

中文引用格式:赵江平,王欣然,吴立舟.改进YOLOv5s的路面坑槽目标检测模型[J].中国安全科学学报,2025,35(1):67-74.

英文引用格式:ZHAO Jiangping, WANG Xinran, WU Lizhou. Model of pavement pothole target detection with improved YOLOv5s[J]. China Safety Science Journal, 2025, 35(1): 67-74.

改进YOLOv5s的路面坑槽目标检测模型*

赵江平副教授,王欣然,吴立舟

(西安建筑科技大学资源工程学院,陕西西安710055)

中图分类号:X924.3

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2025.01.0619

【摘要】 为提高道路安全巡检工作中路面坑槽隐患的检测效率和自动化水平,降低交通事故发生概率,构建一种基于改进YOLOv5s的路面坑槽隐患智能检测模型。在原YOLOv5s网络中加入自适应空间特征融合(ASFF)模块,将主干网络替换为FasterNet网络,引入轻量通道注意力(ECA)模块;通过消融试验分析改进模块对检测模型性能的影响,验证目标检测效果,并开发交互式可视化检测界面。结果表明:改进后的模型精度、召回率和平均检测精度分别提升了4.1%、9.9%和5.6%。较原网络有较为显著的提升,具有良好的检测效果,能够满足路面坑槽自动化检测的应用需求,提高巡检效率,减少因路面坑槽导致的交通事故。

【关键词】 YOLOv5s; 路面坑槽; 目标检测; 自适应空间特征融合(ASFF); FasterNet

Model of pavement pothole target detection with improved YOLOv5s

ZHAO Jiangping, WANG Xinran, WU Lizhou

(School of Resources Engineering, Xi'an University of Architecture and Technology,
Xi'an Shaanxi 710055, China)

Abstract: To improve the detection efficiency and automation level of detecting road surface pits and grooves in road safety inspection work, reduce the probability of traffic accidents. A road surface pit and groove hazard intelligent detection model based on an improved YOLOv5s was proposed. This method incorporated the ASFF module into the original YOLOv5s network, replaced the backbone network with the FasterNet network, and further introduced the Efficient Channel Attention (ECA) module. Ablation experiments are conducted to analyze the effect of the improved module on performance of the detection model, to verify the target detection effect, and to develop an interactive visualized detection interface. The results show that the improved model accuracy, recall rate, and average detection accuracy have increased by 4.1%, 9.9% and 5.6% respectively. Compared to the original network, the improvement is significant. It demonstrates good detection performance that meets the application requirements for automated detection of road surface pits and grooves, thereby enhancing inspection efficiency and effectively reducing traffic accidents caused by road surface pits and grooves.

Keywords: YOLOv5s; pavement potholes; target detection; adaptive spatial feature fusion(ASFF); FasterNet

0 引言

截至2023年,我国(不含港澳台地区)综合交通路网总里程超过600万km,公路里程总长度达544.1万km,其中18.4万km为高速公路^[1]。随着交通路网的扩张及车辆数量的激增,道路交通安全问题日益突出,不仅给交通管理带来严峻挑战,也严重威胁人们的出行安全。在自然环境和行车荷载的作用下,公路包括高速公路路面会产生不同程度的裂缝、沉陷、坑槽等损伤,路面坑槽是影响道路交通安全的重要因素之一^[2]。因此,及时发现并修复路面坑槽,对保障道路交通安全至关重要。然而,传统的人工巡查检测手段存在误检漏检、耗时费力、数据更新周期长等问题。道路检测车能提高路面检测效率,但因其需要搭载的大型检测传感设备昂贵,导致检测成本高。因此,需要一种轻量化检测设备,并结合现代科技手段,实现路面隐患的自动化巡检。

