

基于 YOLOv8 的路面病害检测体系研究

邓文军 段旭东

(云南华怡道桥技术工程公司 云南 昆明 650011)

摘要 对于路面病害精准且及时的检测,是保障道路通行安全、延长道路使用寿命、优化养护资源配置的核心前提。随着深度学习技术的发展,单阶段目标检测算法 YOLO 系列凭借高效的实时检测能力,在路面病害检测领域得到广泛应用。YOLOv8 作为该系列的稳定迭代版本,较之前代和其它模型相比,在特征提取能力及检测精度方面均有显著提升,为构建智能且高效的路面病害检测体系提供了技术支持。本文系统地梳理了基于 YOLOv8 的路面病害检测体系,明确研究方向与研究价值,概括研究现状与现存问题,详细阐述 YOLOv8 模型针对多维度的优化策略,结合典型案例与成果量化来验证其体系的有效性,总结研究成果并提出未来的优化方向。

关键词 YOLOv8; 路面病害检测; 特征提取; 轻量化优化

文章编号 056-2026-3580

Research on Pavement Disease Detection System Based on Yolov8

Deng Wenjun,Duan Xudong

(Yunnan Huayi Road Bridge Engineering Company, Kunming 650011, China)

Abstract Accurate and timely detection of pavement diseases is the core premise to ensure road traffic safety, extend road service life and optimize the allocation of maintenance resources. With the development of deep learning technology, the single-stage target detection algorithm YOLO series has been widely used in the field of pavement disease detection with its efficient real-time detection ability. Yolov8, as a stable iterative version of the series, has significantly improved the feature extraction ability and detection accuracy compared with previous generations and other models, it provides technical support for building an intelligent and efficient pavement disease detection system. This paper systematically sorts out the pavement disease detection system based on Yolov8, clarifies the research direction and value, summarizes the research status and existing problems, and elaborates the multi-dimensional optimization strategy of YOLOV8 model, the effectiveness of the system is verified by combining typical cases and results quantification, and the research results are summarized and the future optimization direction is proposed.

Keywords YOLOV8; Pavement disease detection; Feature extraction; Lightweight optimization

收稿日期: 2025-11-07 录用日期: 2026-01-12

通讯作者: 邓文军 段旭东; 单位: 云南华怡道桥技术工程公司 云南 昆明

1 绪论

道路基础设施是我国经济发展的重要支撑。截至 2024 年底，交通运输部数据显示全国公路里程已达 549.04 万公里，较上年新增 5.35 万公里，形成全球规模最大的公路网络。随着道路使用年限增长、交通荷载累积及极端天气侵蚀，路面易出现裂缝、坑洼、沉陷、松散等多种病害。这些病害不仅降低行车舒适性，还严重威胁驾乘人员安全，同时加速路面结构劣化，导致养护成本大幅增长。传统路面病害检测依赖人工巡检，存在效率低、主观性强、漏检率高、安全风险大等问题。

为解决传统检测模式的痛点，基于计算机视觉与深度学习的自动化检测技术应运而生。YOLO 系列算法作为单阶段目标检测的标杆，凭借“端到端”的检测流程和均衡的精度与速度性能，逐步取代两阶段算法成为路面病害检测的主流技术。综合评价后，本文选取 YOLOv8 作为主要研究对象。该模型由 Ultralytics 团队于 2023 年发布，相较于 YOLOv3 到 YOLOv7 的版本，其在主干网络结构、特征融合方式、检测头设计上进行了全方位优化，具备更强的多尺度特征捕捉能力与实时推理效率，能够更好适配复杂路面场景的病害检测需求。

基于 YOLOv8 的路面病害检测体系研究围绕“精度提升、效率优化、场景适配”三大核心目标，形成三个主要研究方向：一是针对路面病害（尤其是小目标病害）特征模糊、形态不规则、尺度差异大的问题，通过引入注意力机制、改进特征融合模块、优化卷积结构等方式，增强 YOLOv8 对病害特征的提取与表征能力，降低漏检率与误检率；二是面向车载终端、

嵌入式设备等边缘部署场景，通过剪枝、量化、轻量级模块替换等策略，在保证检测精度的前提下，降低模型参数量与计算成本，满足实时检测需求；三是针对光照变化、阴影干扰、路面污渍、背景复杂等实际检测难题，通过数据增强、迁移学习、多模态融合等技术，提升检测体系的鲁棒性。

