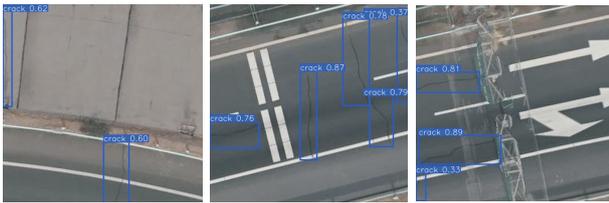


图 11 YOLOv8l 检测结果

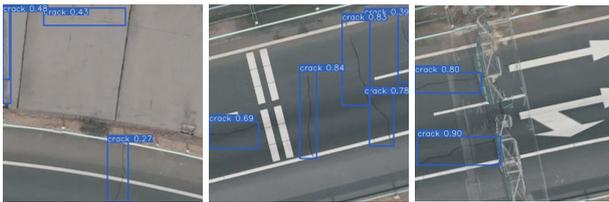


图 12 YOLOv8x 检测结果

由图 7~12 可知:YOLOv8m 模型对路面裂缝病害的目标定位最精准,置信度最高,且没有出现错检漏检情况,对路面裂缝图像的综合检测性能最好;YOLOv8x 模型对个别路面裂缝图像的检测结果的置信度低于 YOLOv8m 模型,且定位精度稍差;YOLOv8l 和 YOLOv8s 模型对个别路面裂缝图像出现漏检现象,且多数裂缝目标置信度低于 0.8,定位精度也低于 YOLOv8m 模型。YOLOv8m 模型能适应路面裂缝中复杂的环境条件,其检测结果优于其他 4 种模型,对道路路面裂缝图像的综合检测效果最好,适用于路面裂缝检测。

5 结论

为解决多尺度道路路面裂缝病害的自动化检测问题,本文提出一种基于 YOLOv8 的路面裂缝智能检测算法。通过分析不同版本 YOLOv8 模型在性能上的优劣,经过对检测性能与计算资源消耗的全面评估,YOLOv8m 模型最理想,该模型在保证检测精度的前提下,能有效降低计算负担并提高检测速度,能高效完成路面裂缝的精准识别。

本文采用 YOLOv8 裂缝智能检测模型对路面裂缝病害开展无损检测,但所选择的研究样本在多样性上存在不足,需进一步扩大路面裂缝病害数据

范围。此外,本文未对神经网络结构进行优化,未来研究中将进一步完善和优化 YOLOv8m 模型的神经网络结构,提高其路面裂缝无损检测效果。

参考文献:

- [1] 交通运输部.2023 年交通运输行业发展统计公报[N].中国交通报,2024-06-18(002).
- [2] 胡鹏,夏晓华,钟预全,等.采用多尺度特征增强的路面病害检测模型[J/OL].西安交通大学学报,1-12[2024-09-03].<http://kns.cnki.net/kcms/detail/61.1069.T.20240829.1738.006.html>.
- [3] 马建,赵祥模,贺拴海,等.路面检测技术综述[J].交通运输工程学报,2017,17(5):121-137.
- [4] 何铁军,李华恩.基于改进 YOLOv5 的路面病害检测模型[J].土木工程学报,2024,57(2):96-106.
- [5] 沙爱民,童峥,高杰.基于卷积神经网络的路表病害识别与测量[J].中国公路学报,2018,31(1):1-10.
- [6] ELGHAISH F, TALEBI S, ABDELLATEF E, et al. Developing a new deep learning CNN model to detect and classify highway cracks[J].Journal of Engineering, Design and Technology,2021,20(4):993-1014.
- [7] 肖力扬,李伟,袁博,等.一种基于改进实例分割模型的路面裂缝检测方法[J].武汉大学学报(信息科学版),2023,48(5):765-776.
- [8] YANG Z, LI L, LUO W. PDNet: improved YOLOv5 nondeformable disease detection network for asphalt pavement[J].Computational Intelligence and Neuroscience,2022,2022:5133543.
- [9] 王丽苹,高瑞贞,张京军,等.基于卷积神经网络的混凝土路面裂缝检测[J].计算机科学,2019,46(增刊 2):584-589.
- [10] ZHANG P, LI W, WENG Y. Detection of road crack defects based on improved YOLOv5s model [J]. Journal of Physics:Conference Series,2022,2303(1):012019.
- [11] LI M J, WANG H, PENG Y H, et al. Edge-to-client real-time road damage detection system based on YOLOv5[C]//2021 China Automation Congress(CAC). Beijing, China, IEEE, 2021:1221-1226.
- [12] 周中,闫龙宾,张俊杰,等.基于 YOLOX-G 算法的隧道裂缝实时检测[J].铁道科学与工程学报,2023,20(7):2751-2762.
- [13] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2017:2117-2125.

(下转第 163 页)