近年来,YOLO算法^[3]在目标检测领域取得显著成果,相较于其他方法,其在精度和速度上均有较大优势。YOLOv5是在YOLOv3基础上改进的算法,具备更高的准确性、更快的检测速度和较小的计算量,成为路面坑槽检测的理想选择。通过改进YOLOv5算法,可以实现对不同路面病害的检测^[4]和更精确的定位^[5],并有效增强目标检测模型的性能^[6]。但目前研究中改进算法的检测效果仍不理想,未能有效解决路面坑槽目标检测算法中参数多、速度慢、检测准确率低等问题。无人机(Unmanned Aerial Vehicle, UAV)作为一种便携、灵活的飞行设备,广泛用于交通基础设施检测,通常搭载高清相机。钟靖涛^[7]基于无人机技术,采用YOLOv3模型搭建了路面病害检测平台,开展了路面病害识别研究。高明星等^[8]针对目标检测算法在无人机图像中容易出现漏检、误检及重复检测的问题,提出了基于改进YOLOv5-DeepSORT算法的公路路面病害检测方法。由此可见,基于无人机的目标检测算法在路面坑槽隐患识别方面具有显著优势。

笔者针对路面坑槽检测问题,提出一种改进的YOLOv5s网络模型,通过融入自适应空间特征融合(Adaptively Spatial Feature Fusion, ASFF)模块,利用FasterNet替换传统的主干网络,并引入高效通道注意力(Efficient Channel Attention, ECA)模块,提升模型在路面坑槽检测上的适用性;构建路面坑槽检测系统,并通过无人机巡检实际场景,验证系统的可行性和实用性,以提高道路巡检的效率和自动化水平,

及时排除道路安全隐患,有效预防交通事故的发生。

1 路面坑槽隐患分析与技术路线

1.1 路面坑槽隐患分析

道路路面在季节变换和车辆长期反复碾压下,易出现坑槽、车辙等路面病害,若不及时维修,会降低行车舒适性,甚至引发交通事故,其中坑槽影响尤为严重。坑槽的出现具有随机性,位置和大小不断变化,行车中难以被发现。一旦遇到坑槽,轻则车辆轮胎受损,重则发生交通事故,导致人员伤亡和财产损失。针对大坑槽、小坑槽、密集坑槽3种类型的坑槽,部分隐患如图1所示。



图1 路面坑槽病害

Fig. 1 Road pothole damage

坑槽大小、位置和数量会直接影响驾驶员采取哪种躲避措施^[9],由图1路面坑槽可知:大面积坑槽可能导致汽车轮胎甚至整辆汽车陷入其中;遇到小坑槽,车主可能选择不减速直接轧过,但车辆绕行会对其他车道的车流产生干扰,增加危害;密集坑槽频繁引起车辆颠簸,影响行驶稳定性和操控性,可能引发交通事故。

1.2 路面坑槽目标检测系统构建

首先,通过网络搜索及实地调研拍摄,收集路面坑槽图片,并利用labelimg工具标注图片中的坑槽,构建图片数据集。其次,基于YOLOv5s模型,针对性优化检测精度、速度和计算量,提出一种坑槽检测方法,使之更适用于无人机巡检应用场景。基于此,在无人机上架设高清摄像头以覆盖检测区域,并开发交互式系统页面实现计算机图像识别,建立检测系统,检测道路坑槽,并验证其检测精度。系统以直观的方式展现了路面坑槽检测结果,包括坑槽的位置、数量和识别精度,最终实现智能高效的道路巡检,系统构建流程如图2所示。

YOLOv5s算法广泛应用于路面坑槽识别,但存在目标误检、漏检和识别精度低等问题。为提升路面坑槽目标的识别效率,选用YOLOv5s网络框架,并融入ASFF自适应特征融合机制、FasterNet和通道注意力模块优化网络模型,从而提高检测水平。