该领域研究丰富了深度学习在土木工程与智能交通交叉领域的应用理论，为小目标、不规则形态、复杂背景下的目标检测问题提供了新的解决方案。针对 YOLOv8 的结构优化策略，可为其他场景下的目标检测模型改进提供借鉴，推动单阶段目标检测算法泛化能力提升。同时，多模态数据融合、迁移学习在路面病害检测中的应用，为解决小样本、高噪声场景下的模型训练难题提供了理论支撑。

基于 YOLOv8 的路面病害检测体系能够实现检测效率、精度与成本的三重优化，具有明显的工程应用价值。效率层面，自动化检测系统每分钟可处理 120 张高清影像，效率较人工检测提升 6 倍，能大幅缩短养护决策周期。精度层面，优化后的 YOLOv8 模型在实验室标准场景下可区分 22 种路面病害，捕捉 0.2mm 细微裂缝，避免人工主观偏差导致的漏检误检，其核心病害检测精度也能满足实际工程需求。成本层面，某地区单公里检测成本从人工的 250 元降至 40 元，降幅达 84%，可显著降低道路养护的成本。此外，该体系能与道路检测车、智慧交通平台深度融合，推动道路养护从“被动修复”向“主动预判”转型，为智能交通系统建设提供核心技术支撑。

2 研究现状

路面病害检测技术经历了从人工检测到机器视觉,再到深度学习检测的三个阶段。早期人工检测依赖检测员视觉评估与工具丈量,效率与精度受人为因素影响较大。传统机器视觉技术通过边缘检测、阈值分割等手工特征提取方法识别病害,但泛化能力弱,难以适应复杂路面场景,深度学习技术的出现实现了特征自动提取,大幅提升了检测性能。

在深度学习检测领域,如 Faster R-CNN 的两阶段算法最早应用于路面病害检测。Li 等提出基于 ResNet50 与 SE 注意力机制的改进 Faster R-CNN 模型,提升了裂缝识别精度,但检测速度较慢,难以满足实时需求。单阶段算法凭借高效性逐步成为主流 YOLO 系列算法表现尤为突出。YOLOv3 通过多尺度预测来提升小目标病害检测能力;YOLOv5 引入 Focus 模块与 C2f 模块,平衡了精度与速度;YOLOv7 提出 E-ELAN 模块增强特征融合;YOLOv8 进一步优化主干网络与检测头,采用自适应锚框与损失函数,在路面病害检测任务中展现出更优的基础性能。

YOLOv8 发布后,国内外学者围绕其在路面病害检测中的应用开展了大量优化研究,形成了多个代表性改进模型。Deng 等以 YOLOv8s 为基础,设计 CAMPCConv 下采样模块保留病害纹理特征,构建 MA-PANet 多尺度自适应特征融合网络,并采用 Focal Loss 缓解正负样本不平衡。该模型在 RDD2020 和 RDD2022 数据集上的 mAP 分别达到 57.1% 和 52.8%,较原模型提升 3.2 和 0.6 个百分点,性能优于 YOLOv5 等传统检测网络。需要说明的是,RDD2022 数据集相较于 RDD2020,新增了 3 类复杂场景病害,标注标准更严格,背景干扰更显著,因此 mAP 出现合理下降。不

过该模型距离实际工程应用的精度要求仍有差距,需在实际采集的路面病害数据集上进一步验证优化。

Qin 针对不同应用场景需求,提出两类改进模型。CG-YOLOv8n 通过 Cross-BiFPN 特征融合结构与 GSConv、VoVGSCSP 模块,在 RDD2020 数据集上实现参数量降低 11.96%、mAP@0.5 提升 0.4% 的轻量化目标;GCRA-YOLOv8n 引入 GCR-C2f 并行特征提取模块与 ASFF 特征融合检测头,使 mAP@0.5 提升 3.4%,同时开发了 PyQt5 可视化检测系统降低使用门槛。但 CG-YOLOv8n 检测精度提升有限,GCRA-YOLOv8n 参数量较大,不适用于边缘设备,且所用数据集覆盖地区和病害类型较少,泛化能力有待验证。

Hou 等提出 YOLOv8n-CB 模型,在主干网络引入 CPCA 注意力机制动态调整权重,颈部替换为加权 BiFPN 增强小目标特征融合。该模型在 China_Mix 数据集上 mAP@0.5 达 92.3%,参数量和 GFLOPs 分别降低 29.33% 和 9.88%,兼顾了精度与轻量化。但模型未充分验证强光照、暴雨等极端环境下的检测性能,缺乏对更多类型路面病害的识别能力。

