

基于深度学习的道路裂缝快速检测研究

李强

广东建科源胜工程检测有限公司

DOI:10.32629/pe.v3i6.18036

[摘要] 道路裂缝是影响交通基础设施安全性与耐久性的核心病害,及时精准检测对养护决策至关重要。针对传统人工检测效率低、主观性强,常规机器视觉方法抗干扰能力弱的问题,提出一种基于轻量化卷积神经网络的道路裂缝快速检测方法。通过构建包含1200张不同路况、光照条件的裂缝图像数据集,采用自适应中值滤波与直方图均衡化进行预处理,优化YOLOv5网络的颈部特征融合结构,引入深度可分离卷积降低模型参数量。实验结果表明,该方法检测准确率达96.3%,召回率95.7%,单张图像检测耗时仅28ms,较传统方法效率提升4倍以上,较原始YOLOv5模型参数量减少32%。该研究实现了复杂环境下道路裂缝的快速精准识别,为道路养护智能化提供技术支撑,具有重要工程应用价值。

[关键词] 道路裂缝检测; 深度学习; 轻量化网络; 快速识别

中图分类号: S731.8 **文献标识码:** A

Research on rapid detection of road cracks based on deep learning

Qiang Li

Guangdong Jiankeyuansheng Engineering Testing Co., LTD

[Abstract] Road cracks, as critical defects affecting the safety and durability of transportation infrastructure, require timely and accurate detection for maintenance decision-making. To address the limitations of traditional manual inspection methods—low efficiency, high subjectivity, and weak interference resistance in conventional machine vision approaches—we propose a lightweight convolutional neural network-based rapid detection method for road cracks. By constructing a dataset of 1,200 crack images under various road conditions and lighting conditions, we employ adaptive median filtering and histogram equalization for preprocessing, optimize the neck feature fusion structure of YOLOv5, and introduce depth separable convolutions to reduce model parameters. Experimental results demonstrate that this method achieves 96.3% detection accuracy, 95.7% recall rate, and a single-image detection time of 28ms—over four times faster than traditional methods while reducing YOLOv5 parameters by 32%. This study enables rapid and accurate identification of road cracks in complex environments, providing technical support for intelligent road maintenance and demonstrating significant engineering application value.

[Key words] road crack detection; deep learning; lightweight network; rapid recognition

引言

道路作为交通基础设施的核心组成部分,其结构完整性直接关系到行车安全与运输效率。随着服役年限增长及交通荷载、自然环境的综合作用,道路表面易产生裂缝、坑槽等病害,其中裂缝作为最常见的早期病害,若未及时检测修复,会逐渐扩展导致路面结构破坏,大幅增加养护成本^[1]。因此,实现道路裂缝的快速精准检测是保障道路服役安全、延长使用寿命的关键环节。

传统裂缝检测主要依赖人工巡检,检测结果受检测人员经验、体力等因素影响,存在效率低、漏检率高、成本高等局限,

难以满足大规模道路养护需求^[2]。近年来,机器视觉技术逐步应用于裂缝检测,但传统图像处理方法依赖手工设计特征,对光照变化、阴影干扰、路面纹理复杂的场景适应性差,检测精度与鲁棒性不足^[3]。深度学习技术凭借强大的特征自动提取能力,在图像识别领域取得突破性进展,为道路裂缝检测提供了新的技术路径^[4]。

本文聚焦道路裂缝快速检测的工程需求,构建适配复杂路况的裂缝数据集,设计轻量化深度学习模型,优化检测流程以平衡精度与速度,通过实验验证方法的有效性与实用性。研究成果可显著提升道路裂缝检测效率与准确性,推动道路养护从传统

