

基于 YOLO 轻量化设计的半刚性基层沥青路面内部松散病害识别算法研究

徐子淇¹ 李灿²

1.金华市公路港航与运输管理中心, 浙江 金华 321000

2.河海大学土木院, 江苏 南京 210024

[摘要]针对三维探地雷达检测沥青路面内部松散病害诊断效率低、人工成本高的问题, 本文提出一种轻量化识别方法。采用 Faster_block 轻量级主干网络替换 CSPDarknet53, 提升训练与推理速度; 设计 SPPFCSPC 模块, 强化特征表达能力并扩大感受野; 在颈部网络嵌入 C3 融合 CBAM 注意力机制, 适配复杂场景关键特征提取。实验表明: 相较原算法, mAP@0.5 提升 6.7%, 计算量降低 38.3%, 检测速度可达 128.2FPS; 对比 YOLOv8 系列模型, 精度最高提升 28.7%, 可同步满足路面病害识别的精度与实时检测需求。

[关键词]半刚性沥青路面; 内部松散病害; 智能识别算法; YOLOv5 优化; 轻量化设计

DOI: 10.33142/sca.v9i4.19558

中图分类号: U418.6

文献标识码: A

Research on the Algorithm for Identifying Internal Loose Diseases in Semi-rigid Base Asphalt Pavement Based on YOLO Lightweight Design

XU Ziqi¹, LI Can²

1. Jinhua Highway Port and Transportation Management Center, Jinhua, Zhejiang, 321000, China

2. College of Civil and Transportation Engineering, Hohai University, Nanjing, Jiangsu, 210024, China

Abstract: In response to the problems of low efficiency and high labor cost in the diagnosis of internal loose diseases in asphalt pavement using 3D ground penetrating radar, this paper proposes a lightweight recognition method, which replaces CSPDarknet53 with a Faster_block lightweight backbone network to improve training and inference speed; Design SPPFCSPC module to enhance feature expression ability and expand receptive field; Embedding C3 fusion CBAM attention mechanism into the neck network to adapt to complex scene key feature extraction. Experiments have shown that compared to the original algorithm, mAP@0.5 Improved by 6.7%, reduced computation by 38.3%, and achieved a detection speed of 128.2FPS; Compared with the YOLOv8 series models, the highest accuracy improvement is 28.7%, which can simultaneously meet the accuracy and real-time detection requirements of road disease recognition.

Keywords: semi-rigid asphalt pavement; internal loose diseases; intelligent recognition algorithm; YOLOv5 optimization; lightweight design

引言

截至 2024 年底,我国公路里程超 549 万公里,超 60% 公路接近或超出设计年限,路面内部松散、层间粘结不良等结构性病害频发,威胁道路安全。三维探地雷达^[1]可无损检测路面内部缺陷,但数据解析依赖人工,存在效率低、误检漏检率高、主观差异大^[2]等问题。深度学习目标检测模型为病害自动化识别提供了新思路, YOLO 系列因速度优势被广泛应用于路面病害检测,但现有模型对松散病害弱振幅、弥散散射的雷达特征提取能力不足,精度与速度难以平衡。为此,本文基于 YOLOv5m 开展轻量化改进,优化主干网络、池化结构与注意力机制,构建适配松

散病害特征的检测算法,实现高精度、高效率的路面内部病害智能识别。

1 路面内部松散病害的特征分析

路面内部松散病害表现为路面内部层间粘结不良,且该类病害具备较大的面积尺寸,属于路面内部典型的结构性缺陷;探地雷达检测时,其发射的电磁波传播至该类病害区域时,因病害位置的介电常数发生变化,电磁波会在该位置发生反射并被接收天线所接收,这一传播规律反映在雷达剖面图上,便呈现出同相轴明显不连续的核心特征,同时还会伴随较多轻微的双曲线特征。然而,由于路面内部松散病害其内部会存在一定程度的碎石,其雷达响应不

仅包括同向轴的不连续,更突出表现为在病害区域内出现较多离散、弱振幅的双曲线散射点,这些散射点分布相对弥散,整体高亮区域反射强度提升较低,且纹理杂乱,常伴有信号多次反射现象。本文所用数据集由天线主频为1500MHz的地面耦合式三维阵列探地雷达采集,此雷达系统采用MIMO架构,雷达主机、阵列天线高密度一体集成设计,针对道路内部缺陷,实现厘米级高密度采样。