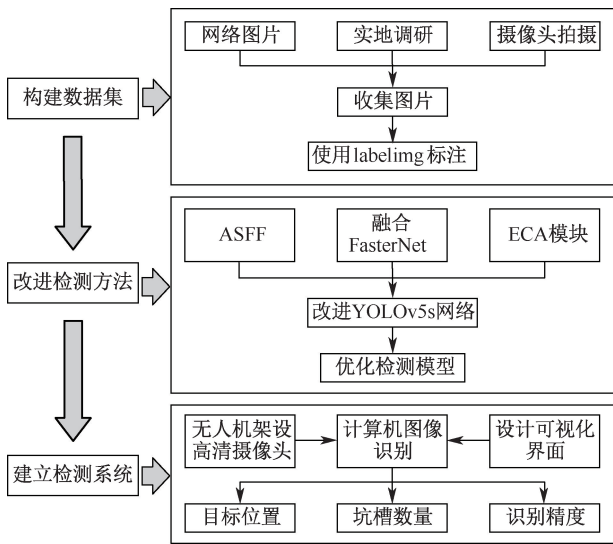


图 2 目标检测系统构建流程

Fig. 2 Detection system construction process

2 YOLOv5s 网络的改进

2.1 ASFF

路面坑槽尺寸变化广泛,小大不一,在复杂路面环境下,光照和遮挡等因素影响坑槽识别,对检测算法构成挑战。YOLOv5s 的特征融合模块,即路径聚合网络(Path Aggregation Network, PAN)用于目标检测,实现了信息的自底向上和自顶向下流动,但在融

合不同层特征时较为简单,未能充分利用各层特征的互补优势。LIU Songtao 等^[10]提出 ASFF 方法,基于数据驱动,自适应地融合不同尺度的特征图,有效捕获和区分不同大小的坑槽,增强多尺度检测能力,并通过学习不同尺度特征图融合的权重,更好地集成和优化特征信息,提高特征的利用效率。合理的模块设计确保性能提升的同时,不会大幅增加计算负担。融入 ASFF 模块旨在通过更高效的特征融合方式,增强模型对新场景的适应性及泛化性能。

2.2 融合 FasterNet

算法的识别速度是其在路面坑槽识别中实用性和有效性的关键。快速识别能力能够确保路面变化的实时检测,并将结果及时报告给管理部门以便修复。这种高效的反馈机制可以提高对突发情况的应对效率,减少因路面坑槽导致的交通事故,保障行车安全和道路畅通。为提升算法的训练效率与检测速度,CHEN Jierun 等^[11]提出一种新的部分卷积,优化由冗余计算引起的参数量问题,增强对空间特征的捕捉能力,并在此基础上提出 FasterNet。研究将主干网络替换为 FasterNet 网络,聚焦于加速推理,确保即时反馈,同时维持高精度,适用于对速度和精度要求高的智能交通应用场景。FasterNet 网络结构如图 3 所示,其中, h, w 分别为特征图的高度和宽度, k 为特征图的卷积核长度, C 为常规卷积通道数。

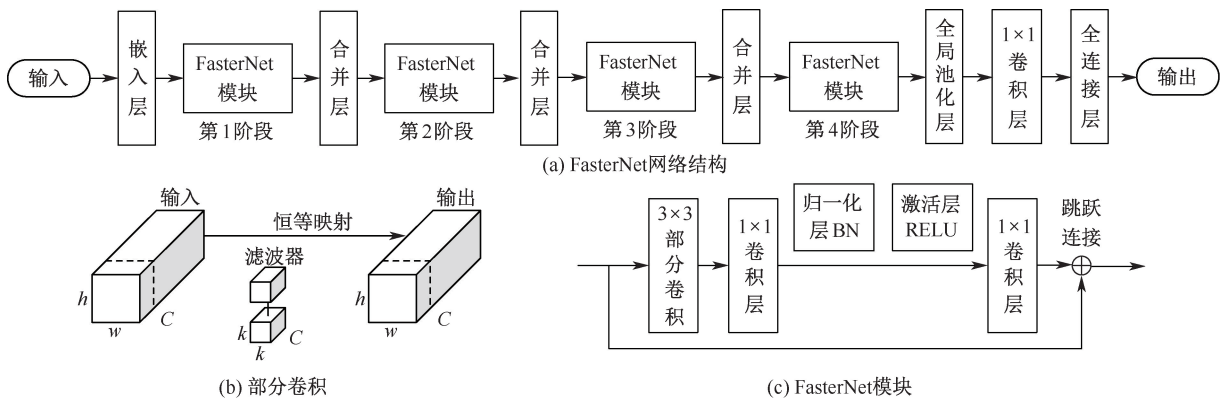


图 3 融合 FasterNet 模块的网络结构

Fig. 3 Network architecture incorporating FasterNet module

FasterNet 通过残差连接与批标准化模块增强模型的特征提取和语义信息捕捉能力,并减少数据传输中的噪声干扰与数据交错频次。网络架构中的嵌入层和合并层用于空间下采样和通道数扩展, FasterNet 模块使输入特征得以循环使用,最后的 3 个层用于特征分类。

