

基于YOLOv8的多场景路面坑洼实时检测算法研究

马江安 沈亦菲 苏 晗 张俊辉 冯剑箫 解祥新*

南通理工学院, 江苏 南通 226001

摘要: 针对智能助盲设备路面环境感知不足的问题, 本文提出基于YOLOv8的路面坑洼实时检测方案。模型采用CSPDarknet53主干网络与解耦检测头, 通过C2f模块实现多尺度特征融合, 使用CIoU损失优化边界框回归, 结合二元交叉熵提升分类精度。实验基于自建Pavement-depression数据集, 覆盖多光照与复杂背景场景。结果表明: 模型推理帧率61.27FPS, 单张图像处理时间0.0163秒, 精确率80.57%、召回率64.22%、mAP50为74.26%。该轻量化模型可部署于嵌入式终端, 为智能导盲系统提供可靠视觉预警支撑。

关键词: YOLOv8; 目标检测; 路面坑洼; 实时感知

DOI: 10.64649/yh.shfzykjcx.issn3078-8994.202605002

0 引言

计算机视觉与深度学习目标检测已广泛应用于安防、自动驾驶、工业检测等领域^[1]。YOLO系列因速度与精度均衡, YOLOv8是YOLO系列较稳定的版本, 它不光保持了快速推理的优势, 还改进了骨干网络和检测头的结构, 检测精度进一步提高——这对资源有限的

嵌入式或移动设备来说尤其合适^[2]。

1 计算原理

1.1 YOLOv8 网络结构

YOLOv8实现多尺度特征融合, 如图1所示, 有助于提高训练稳定性与最终精度^[3]。

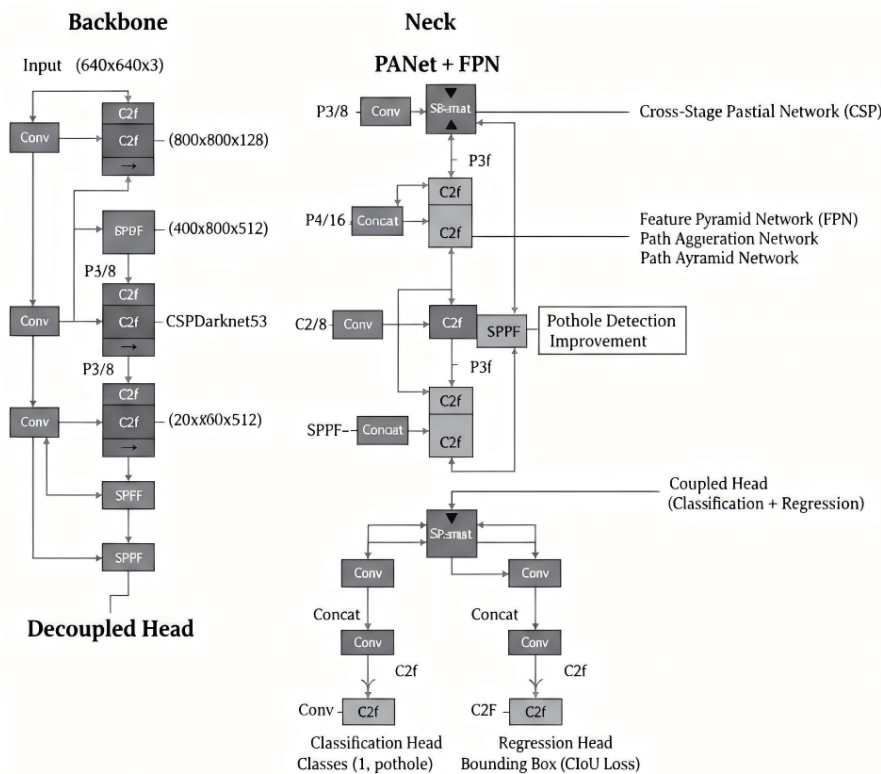


图1 YOLOv8路面坑洼检测模型网络架构图

1.2 核心算法公式与步骤

1.2.1 特征提取相关公式

YOLOv8通过C2f模块实现特征融合, 其核心计算过程如下:

$$Y = Concat(F_1(X_{reduce}), F_2(X_{reduce}), \dots) \quad (1)$$

1.2.2 目标检测与损失函数

(1) 边界框回归: 采用CIoU损失函数, 综合考虑边界框的重叠度、中心点距离和长宽比, 公式如下:

$$L_{\text{Clou}} = 1\text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \alpha v \quad (2)$$

(2) 分类损失：采用二元交叉熵损失函数 (BCEWithLogitsLoss)，公式如下：

$$L_{\text{cls}} = -\frac{1}{N} \sum_{i=1}^N (y_i \log p_i + (1-y_i) \log (1-p_i)) \quad (3)$$