2 基于松散特征的YOLOv5算法优化

2.1 YOLOv5算法

YOLOv5算法识别内部松散病害的核心问题在于松散病害的雷达特征是弱对比度、低信噪比,无明显的“强边缘”,特征形态是离散、弥散的双曲线散射点,而非连

续轮廓,YOLOv5的CSPDarknet53标准卷积对这类特征提取能力极弱,易将散射点误判为噪声,导致漏检率高、定位不准、鲁棒性差,且无法满足工程所需的量化需求。

2.2 YOLOv5算法优化

为适配松散病害弱振幅、弥散散射的雷达特征,满足快速检测与抗干扰需求,本文对YOLOv5m进行三项核心改进:用Faster_block替换主干网络提升弱特征提取效率;引入SPPFCSPC强化多尺度特征融合;在颈部网络嵌入C3-CBAM注意力机制抑制背景干扰,全面提升模型检测精度与鲁棒性。本文设计的模型网络结构如图1所示。

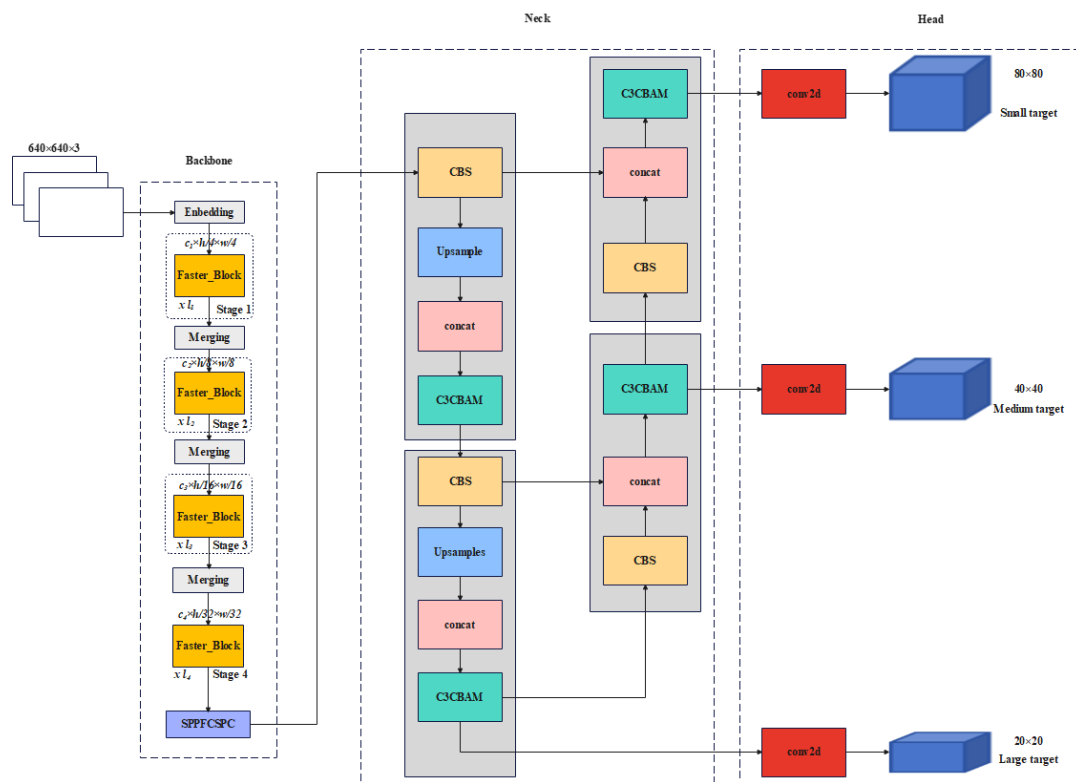


图1 改进YOLOv5模型结构

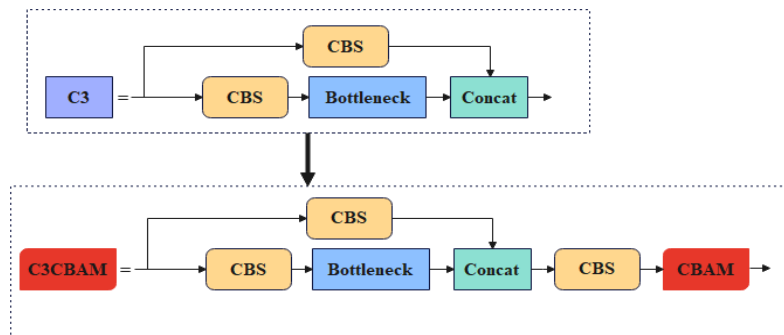


图2 改进C3CBAM的结构图

2.2.1 Faster_block 主干特征网络改进

Faster_block 引入部分卷积 (PConv) 这一新型计算单元, 相较于传统卷积, PConv 在保障有效特征提取的同时, 可跳过冗余计算操作, 在各类硬件平台上运行效率更优。其整体架构包含四个阶段的 Faster_block 块, 块内采用 PConv 层后接两层 PWConv 的结构, 既能保留特征多样性, 又能降低推理延迟。该主干网络兼顾目标检测的速度与精度, 性能优于 CSPDarknet53, 推理速度快, 适配路面病害检测的高实时性要求。凭借更优的特征提取与表达能力, Faster_block 有效提升松散病害检测精度, 模型响应速度更快, 可满足工程检测的高效需求。

2.2.2 空间金字塔池化层改进

YOLOv5 中何等人^[3]引入的 SPP 结构通过多尺寸池化解决了 CNN 处理不同尺寸输入的问题, 可适配不同大小目标并保证输出特征尺寸固定, YOLOv5-6.0 将其改进为串联池化的 SPPF^[4]结构, 在保留原有优势的同时减小模型尺寸、提升处理速度, 而 YOLOv7 则进一步提出 SPPCSPC 结构, 通过增加跨阶段连接枝强化了特征传递效率与网络性能。