2.3 ECA 模块

在道路复杂环境中,阴影、积水、磨损标记等多样化干扰因素可能与坑槽特征混淆。ECA 模块^[12]具有高效和轻量化的特点,参数量比传统卷积神经网络更小,能在不大幅增加计算负担的情况下,使模型在有限资源下高效工作,满足长时间、大面积道路

监测需求。该模块通过强调重要特征通道,忽略无关或干扰信息,提升识别准确性,使改进后的YOLOv5s(图4)在道路复杂场景中的路面坑槽识别表现更优异。

为确保模块识别效果和计算速度,在全局平均池化后,ECA模块捕获每个通道及其相邻通道的局

部跨通道交互信息,避免了降低通道维数。通道维数用 D 表示, n 为一维卷积的核大小,与 D 成正比关系,根据通道维数计算卷积核尺寸:

$$n = \varphi(D) = \left\lfloor \frac{\log_2(D)}{2} + \frac{1}{2} \right\rfloor_{\text{odd}} \quad (1)$$

式中 $\lfloor \cdot \rfloor_{\text{odd}}$ 取最接近的奇数。

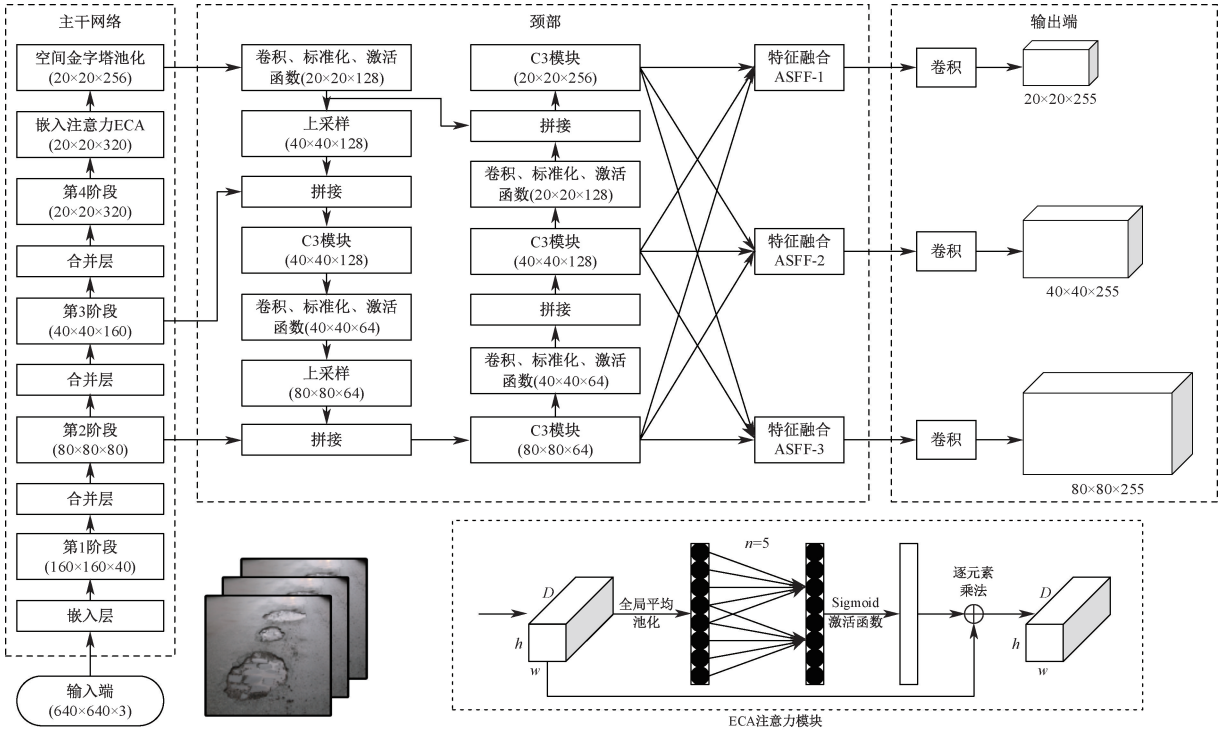


图4 改进后YOLOv5s-AFE网络架构

Fig. 4 Improved YOLOv5s-AFE network structure

3 目标检测模型试验结果与分析

3.1 数据集构建及试验环境

通过网络图库搜索和使用手机、无人机在不同道路拍摄,收集了包含不同角度、不同天气、不同明暗色调、不同清晰程度和不同道路场景的道路图片数据,并且图像中存在裂缝、油污、井盖等其他干扰病害,共收集了2012张图片,涵盖不同大小、形状和深度的坑槽。使用labelimg软件标注坑槽位置,生成.xml格式的文件,并转换图片格式,以便用于YOLOv5网络的训练,随后建立检测数据集。数据集按8:2比例分为训练集和验证集,并进行100轮次拟合试验。

3.2 评价指标

统计分类目标包括正例和反例2类,基于正例和反例的不同组合,样本呈现4种情况:真正例(True Precision, TP)、假正例(False Precision, FP)、真反例(True Negative, TN)、假反例(False Negative,

FN)^[13]。