Chen 等针对高原山区沥青路面图像阴影多、干扰大的问题,采用改进 Fast YOLOv1 模型,通过调整网格划分(14×14)和图像预处理(448×448),实现横裂、纵裂等 5 类病害的准确识别,鲁棒性优于传统数字图像处理算法。但该模型基于早期 YOLOv1 架构,性能不如新一代模型,没有量化检测精度指标,也缺少与主流模型的对比验证。

尽管基于 YOLOv8 的路面病害检测研究已取得显著进展,但仍存在四大核心问题:第一是小目标病害(如细微裂缝)检测精度不足,受复杂背景与噪声干扰,漏检率仍维持在一定

水平。模型泛化能力有限，在光照突变、积水、冰雪等极端天气场景下，检测性能大幅下降。第二是轻量化与精度的平衡难题尚未完全解决，轻量化模型在复杂病害场景下精度损失明显，高精度模型难以部署于低算力边缘设备。第三是工程化应用不成熟，多数研究停留在实验室数据集验证阶段，与实际道路检测车、养护管理平台的融合度低，缺乏标准化的部署流程与数据交互机制。本文针对路面病害检测中小目标病害漏检率高、模型泛化能力弱、轻量化与精度难平衡及工程化融合度低等问题，采用“数据-网络-训练”协同优化提升检测精度，结合“卷积替换+结构化剪枝+模型量化+知识蒸馏”四步递进策略实现模型轻量化，并通过工程化部署验证，构建了基于 YOLOv8 的路面病害检测体系。

3 基于YOLOv8的体系优化策略

实际检测中存在小目标病害占比高、边缘特征模糊、背景干扰大等问题，同时车载终端、边缘检测盒等工程部署设备算力有限，原生 YOLOv8 模型难以兼顾检测精度与轻量化需求。针对这一问题，本文提出针对性优化方案，先通过数据、网络、训练策略的协同优化提升检测精度，再通过轻量化技术实现模型压缩，兼顾工程部署的实时性。下文结合某市政道路病害检测工程案例，验证优化方案的实用性与可行性。

3.1 精度提升优化

精度提升优化从数据、网络、训练三个维度构建协同优化体系，减少单一优化的局限。

数据层面，路面病害小目标占比高（微裂缝、细坑槽占比超 60%），且存在样本不平衡、模糊特征突出的问题。为此设计定制化数据增强策略：采用 Copy-Paste 增强将标注的小

病害随机复制粘贴到无病害路面背景中，搭配 1.5-2.0 倍的局部放大操作，保留细粒度边缘特征，有效提升小目标样本覆盖率；将 Mosaic 与 MixUp 增强概率调至 0.8，融合干燥、潮湿、有标线等不同路面背景，提升模型对复杂环境的泛化能力；添加高斯模糊（核大小 $3 \times 3/5 \times 5$ ）、椒盐噪声（噪声密度 0.01-0.03）及随机亮度对比度调整（亮度 $\pm 30\%$ 、对比度 $\pm 20\%$ ），模拟实际检测中摄像头抖动、光照变化、路面污渍导致的图像模糊，增强模型对模糊病害的识别能力。同时，对沉陷等稀缺病害采用 2 倍过采样，对轻微裂缝等冗余类别保留 60% 原样本量进行欠采样，结合类别权重调整损失函数（稀缺类别权重设为 2.0，冗余类别权重设为 0.5），缓解样本不平衡导致的模型偏置。

网络结构层面，将 Backbone 部分中的 C2f 模块替换为 C2f-Focus 模块，其构建与优化步骤分为四步，第一步是切片操作，输入的特征图采用 2×2 非重叠切片，将单张特征图分割为 4 个尺寸相同的子特征图，拼接后通道数扩展至 $4 \times$ 个（通道数为）。第二步则是通道校准，通过 1×1 的卷积层将通道数降维至原生 C2f 模块的输入通道数。第三步是特征融合，保留原生 C2f 的多分支结构，通过 Split 操作将降维后的特征分为比例 1:1 的两支，一支经 Bottleneck 序列提取深层特征，另一支直接保留浅层细节，最终通过 Concat 操作融合两支的特征；最后一步是参数设置，所有卷积层均采用零均值初始化，Bottleneck 的膨胀率为 1，未引入额外参数量，确保其与原生 C2f 参数量一致。该设计保留小目标病害的边缘、纹理特征，避免原生的 C2f 直接下采样进而导致的细粒度特征丢失，以适配小目标病害的检测需求。