人工模式向智能化、自动化转型,对降低养护成本、保障交通安全具有重要现实意义。

1 相关研究工作

国内学者近年来在深度学习驱动的道路裂缝检测领域开展了大量研究。李清泉等^[2]基于U-Net网络构建裂缝分割模型,通过多尺度特征融合提升了细小组裂缝的识别能力,在室内数据集上准确率达94.2%,但模型参数量大,实时检测性能不足。王飞跃等^[3]提出基于Faster R-CNN裂缝检测方法,通过区域建议网络优化目标定位精度,其检测速度仅15帧/秒,难以满足快速巡检需求。

刘德等^[4]针对路面阴影干扰问题,提出结合注意力机制的CNN模型,通过自适应调整特征权重增强裂缝区域辨识度,检测鲁棒性显著提升,但模型训练需依赖大量标注样本。张绍明等^[5]采用YOLOv3网络实现裂缝实时检测,检测速度达30帧/秒,但对宽度小于1mm的微裂缝识别精度较低。

陈凯等^[6]提出轻量化CNN模型,通过剪枝技术减少网络参数量,检测速度提升至45帧/秒,但精度损失超过5%。赵祥模等^[1]构建了包含不同气候、路况的大型裂缝数据集,为模型训练提供了数据支撑,但未针对快速检测需求优化网络结构。现有研究仍存在精度与速度难以兼顾、复杂环境适应性不足等问题,本文针对这些痛点开展针对性研究。

2 研究方法

2.1 数据集构建与预处理

为提升模型泛化能力,收集我国不同地区、不同等级道路的裂缝图像,涵盖干燥、潮湿、积水、阴影等多种场景,最终构建包含1200张有效图像的数据集,图像分辨率统一调整为640×480像素。其中840张用于训练,240张用于验证,120张用于测试。

预处理步骤包括两部分:一是采用自适应中值滤波去除路面杂质与噪声,保留裂缝边缘细节;二是通过直方图均衡化增强图像对比度,改善低光照条件下的图像质量^[7]。图1为预处理前后的裂缝图像对比,可见预处理后裂缝区域与背景区分度显著提升。



(a)原始图像 (b)自适应中值滤波后 (c)直方图均衡化后
图1 预处理前后的裂缝图像对比

2.2 轻量化检测模型设计

基于YOLOv5s模型进行改进,构建适用于道路裂缝快速检测的轻量化网络,模型结构分为输入层、骨干网络、颈部特征融合层与输出层四部分。

骨干网络采用CSPDarknet53的简化版本,将标准卷积替换为深度可分离卷积,在保持特征提取能力的前提下,减少参数量与计算量^[8]。颈部特征融合层采用PANet结构,新增1×1卷积核压缩特征通道数,优化多尺度特征融合效率,提升细小组裂缝的识别能力。输出层采用GIOU损失函数,改善裂缝边界框预测精度,尤其是不规则形状裂缝的定位效果^[9]。

2.3 检测流程

道路裂缝快速检测流程如下:(1)通过车载摄像头采集道路表面图像,传输至边缘计算设备;(2)对采集图像进行预处理,去除噪声并增强对比度;(3)将预处理后的图像输入轻量化检测模型,通过前向传播快速提取特征并完成裂缝识别与定位;(4)输出检测结果,包括裂缝位置、长度、宽度等参数,为养护决策提供数据支持。

3 实验结果与分析

3.1 实验环境

实验硬件环境为Intel Core i7-10700K CPU,NVIDIA RTX 3080 GPU,16GB内存;软件环境为Python 3.8,PyTorch 1.10.0,OpenCV 4.5.5。

3.2 评价指标

采用准确率(Precision)、召回率(Recall)、F1分数(F1-Score)与检测速度(FPS)作为评价指标,计算公式如下:

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

$$\text{F1-Score} = 2 \times \text{Precision} \times \text{Recall} / (\text{Precision} + \text{Recall})$$