基于此,计算精确率 P 、召回率 R 、平均精度(Average Precision, AP)和平均精度均值(mean Average Precision, mAP)4个评价指标,以评估模型性能。

$$P = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

$$AP = \int_0^1 P(R) dR \quad (4)$$

$$mAP = \frac{1}{a} \sum_{i=1}^a AP_i \quad (5)$$

式中: a 为隐患类别总数,文中只含一种隐患类别, $a=1$; i 为隐患类别。预测框和真实框分别用 A 、 B 表示,二者的交集与并集之比称为交并比(Intersection over Union, IoU)。

$$IoU = \frac{A \cap B}{A \cup B} \quad (6)$$

3.3 消融试验结果分析

3.3.1 改进模块性能分析

测试改进模块性能,如图5所示。由图5可知:基于原 YOLOv5s 算法框架,分别优化3个关键模块后,经训练集验证,各改进模块均提升了模型的识别精度,且 $mAP@0.5$ (表示 IoU 值为 0.5 时,计算各类别所有图片的加权平均值) 都超过 80%。这一结果证实文中选用的改进点在路面坑槽识别任务上的适用性。总体来看,采用 FasterNet 网络替换原始部件的优化方式最为有效,增强了模型对图像特征的捕捉能力,从而显著提升了平均精度 mAP 均值。

3.3.2 模型消融试验

验证3种改进方式的有效性后,采用消融试验开展分析^[14]。虽然 ASFF 模块的引入对提升平均精度能力表现较差,但其对模型精度的改善效果最好。因此,选择首先在 YOLOv5s 检测算法中增加 ASFF 模块,然后逐步增加改进点,最终将所有改进点融合在一起试验。在相同的试验条件下,6组试

验的结果见表1。为简化改进后模型的名称,在原模型后添加所加入模块的首字母来命名, YOLOv5s-A、YOLOv5s-F、YOLOv5s-E 表示单独加入 ASFF、FasterNet、ECA 模块, YOLOv5s-AF 表示加入 ASFF 和 FasterNet 模块, YOLOv5s-AFE 表示同时加入3个模块。