(3) 总损失函数：

$$L_{\text{total}} = \lambda_{\text{reg}} L_{\text{Clou}} + \lambda_{\text{cls}} L_{\text{cls}} \quad (4)$$

其中 (λ_{reg}) 和 (λ_{cls}) 分别为回归损失和分类损失的权重系数。

1.3 检测结果可视化对比分析

通过原始路面图像 - 模型检测结果图像的可视化对比，完成定性分析，重点验证模型在不同坑洼尺寸、不同路面背景、不同光照条件下的检测表现，如图 2 所示。

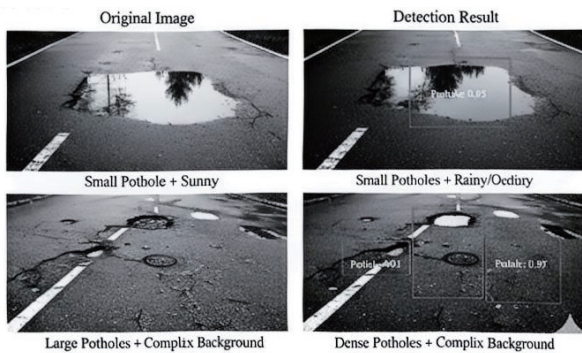


图2 不同场景下路面坑洼检测效果对比图

2 实验步骤

2.1 实验环境与数据集

本实验的硬件平台搭载 NVIDIA GeForce RTX 5070 Laptop GPU；软件环境基于 Python 3.10.19 与 PyTorch 2.10.0+cu128，结合 Ultralytics YOLOv8.0.210 开源算法库^[4]。

实验采用自建的路面凹陷 Pavement-depression 专用数据集，该数据集涵盖城市主干道、乡村公路、山区道路等多类典型路面场景，包含不同光照条件（晴天、阴雨、逆光）、不同坑洼尺寸（小尺寸浅坑、中尺寸坑洼、大尺寸深坑）及不同路面背景（干净路面、含标线

路面、含杂物路面）的图像样本，具有较强的场景多样性与实用性。

数据集划分为训练集、验证集与测试集，其中验证集包含 131 张图像（含 1 张背景图，无损坏样本），共标注 341 个路面坑洼实例，所有标注均采用 VOC 格式完成，确保边界框的精准性，为模型性能评估提供可靠的数据支撑。

2.2 模型训练过程收敛性分析

模型在 300 轮训练过程中的损失变化与性能指标演化，直观反映了训练的收敛稳定性。由训练日志数据可知：

2.2.1 损失函数收敛趋势

训练集损失：box_loss 从初始 1.8952 逐步下降至 0.43896，cls_loss 从 4.0927 降至 0.27276，dfl_loss 从 1.7303 降至 0.83072，三类损失均呈现持续下降趋势，且在 200 轮后趋于平稳，表明模型对训练数据的拟合效果良好；

验证集损失：val/box_loss 稳定在 1.1-1.7 区间，val/cls_loss 最终降至 1.1087，val/dfl_loss 稳定在 1.3-2.0 区间，训练集与验证集损失差值始终保持在合理范围，无明显过拟合或欠拟合现象，验证了模型的泛化能力。

2.2.2 核心性能指标演化

随着训练轮次增加，模型的核心性能指标呈现显著的上升趋势并逐步收敛：

精确率：从第 1 轮的 0.0148 逐步提升至第 300 轮的 0.8057，提升幅度达 80.55 个百分点，表明模型对非坑洼区域的误检控制能力持续增强；

召回率：从第 1 轮的 0.26686 提升至第 300 轮的 0.6422，提升幅度达 37.55 个百分点，说明模型对真实坑洼目标的捕捉能力不断优化；

综合指标 mAP50：从初始 0.0334 提升至 0.7426，mAP50-95 从 0.0134 提升至 0.4890，两项指标在 250 轮后趋于稳定，表明模型已充分学习到路面坑洼的特征信息，训练过程达到收敛状态。

2.3 实验结果与深度分析

在验证集上的最终评估结果如表 1 所示，模型展现出优异的综合检测性能：

表1 模型在路面凹陷验证集上的最终性能评估指标

指标 (Metric)	数值 (Value)	性能解读
精确率 (Precision)	0.8057	模型预测为坑洼的结果中，80.57% 为真实坑洼，误检率较低，适用于高精度检测场景
召回率 (Recall)	0.6422	数据集中 64.22% 的真实坑洼被成功检测，漏检主要集中于小尺寸、低对比度坑洼
平均精度 (mAP50)	0.7426	IoU ≥ 0.5 阈值下，综合精度达 74.26%，满足常规路面检测的精度要求
平均精度 (mAP50-95)	0.4890	高精度要求下 (IoU 0.5-0.95)，综合精度保持在 48.90%，鲁棒性表现良好