本文受此启发, 针对路面内部松散病害的弱振幅双曲线散射点微小且呈弥散分布, 模型难以有效捕捉聚合病害特征, 被漏检的概率较大, 导致检测精度降低的问题, 采用 SPPFCSPC 结构, 串联 3 个 5×5 最大池化, 保持输入和尺寸不变, 降低池化成本, 实现跨阶段特征交互和信息传递, 增强多尺度表示, 提高模型整体的感受野和检测速率。

2.2.3 C3 模块的注意力机制集成方法

为解决路面内部病害定位不准、尺寸难测、不易检测的问题, 本文将 CBAM 集成于 YOLOv5m 的 C3 模块。CBAM 融合通道与空间注意力, 可强化关键通道特征响应、聚焦病害核心区域, 提升特征表征与局部结构感知能力。由于暂无 CBAM 最优嵌入位置的定论, 本文将其嵌入颈部网络, 实现目标与位置特征的通道、空间维度精准学习, 有效提升模型检测性能。改进后如图 2 中红色实线方框所示。

3 实验与分析

3.1 实验参数设置

本文实验部分参数设置如表 1 所示。

表 1 实验参数设置

项目	内容
Imagesize	640×640
Batchsize	16
Epoch	300
Learningrate	0.01
Momentum	0.937

3.2 数据集与增强策略

针对这一病害特征, 本研究基于采集的三维雷达检测结果, 具体分析了松散病害数据特征, 形成了 3200 张高速公路路面结构内部松散病害数据集, 并以 8:1:1 比例分为训练集、测试集和验证集。

3.3 评价指标

本文采用准确率 (P)、召回率 (R)、平均精度 (AP)、平均精度均值 (mAP) 及帧率 (FPS) 作为模型评估指标, 结合混淆矩阵完成性能验证。准确率是正确识别目标数 (TP) 占预测正样本 (TP+FP) 的比例, 召回率是正确识别目标数 (TP) 占实际正样本 (TP+FN) 的比例。AP 为单类别精确率-召回率曲线下面积, 用于衡量单一类别检测性能; mAP 是所有类别 AP 的平均值, 是评估目标检测模型综合检测能力的核心指标, 数值越高代表模型整体性能越优。mAP@0.5 指交并比 (IoU) 阈值为 0.5 时计算的 mAP, 是目标检测领域最常用的精度评价标准。目标检测任务中, mAP 综合考量不同召回率下的精确率, 计算逻辑严谨, 能客观准确地反映模型对路面内部松散病害的识别精度与检测效果。