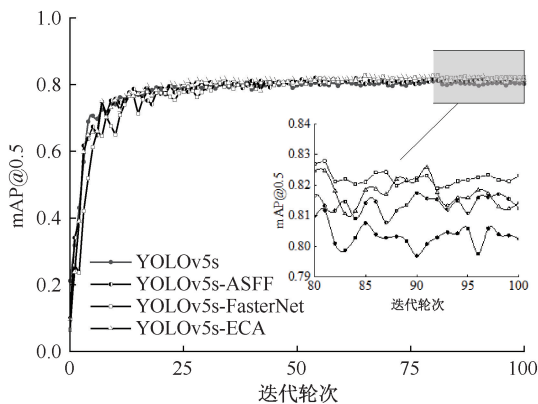


图5 改进模块性能测试

Fig. 5 Improved module performance testing

表1 消融试验结果分析

Table 1 Analysis of ablation experiment results

模型	ASFF	FasterNet	ECA	$P/\%$	$R/\%$	$mAP@0.5/\%$	$mAP@0.5:0.95/\%$	FPS/ (帧·s ⁻¹)	浮点运算量/G	参数量/ MiB
YOLOv5s	—	—	—	85.0	70.7	80.9	52.7	176.8	15.8	7.01
YOLOv5s-A	√	—	—	87.3	72.6	81.6	54.6	149.6	24.2	12.45
YOLOv5s-F	—	√	—	83.8	76.2	82.3	53.3	179.9	13.7	5.99
YOLOv5s-E	—	—	√	83.1	77.6	82.6	54.8	175.5	15.8	7.01
YOLOv5s-AF	√	√	—	86.8	76.3	83.1	57.2	154.8	24.2	12.45
YOLOv5s-AFE	√	√	√	89.1	80.6	86.5	59.5	146.0	22.1	11.42

注:√表示模块被选用加入网络模型,—表示模块未被选用加入网络模型; $mAP@0.5:0.95$ 表示在0.5~0.95内,以0.05为步长的不同IoU阈值下的 mAP ;FPS表示每秒帧数(Frames Per Second)。

由表1中前4组观察试验结果可知:单独引入3种模块后,改进模型的 $mAP@0.5$ 分别提高了0.7%、1.4%和1.7%。FasterNet 模块的增加使模型的FPS值增加3.1帧/s,加快了模型处理图像的速度,并部分补偿了因引入另外2个改进模块而下降的速度。这些数值的增长表明3种改进方式在提高模型识别路面坑槽目标的性能方面都是有效的。

ECA 模块的引入并未改变模型的计算量和参数量,展现了其在增强模型性能和保持良好资源效率的双重特性。相比之下,FasterNet 模块替换原网络部分结构后,模型的计算量和参数量呈现减少趋势,有利于实现模型的轻量化设计。与此相反,ASFF 模块加入后,计算量和参数量有所增长,这是因为在模型的输出端实现了特征的自适应融合。

图6为雷达图,展示了在原 YOLOv5s 模型逐步叠加改进点的过程中,4种改进模型的训练测试结果。根据 P 、 R 、 $mAP@0.5$ 和 $mAP@0.5:0.95$ 分成不同象限,以更明显地评估改进性能的差异。观察结果显示,随着改进点的增加,4个评价指标均呈增长趋势,其中召回率的提升最为显著,达到9.9%。这表明模型识别出的正例数量更接近实际存在的坑槽数量,确保了目标检测的精准度,同时降低了漏检率,实现了提高算法检测水平的试验目的。

3.3.3 改进模型训练结果

经过100轮优化,改进的 YOLOv5s-AFE 模型提取的数据与人工标注的数据高度吻合,表明改进算法在识别训练数据集时具有较强的性能和较高的准确性。图7为改进模型与原模型训练结果对比,由

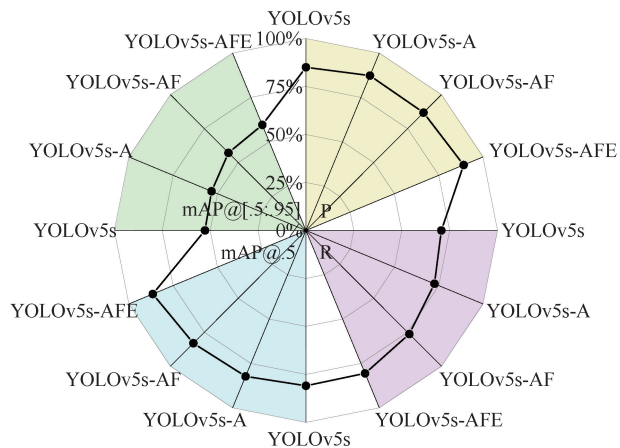


图6 消融试验4个评价指标对比雷达
Fig. 6 Radar chart comparing four evaluation metrics for ablation experiments