接下来选择 SimAM 轻量注意力机制嵌

入特征融合层，其核心计算逻辑有三部分，第一部分是特征重要性评估，对输入特征图 $F \in R^{(H \times W \times C)}$ (H 、 W 为特征图尺寸， C 为通道数)，计算每个通道 k 的均值和方差，如公式 (1.1) 和 (1.2)：

第二部分是权重生成，通过公式 (1.3) 计算通道权重，并对做归一化处理，使用公式 (1.4)。最后一部分是特征重加权，将归一化后的权重与原特征通道所有元素逐次相乘，得到增强后的特征图 F' ，实现对病害区域特征的聚焦，提升特征利用率。

训练策略层面，将原生 CIoU 损失替换为 EIoU 损失，将回归损失分解为距离、重叠、长宽比损失，适配路面病害不规则形状的回归需求，提升定位精度；分类分支采用 Focal Loss v2，通过难样本挖掘缓解“背景多、病害少”的正负样本不平衡问题。

采用“预热 + 余弦退火”的组合学习率调度策略可显著提高模型性能，其关键参数设置为两个阶段，一是预热阶段，前 5 个 epoch 为预热期，学习率从初始值 $1e-5$ 线性增长至目标初始学习率 $1e-3$ ，避免初始学习率过高导致模型震荡；二是余弦退火阶段：预热结束后（第 6-100 个 epoch），采用余弦衰减策略，设置 $\eta=95$ ，最小学习率 $1e-6$ ，学习率随 epoch 变化公式为公式 (1.5)：

3.2 轻量化优化

轻量化的优化采取“卷积替换 + 结构化剪枝 + 模型量化 + 知识蒸馏”的四步递进策略。具体的优化步骤分为四步，第一步先将模型的 Backbone 与 Neck 部分中所有标准 3×3 卷积替换为深度可分离卷积，在保持特征提取能力基本不变的前提下，可使参数量与计算量降低 80% 左右，适配特征提取需求。第二步采用基于 L1 正则化的结构化剪枝，针对 C2f-Focus

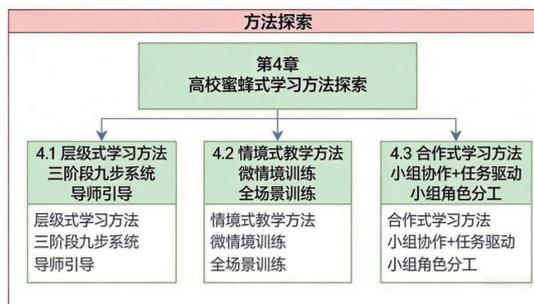


图 1 检测流程及替换模块示意图

模块与卷积层，计算各特征通道的权重 L1 范数，剔除权重值低于阈值的冗余特征通道，其阈值的设定通常为所有通道权重均值的 0.3 倍，剪枝率控制在 40% 左右。剪枝后通过小学习率 ($1e-5$) 微调 20 个 epoch，恢复模型特征提取能力。第三步，将 FP32 精度模型转换为 INT8 精度，采用 500 张路面病害图作为校准数据，此数据集应尽量涵盖不同光照、路况的场景，使模型存储体积降低 75%，进而端侧推理速度可提升 2-3 倍。最后一步通过知识蒸馏弥补缺量化带来的精度损失，以未轻量化的高精度基线模型作为教师模型，轻量化模型作为学生模型，结合硬蒸馏与软蒸馏，损失函数为公式 (1.6)：

通过混合损失函数指导学生模型训练，使精度损失控制在 1%-2%，兼顾精度与轻量化。其总体检测流程图及优化模块示意如图 1 所示。

4 工程案例分析

4.1 实验环境与过程

为验证优化方案的工程实用性，某科技公司推出道路表观病害智慧检测系统，将其应用于某市政道路病害检测工程。该工程所负责的市区涵盖 30 条主次干道，总长度达 85 公里，要求实现裂缝、坑槽、剥落、沉陷 4 类病害的实时检测。部署设备选用 Nvidia Jetson Nano