表 2 混淆矩阵

混淆矩阵		预测值	
		1	0
真实值	1	TP	FN
	0	FP	TN

$$R = \frac{TP}{TP+FN} \quad (1)$$

$$P = \frac{TP}{TP+FP} \quad (2)$$

$$AP = \int_0^1 P(R) \quad (3)$$

$$mAP = \frac{1}{c} \sum_{j=1}^c AP_j \quad (4)$$

式中: AP 表示每个类别的平均准确率; AP_j 表示第 j 类目标的平均准确率; c 表示标记类别总数; mAP 表示所有类别的平均准确度均值。

3.4 实验结果与分析

3.4.1 C3 模块集成 C3CBAM 注意力机制改进的实验分析

为验证 C3 模块集成 CBAM 的有效性, 在 YOLOv5-A (用 Faster_block 替代 CSPDarkNet53) 算法基础上进行了改进, 并命名新算法为 FCC-YOLO, 在保证模型有效性的同时考虑控制模型大小, 本文在 C3 模块的四个特征

维度之前引入了 CBAM,分别命名为 CBAM_X、CBAM_S、CBAM_M 和 CBAM_L,保持其他部分不变。同时将 CBAM 模块替代 YOLOv8 的 C2f 模块,命名为 CBAM_N。以路面结构内部病害数据集作为样本,与 YOLOv5-A 算法进行实验对比。实验对比结果详见表 3。

表 3 融合 CBAM 的验证实验

算法模型	X	S	M	L	mAP@0.5/%
YOLOv5-A					81.6
YOLOv8					80.3
YOLOv8-CBAM_N					79.5
YOLOv5-A-CBAM_X	√				80.4
YOLOv5-A-CBAM_S		√			80.6
YOLOv5-A-CBAM_M			√		80.1
YOLOv5-A-CBAM_L				√	81.9
Yolov5-A-CBAM_XSML	√	√	√	√	82.5

表 3 表明,C3 嵌入 CBAM 的性能提升效果存在维度差异。C3 结合 CBAM_L 时,mAP@0.5 提升 0.3 个百分点;融合 CBAM 四维度时提升 0.9 个百分点,效果最优,其余组合无性能提升。这说明在颈部网络四特征维度前的 C3 模块嵌入 CBAM,可强化模型关键信息捕捉能力,提升复杂场景鲁棒性。对比实验显示,CBAM 替换 YOLOv8 的 C2f 模块会造成精度下降,证明 C3 集成该注意力机制更适配 YOLOv5。为进一步探究,本文将其余三种注意力机制嵌入 C3 模块,基于路面病害数据集开展对比试验,结果如表 4。

从表 4 中可以看出,相较于 YOLOv5-A,SENet、ECA、CA 和 CBAM 的 mAP@0.5 分别变动-3.1%、0.1%、-1.0% 和 1.1%。综合分析,CBAM 因综合关注通道和空间的能力而表现突出,其结合通道和空间关注有助于捕获更丰富

的特征表示,提升模型性能和判别能力,相较于其他注意力机制更出色。

表 4 不同注意力网络的比较结果

算法模型	Weights/10 ⁶	GFLOPs	mAP@0.5/%
Yolov5-A	52.6	34.4	81.6
Yolov5-A-SENet	48.2	29.6	78.5
Yolov5-A-ECA	48.0	29.6	81.7
Yolov5-A-CA	48.2	29.7	80.6
Yolov5-A-CBAM	48.2	29.7	82.5

3.4.2 消融试验

本文改进了 YOLOv5m 模型,使用 Faster_block 替代 CSPDarkNet53 作为骨干特征网络,提出了 YOLOv5-A 算法,改进空间金字塔池化层为 SPPFCSPC,并集成了 C3 模型和 CBAM。为验证有效性,进行了消融实验和与原有 YOLOv5m 算法进行实验对比,将改进算法分为 8 组进行训练,各组采用相同训练参数和环境。改进效果如表 5 所示。

从表 5 中可以看出,原始 YOLOv5m 算法检测效果不佳。通过改进骨干特征网络、空间金字塔池化层和 C3 模块集成 CBAM 注意力机制,mAP@0.5 分别提升了 3.0%、0.6% 和 3.1%,提升明显但仍可改进。将三种改进方法结合,mAP@0.5 提升了 3.9%,模型大小略增,表示能力更强,能更好捕捉复杂特征和模式。同时,GFLOPs 参数量减少近 50%,计算量减少,实现模型轻量化,提高存储和传输效率。