图7可知： P 、 R 、 $mAP@0.5$ 和 $mAP@0.5:0.95$ 相较于原模型都有明显提升，且 $mAP@0.5$ 变化曲线在50轮次后趋于平缓稳定，实现了识别精度与召回率之间的平衡。综合分析表明：改进算法模型的综合检测性能相较于原Yolov5s模型有所提升， P 从85.0%增涨到89.1%， R 提升了9.9%， $mAP@0.5$ 提高至86.5%， $mAP@0.5:0.95$ 增加了6.8%，检测精度显著提高，其优异的性能可以满足路面坑槽实时智能检测的需求。




图7 改进模型与原模型训练结果对比
Fig. 7 Comparison of training results of improved model and original model

3.4 路面坑槽检测可视化应用

为直观验证改进后的检测算法在实际场景中的识别效果，使用优化前后的模型，分别预测验证集中的403张图片，并选取3组具有代表性的验证结果

来展示具体的改进点。隐患预测框上方的文字标签和数字分别表示隐患类别及其识别置信度，原算法与优化后算法预测结果对比如图8所示。观察结果显示，改进后的算法性能更好，整体精度显著提高。值得注意的是，在第1组图中，漏检问题减少；第2组图中，误检问题得到改善；第3组图中，锚框边界的框定更加精确。综上，改进算法可以准确识别路面坑槽隐患目标，验证了算法的有效性。




图8 原YOLOv5s算法与改进后算法检测效果对比
Fig. 8 Comparison of detection effect between original YOLOv5s algorithm and improved algorithm

在实际道路巡检运维场景中，使用PyQt5设计路面坑槽检测系统，结合目标检测算法，页面效果如图9a所示，目标检测工具分为功能选择、检测结果和检测信息3个主要部分。功能选择包括模型权重、初始化模型和数据源选择，数据源可以来自图片、视频和调用摄像头实时检测；检测结果区域直观展示目标检测算法处理数据源后的结果；检测信息部分实时输出检测结果的坐标、精度和类别。这种实时检测系统有助于用户及时查看模型运行效果和实际场景中路面的状态。

实时检测系统采用搭载2000万像素影像传感器^[15]的无人机，悬浮在有坑槽路面上空实时拍摄，结果如图9b所示。系统自动识别并统计摄像头覆盖画面内的坑槽数量，检测精度保持在85%以上实



(a) 检测系统页面



(b) 开启检测功能结果

图 9 路面坑槽检测系统可视化界面

Fig. 9 Pavement pothole inspection system visualization interface display

地应用表明:该系统直观展示检测结果,显著提升路面巡检效率,帮助工作人员及时发现隐患并采取措施,保障道路交通安全。

4 结 论

1) 提出 YOLOv5s-AFE, 一种基于 YOLOv5s 改进的路面坑槽隐患检测轻量化网络模型。通过深度融合不同层级的特征,优化全局和局部特征的分配。FasterNet 替代原 YOLOv5s 的主干网络,并加入 ECA 模块,显著提升模型在路面坑槽检测中的特征提取能力和语义信息理解力,有效提升了模型的融合效率和检测精度。

2) 改进后的网络模型在保持较高运算速度的同时,相较于原 YOLOv5s 模型,其精度、召回率和平均检测精度分别提升了 4.1%、9.9% 和 5.6%。尽管模型参数有所增加,但在计算成本和检测性能之间取得平衡后,模型仍能满足实际路面巡检的需求,展现了其在实用性和高效性上的均衡。下一步研究将考虑增加更多训练数据和优化算法,提高系统的适应性和应用范围,并结合云端技术实现远程监测和数据管理。