边缘检测盒，推理速度可达到 30FPS 以上，检测精度 $mAP@0.5$ 不低于 85%，且能适应车速 20-30km/h 的车载移动检测场景。

工程实施过程中，首先是构建工程专用的数据集。采集该市区不同路段、不同光照、不同路面条件的病害图像 8000 张，采用 COCO 格式进行人工手动标注，划分训练集 6400 张、验证集 800 张、测试集 800 张，小目标病害占比 68%，补充约 15% 的雨天、夜间拍摄的模糊图像，提升数据集的工程适配性。其次，基于 Ultralytics 框架实现优化方案的代码部署与模型训练。硬件环境采用 Intel Core i7-12700K 搭配 NVIDIA RTX 3090，训练 epochs 设置为 100，批量大小为 32，并采用迁移学习的方法来提升训练效率。模型训练完成后，导出为 TensorRT 引擎，部署至车载边缘检测盒，搭配 1080P 高清摄像头，实现移动检测与实时反馈。

4.2 实验结果与结论

工程测试结果显示，优化后的 YOLOv8 模型在测试集上的 $mAP@0.5$ 达到 87.3%，较原生 YOLOv8n 模型提升 9.1%，其中微裂缝检测召回率提升 16.4%，漏检率从 18.7% 降至 5.2%，显著提升了检测精度，有效的解决了小目标病害漏检问题；参数量从 3.2M 降至 1.1M，降低 65.6%，计算量从 8.7GFlops 降至 2.3GFlops，降低 73.6%；在 Nvidia Jetson Nano 上的推理速度达到 62FPS，远超工程要求的 30FPS，模型体积仅 3.6MB，大大降低了硬件要求和模型体积，以便于在不同门槛硬件平台进行部署。

在实际工程应用中，该系统实现了车载移动检测的实时性，能准确识别不同路面条件下的各类病害。检测所得结果可通过 5G 网络实时传输至养护管理平台，自动标注病害位置、类型与严重程度，为后续养护计划制定提供精准数据支持。对比传统人工检测，该系统将检

测效率提升 6 倍以上，人工成本降低 70%，检测漏检率与误检率均控制在 6% 以内，圆满完成工程检测任务，验证了优化方案的工程实用性与可靠性。

工程应用中发现，优化后的模型在夜间强光反射、路面严重破损（多病害重叠）场景下，检测精度略有下降。后续可通过补充对应场景的训练样本、优化注意力机制的特征聚焦范围，进一步提升模型的工程适配性。本次工程实践表明，所提出的 YOLOv8 优化方案，针对性解决了路面病害检测中小目标漏检、模型笨重、端侧部署困难等工程痛点，兼顾了检测精度与实时性，代码修改量小、易复现、部署友好，可广泛应用于市政道路、高速公路等路面病害的移动检测工程，为公路养护智能化提供技术支撑。同时，本次优化方案与工程案例的落地，也为同类目标检测任务（如桥梁病害、隧道病害检测）的精度与轻量化优化提供了可借鉴的

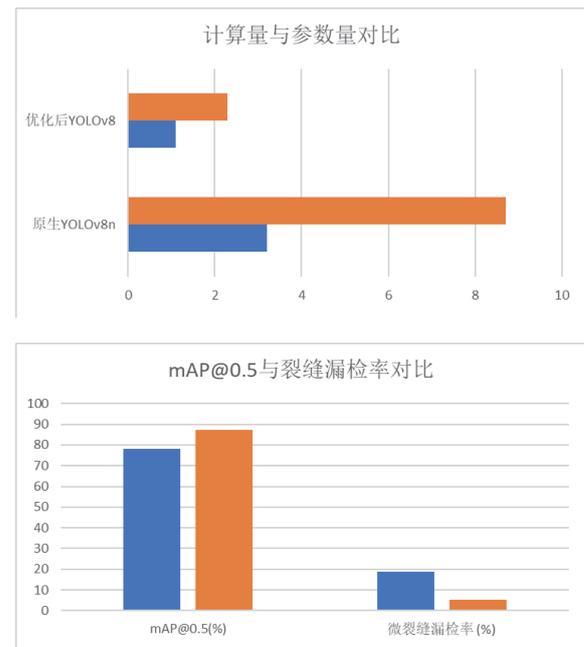


图2 模型优化前后效率对比

思路与经验。模型部分参数对比如图2所示。

5 基于YOLOv8的路面病害检测体系进步点

与人工巡检、传统机器视觉检测相比，基于YOLOv8的检测体系实现了三大突破。效率方面，人工检测单公里约需16小时（基于市政道路人工巡检行业常规效率），而该体系在实验室理想条件下500公里道路数据全流程分析仅需15小时，实际工程场景中效率较人工提升6倍，彻底解决“采集快、处理慢”的行业痛点，大幅缩短养护周期。精度方面，消除了人工主观偏差，实验室标准数据集下识别准确率达96.4%，可捕捉0.2mm细微裂缝，实际工程场景中漏检率与误检率均控制在6%以内，远低于人工检测（漏检率约25%、误检率约18%）。成本方面，单公里检测成本降幅超80%，同时避免了人工巡检的安全风险，尤其适用于高速公路、偏远路段等复杂巡检场景。