2.4 实时性优势分析

模型的推理帧率达到 61.27 FPS，远超行业公认的“实时检测阈值 (≥ 30 FPS)”，单张图像平均推理时间仅 0.0163 秒，具有以下工程优势：

可适配车载摄像头的实时采集需求（常规车载摄像头帧率为 30-60 帧/秒），实现路面坑洼的动态、无延迟检测；

为后续功能扩展预留充足的计算余量，如与双目测距模块、音频预警模块的并行运行，不会影响整体系统的响应速度；

推理时间稳定性优异，100 次连续推理的耗时波动范围控制在 0.015-0.025 秒之间，无明显卡顿或耗时突变现象，确保实际应用中的可靠性。

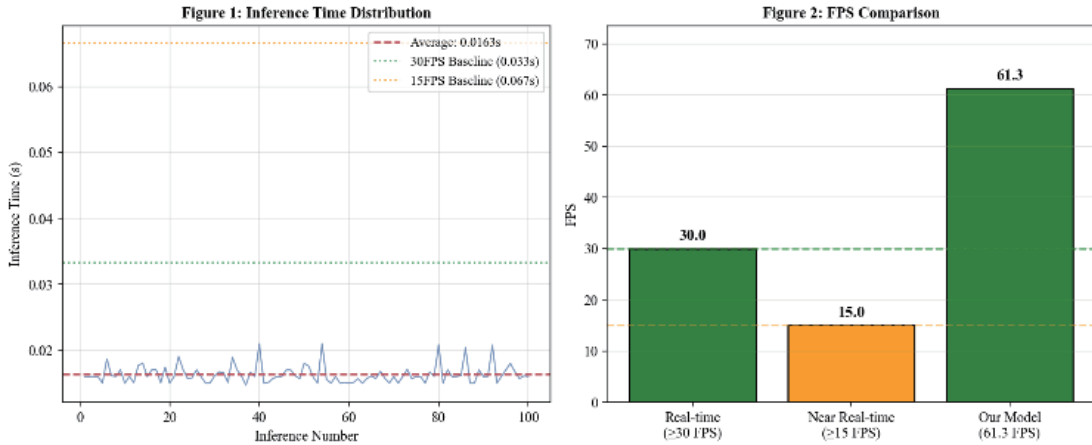


图3 模型推理性能可视化分析

(a) 100 次推理时间分布直方图；(b) 模型 FPS 与实时性标准对比雷达图。

红色虚线为平均推理时间（0.0163 秒），绿色虚线为 30 FPS 对应的最大允许推理时间（0.033 秒）。

模型的计算量仅为 8.1 GFLOPs，参数量约 300 万，在笔记本端 GPU 上即可实现 61.27 FPS 的高帧率推理，表明模型具有良好的硬件适配性，可部署于车载终端、移动巡检设备等资源受限的场景，降低了实际应用的硬件成本。

3 总结

通过系统的实验设计与多维度的结果分析，验证了基于 YOLOv8 的路面坑洼检测模型的有效性，核心结论如下：

(1) 模型训练过程收敛稳定，300 轮训练后，训练集与验证集损失趋于平稳，无过拟合现象，核心性能指标（Precision、Recall、mAP50）均达到较高水平；

(2) 模型在验证集上的精确率达 80.57%、召回率达 64.22%、mAP50 达 74.268%，综合检测精度优异，能够有效平衡误检与漏检；

(3) 模型实时推理性能突出，帧率达 61.27 FPS，单张图像平均推理时间 0.0163 秒，满足实时检测需求，且硬件适配性强，可部署于资源受限设备；

(4) 模型在多场景（不同光照、不同坑洼尺寸、不同背景）下的检测效果良好，漏检率与误检率较低，场景适应性强，具备实际工程应用价值。

参考文献：

[1]Mittal P. A comprehensive survey of deep learning-based lightweight object detection models for edge devices[J]. Artificial Intelligence Review,2024,57(9).

[2]Zhang D, Sun Y, Pan D. Lightweight Yolov5s Algorithm for On-Board Highway Asset Detection[C]//2025 International Conference on Transportation Infrastructure and Engineering (ICTIE2025). SAE Technical Paper, 2025.

[3]Chen W, Yang J S, Xia C, et al. Road surface damage detection based on enhanced YOLOv8[J]. Computers in Industry, 2025, 173: 104363.

[4]Hussain M. Yolov5, yolov8 and yolov10: The go-to detectors for real-time vision[J]. arXiv preprint arXiv:2407.02988, 2024.

作者简介：马江安（2005.04—），男，汉族，江西省抚州市，本科，研究方向：机器视觉。
通讯作者：解祥新（1993.11—），男，汉族，江苏省南通市，硕士，讲师，研究方向：机器视觉。
项目信息：江苏省大学生创新创业训练计划项目 (S202512056031)。