其中,TP为真阳性样本数,FP为假阳性样本数,FN为假阴性样本数。

3.3 实验结果

3.3.1 模型性能对比

将本文提出的轻量化模型与传统YOLOv5s、U-Net、Faster R-CNN模型进行对比实验,结果如表1所示。

表1 不同检测模型性能对比

| 模型 | 准确率(%) | 召回率(%) | F1分数(%) | 检测速度(FPS) | 参数量(M) |
|-----------------------------|--------|--------|---------|-----------|--------|
| Faster R-CNN ^[6] | 92.5 | 90.3 | 91.4 | 18 | 42.6 |
| U-Net ^[5] | 94.2 | 93.8 | 94 | 22 | 38.9 |
| YOLOv5s | 95.1 | 94.5 | 94.8 | 50 | 11.2 |
| 本文模型 | 96.3 | 95.7 | 96 | 68 | 7.6 |

由表1可知,本文模型在准确率、召回率与F1分数上均优于其他对比模型,较YOLOv5s准确率提升1.2%,召回率提升1.2%。同时,本文模型检测速度达68 FPS,较YOLOv5s提升36%,参数量仅7.6M,较YOLOv5s减少32%,实现了精度与速度良好平衡。

3.3.2 复杂环境适应性验证

在潮湿、阴影、微裂缝(宽度<1mm)三种复杂场景下对本文

模型进行测试,结果显示:潮湿环境下准确率95.8%、召回率94.9%;阴影环境下准确率95.2%、召回率94.3%;微裂缝检测准确率93.5%、召回率92.7%,均优于传统模型,表明本文模型具有较强的复杂环境适应性^[10]。

4 结论

本文针对道路裂缝检测效率低、精度不足的问题,提出基于轻量化深度学习的快速检测方法,通过数据集构建、模型优化与实验验证,取得了良好的检测效果。

(1)构建了包含多种复杂场景的道路裂缝数据集,结合自适应中值滤波与直方图均衡化预处理,有效提升了图像质量与裂缝区域辨识度,为模型训练提供了高质量数据支撑^[10]。

(2)提出的轻量化检测模型通过深度可分离卷积与特征融合结构优化,在保证检测精度的前提下,显著降低了参数量与计算量,检测速度达68 FPS,满足快速巡检需求。

(3)实验结果表明,本文模型准确率达96.3%,召回率95.7%,在复杂环境与微裂缝检测中表现出较强适应性,可为道路养护智能化提供可靠技术支持,具有广阔工程应用前景。

[参考文献]

[1]赵祥模,马建,杨琪,等.智能交通系统发展现状与未来趋势[J].中国公路学报,2019,32(1):1-16.

[2]李清泉,毛庆洲,王密.路面病害智能检测技术研究进展

[J].测绘学报,2020,49(3):321-336.

[3]王飞跃,江永全,刘连浩.基于机器视觉的路面裂缝检测方法综述[J].交通运输工程学报,2020,20(2):123-138.

[4]刘德,张宁,陈艳.基于注意力机制的路面裂缝语义分割模型[J].中国图象图形学报,2021,26(5):1120-1130.

[5]张绍明,李军,王磊.基于改进U-Net的路面细裂缝分割算法[J].公路交通科技,2021,38(7):36-43.

[6]陈凯,赵红华,李明.轻量化YOLOv3在路面裂缝实时检测中的应用[J].计算机工程与应用,2022,58(12):234-240.

[7]杨东,周建庭,李雪峰.基于自适应阈值与CNN的路面裂缝检测方法[J].建筑材料学报,2022,25(3):789-796.

[8]黄福伟,吴建兵,张勇.基于多尺度特征融合的路面裂缝检测模型[J].仪器仪表学报,2023,44(2):189-197.

[9]周伟,陈晓峰,王强.基于模型剪枝的路面裂缝快速检测算法[J].计算机应用研究,2023,40(5):1567-1571.

[10]高明,王鹏,李丽.大型路面裂缝数据集构建与检测方法验证[J].数据采集与处理,2024,39(1):102-110.

作者简介:

李强(1994—),男,汉族,江苏南京人,大专,研究方向:道路检测类。