相较于YOLO系列其他前序版本，YOLOv8基础模型及优化版本在路面病害检测中展现出四大优势。特征提取能力更强，采用更高效的主干网络与特征融合结构，对路面病害模糊特征、不规则形态的捕捉能力提升，小目标病害检测精度提高2-5个百分点。实时性更优，在同等精度下，YOLOv8推理速度比YOLOv7快10%-15%，经轻量化优化后，边缘设备部署速度进一步提升。泛化能力更好，自适应锚框与损失函数设计，使其在不同路况、天气场景下的鲁棒性更强，无需大量场景适配调整。工程化更便捷，Ultralytics框架提供完整的训练、导出、部署工具链，支持多平台部署，相较于前代算法，开发周期缩短30%以上。

与Faster R-CNN、SSD等其他深度学习算法相比，基于YOLOv8的体系核心优势在于

“精度-速度”均衡性。两阶段算法（如Faster R-CNN）精度略高（mAP@0.5约89%）但速度仅为YOLOv8的1/3（约28FPS），难以满足实时检测需求。SSD等单阶段算法速度较快（约75FPS）但小目标病害检测精度低（mAP@0.5约78%），漏检率较高（约15%）。而YOLOv8通过结构优化，在保持85FPS以上推理速度的同时，mAP@0.5比SSD高8-10个百分点，实现了实时性与精度的协同，更契合路面病害动态检测的实际需求。

6 总结与展望

本文系统阐述了基于YOLOv8的路面病害检测体系的研究进展，现存问题，优化思路，并通过工程化部署案例表明其在理论与工程层面的双重价值。同时，现有研究仍存在一些不足，如小目标病害检测精度不足、极端场景泛化能力有限、轻量化与精度的平衡难题尚未完全解决、工程化融合度低等问题。这些短板限制了该体系在复杂实际场景中的全面应用，需在后续研究中重点突破。

针对以上问题，可大胆展望未来发展的方向，对于细微裂缝、早期松散等小目标病害，可引入超分辨率重建技术，提升病害特征分辨率后再进行检测；融合Transformer架构与YOLOv8，通过Multi-Head Self-Attention机制增强全局特征捕捉能力，解决复杂背景下病害特征被掩盖的问题。针对极端天气场景，可开发自适应光照调整、雨雪噪声去除算法，结合多模态数据融合检测。应加强检测系统与智慧交通平台、道路养护管理系统的深度融合，实现检测数据的实时上传、分析与可视化，构建“检测-评估-养护-反馈”闭环体系。同时，开发标准化的部署流程与接口，提升系统在不同检测设备、不同地区道路场景中的通用性。

参考文献

- [1] 邓天民, 李亚楠, 李庆营, 等. 改进 YOLOv8 的路面病害检测模型 [J]. 重庆理工大学学报 (自然科学), 2024, 38 (4): 138-145.
- [2] 秦海福. 基于 YOLOv8 的公路路面病害检测方法研究 [D]. 广州: 广东工业大学, 2024.
- [3] 侯勇严, 梁扩旺, 郭文强, 等. 基于改进 YOLOv8 的路面病害检测模型 [J]. 陕西科技大学学报, 2024, 43 (3): 166-173.
- [4] 陈旭丹, 姜男, 董丽娜, 等. 基于深度学习 YOLO 模型的高原山区沥青路面病害自动识别 [J]. 道路工程, 2019 (11): 67-70.
- [5] Ultralytics. YOLOv8: Ultralytics Real-Time Object Detection[EB/OL]. 2023.
- [6] 交通运输部. 2024 年交通运输行业发展统计公报 [EB/OL]. 2025-03-20.
- [7] 李建忠, 王强, 刘敏. 基于 YOLOv8 与知识蒸馏的路面病害轻量化检测模型 [J]. 交通运输工程学报, 2024, 24 (2): 187-198.