3.4.3 对比实验

在相同数据集下,对多个目标检测模型进行训练,并与本文提出的 FCC-YOLO 进行比较。实验在相同参数下进行,以验证本文改进方法的有效性和优越性,结果如表 6 所示。

表 5 消融实验

Faster_block	SPPFCSPC	C3CBAM	Weights/10 ⁶	GFLOPs	mAP@0.5/%
			41.6	48.2	78.6
√			23.2	22.5	81.6
	√		70.6	59.4	79.2
		√	37.2	43.3	81.7
√	√		52.6	34.4	81.6
√		√	18.8	17.9	79.0
	√	√	66.2	54.8	81.4
√	√	√	48.2	29.7	82.5

表 6 对比实验

算法模型	主干网络	Weights/10 ⁶	GFLOPs	FPS	P/%	R/%	mAP@0.5/%
SSD	VGGNet-16	52.6	183.4	63.1	82.7	73.6	75.6
Faster-R-CNN	ResNet50	83.0	194.3	21.8	81.9	78.3	80.4
YOLOv3	CSPdarknet-19	123	154.6	138.9	55.0	54.5	53.3
YOLOv5n	CSPdarknet-53	3.4	4.2	210.5	73.8	77.2	74.6
YOLOv5s	CSPdarknet-53	14.0	16.0	185.2	68.9	67.6	70.2
YOLOv5x	CSPdarknet-53	172.4	204.7	123.5	75.4	76.9	73.8
YOLOv5l	CSPdarknet-53	92.9	108.3	161.3	86.9	85.6	84.7
YOLOv5m	CSPdarknet-53	41.6	48.2	175.8	82.9	79.2	80.6
YOLOv7	YOLOV7	74.4	105.1	125.1	78.6	77.9	76.8
YOLOv7-tiny-silu	YOLOV7	12.0	13.2	104.6	74.4	73.6	75.5
YOLOv8n	YOLOV8	6.3	8.2	272.8	81.9	79.5	80.8
YOLOv8s	YOLOV8	22.6	28.4	236.5	82.6	80.5	83.6
YOLOv10n ^[5]	YOLOv10	5.8	8.2	435	-	-	80.6
FCC-YOLO	Faster_block	48.2	29.7	200.2	86.9	87.2	87.3

表 6 数据表明, FCC-YOLO 召回率与 mAP@0.5 指标最优, 在路面内部松散病害识别中优势突出。该模型体量适中、计算效率良好, 相较于 SSD、Faster-R-CNN 及多款 YOLO 系列模型, 检测精度和推理速度提升明显, 仅相比 YOLOv5l 计算量与参数量略高。

综上, FCC-YOLO 兼顾轻量化、推理速度与识别精度, 判别能力与可靠性更强。本文改进方案可有效解决路面病害人工识别效率低、成本高、结果偏差大的问题。

3.4.4 网络前后可视化对比

针对改进模块对网络整体性能的影响, 本文对改进前后网络的 map@0.5 进行了分析, 对比图如图 3 所示。

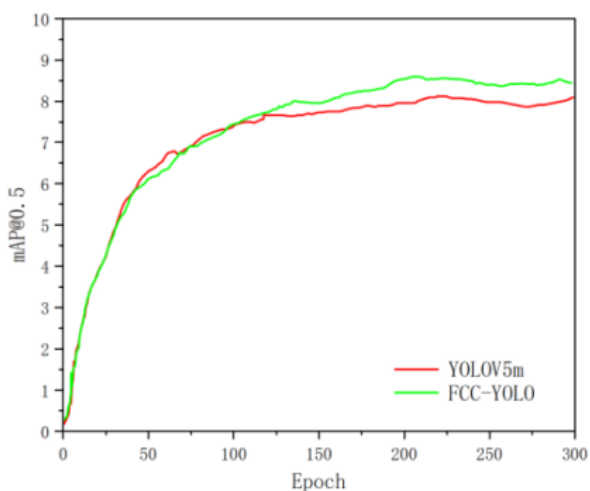


图 3 FCC-YOLO 与原始算法 YOLOv5m 对比图

由图 3 可看出, 改进后 FCC-YOLO 网络在训练 200 轮时趋近平稳并收敛, mAP@0.5 达到最大, 并且在训练

过程中 mAP@0.5 整体高于改进前的 YOLOv5m 网络。

此外, 为验证改进策略的有效性和直观观察改进情况, 将原始 YOLOv5m 算法和 FCC-YOLO 算法在路面内部结构病害数据集上进行测试, 并选取部分结果, 结果如图 4 所示。