参 考 文 献

- [1] 道路交通管理杂志社. 数说交通 | 2023 年, 全国公路总里程 544.1 万公里, 其中高速公路 18.4 万公里[EB/OL]. (2024-04-08). <https://www.yoojia.com/article/9539097732664945371.html>.
- [2] 纪雅琪, 程博文, 龚煜. 智能道路状态检测系统研究[J]. 长江信息通信, 2023, 36(3):154-156,159. JI Yaqi, CHENG Bowen, GONG Yu. Research on intelligent road state detection system[J]. Changjiang Information & Communications, 2023, 36(3):154-156,159.
- [3] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 779-788.
- [4] 高倩. 公路路面病害智能检测技术研究与应用[D]. 北京: 北京工业大学, 2022. GAO Qian. Research and application of intelligent detection technology for highway pavement disease [D]. Beijing: Beijing University of Technology, 2022.
- [5] 白芮, 徐杨, 王彬, 等. 基于改进 YOLOv5s 的道路坑洼检测算法[J]. 计算机与现代化, 2023(6):69-75. BAI Rui, XU Yang, WANG Bin, et al. Road pothole detection algorithm based on improved YOLOv5s[J]. Computer and Modernization, 2023(6):69-75.
- [6] 朱瑞鑫, 杨福兴. 运动场景下改进 YOLOv5 小目标检测算法[J]. 计算机工程与应用, 2023, 59(10):196-203. ZHU Ruixin, YANG Fuxing. Improved YOLOv5 small object detection algorithm in moving scenes [J]. Computer Engineering and Applications, 2023, 59(10):196-203.
- [7] 钟靖涛. 基于无人机图像与深度学习的路面病害识别研究[D]. 南京: 东南大学, 2022. ZHONG Jingtao. Research on pavement disease recognition based on UAV images and deep learning [D]. Nanjing: Southeast University, 2022.

- [8] 高明星, 关雪峰, 范井丽, 等. 基于改进 YOLOv5-DeepSORT 算法的公路路面病害智能识别[J]. 森林工程, 2023, 39(5):161-174.
GAO Mingxing, GUAN Xuefeng, FAN Jingli, et al. Intelligent recognition of road surface disease based on improved YOLOv5-DeepSORT algorithm[J]. Forest Engineering, 2023, 39(5):161-174.
- [9] 李雪. 公路路面坑槽及应对策略对交通的影响[D]. 北京: 北京交通大学, 2022.
LI Xue. Impact of highway pavement potholes and coping strategies on traffic[D]. Beijing: Beijing Jiaotong University, 2022.
- [10] LIU Songtao, HUANG Di, WANG Yunhong. Learning spatial fusion for single-shot object detection[J]. ArXiv Preprint ArXiv, 2019: DOI: 10.48550/arXiv.1911.09516.
- [11] CHEN Jierun, KAO Shuihong, HE Hao, et al. Run, don't walk: chasing higher FLOPS for faster neural networks[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023:12 021-12 031.
- [12] WANG Qilong, WU Banggu, ZHU Pengfei, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020:11 531-11 539.
- [13] 刘雅洁, 伊力哈木·亚尔买买提, 席凌飞, 等. 改进 YOLOv5s 的安全帽佩戴检测算法研究[J]. 计算机工程与应用, 2023, 59(20):184-191.
LIU Yajie, YILHAMU Yaermainaiti, XI Lingfei, et al. Research on improved safety helmet wearing detection algorithm of YOLOv5s[J]. Computer Engineering and Applications, 2023, 59(20):184-191.
- [14] 赵江平, 刘星星, 张想卓. 基于改进 YOLOv5s 的外脚手架隐患图像识别技术[J]. 中国安全科学学报, 2023, 33(12):60-66.
ZHAO Jiangping, LIU Xingxing, ZHANG Xiangzhuo. Research on image recognition technology for external scaffold hidden danger based on improved YOLOv5s[J]. China Safety Science Journal, 2023, 33(12):60-66.
- [15] 李华, 吴立舟, 薛曦澄, 等. 基于计算机视觉的高处临边作业安全巡检[J]. 中国安全科学学报, 2023, 33(9):69-75.
LI Hua, WU Lizhou, XUE Xicheng, et al. Computer vision based safety inspection of high abutting edges[J]. China Safety Science Journal, 2023, 33(9):69-75.



作者简介: 赵江平 (1972—),男,湖北潜江人,硕士,副教授,主要从事建筑安全与防火、图像识别、安全评价等方面的研究。E-mail:348916294@qq.com。