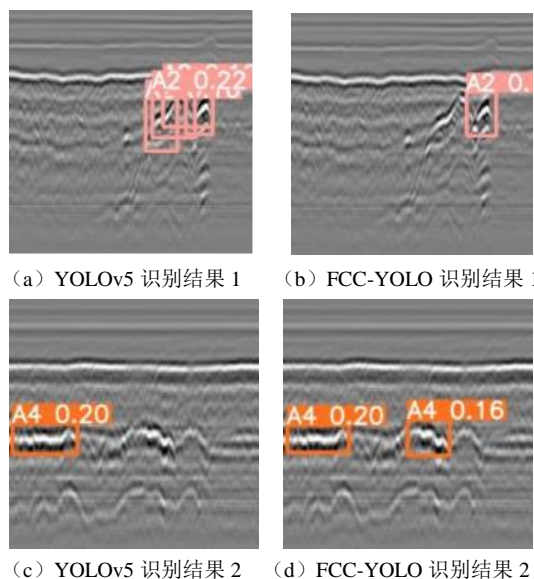


图 4 YOLOv5 优化前后检测结果对比

从图 4 中可以看出, 改进后的网络能够减少检测结果的重复性, 有效过滤更多重叠框, 并能够识别原始 YOLOv5m 未能检测到的结果, 显著降低漏检率。此外, 改进网络模型在检测结果的置信度上也有所提升。综合多项检测数据分析, 改进后的 FCC-YOLO 模型在精确检测和识别路面结构内部病害方面, 较原 YOLOv5m 模型有了显著的进步。

4 结论

本文基于三维探地雷达路面内部松散病害数据,提出改进 YOLOv5m 的 FCC-YOLO 检测算法,经模型对比与工程取芯验证,主要结论如下:

(1) 以 Faster_block 替换 CSPDarknet53 主干网络,大幅提升弱特征表达与感受野覆盖,模型更轻量、推理更快。FCC-YOLO 的 mAP@0.5 显著高于原始 YOLOv5m,检测速度达 200.2FPS,相较 YOLOv8 系列最高提升 mAP@0.5 达 28.7%,病害识别更准更快。

(2) 引入 SPPFCSPC 特征级联空间卷积池化网络,强化多尺度特征融合与跨阶段信息交互,有效捕捉弥散散射点。模型计算量仅 29.7×10^6 ,较原模型降低 38.3%,感受野与检测速率同步提升。

(3) 在颈部网络 C3 模块嵌入 CBAM 注意力,融合通道与空间注意力,精准聚焦病害区域、抑制背景干扰。相比 SENet、ECA、CA 等机制,CBAM 提升效果最优,模型尺寸与计算量下降,复杂场景鲁棒性更强。

[参考文献]

[1] 李晓华,宋亮,叶伟,等.基于三维探地雷达的沥青路面内

部病害分布特征与养护决策研究[J].中外公路,2025,45(3):221-231.

[2] Sun Ya-zhen, Tang Hai-xiang, Zhang Huai-zhi. Automatic Detection of Pavement Marking Defects in Road Inspection Images Using Deep Learning[J]. Journal of Performance of Constructed Facilities, 2024, 38(2): 04024002.

[3] He Kaiming, Zhang Xiang-yu, Ren Shao-qing, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition[J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 37(9): 1904-1916.

[4] Lu Xing-min, Song Wei. Improved YOLOv5s model for vehicle detection and recognition[C]. Proceedings of the Intelligent Computing Methodologies, 2022: 423-434.

[5] 吐尔逊·买买提,邱建卓,刘健等.基于改进 YOLOv8n 的道路裂缝检测算法[J].科学技术与工程,2025,25(14): 6044-6053.

作者简介:徐子淇(1993—),女,汉族,硕士,浙江金华人,就职于浙江金华市交通工程管理中心,中级工程师,主要研究方向为路面养护工程。