

# 无人机公路日常巡检多目标识别算法研究

马涛,田梅娟,王志鹏,董嘉智,朱俊清\*

(东南大学交通学院,江苏南京 210096)

**摘要:**针对无人机公路日常巡检任务中检测目标小、背景复杂、计算量大导致的检测精度不足、实时性差等问题,该文提出一种基于YOLOv11n改进的无人机公路日常巡检算法YOLOv11-UR。该算法将MLCA注意力机制加入主干网络,融合通道与空间维度信息,整合局部与全局感受野,有效增强特征表达能力。在仅增加少量参数的前提下,实现了检测精度的显著提升。在Neck部引入GSConv替换标准卷积,使卷积计算的输出尽可能接近标准卷积的同时,降低计算成本;引入VoVGSCSP替换C3k2,降低模型参数量和计算复杂度的同时增强特征提取能力。试验结果表明:YOLOv11-UR算法在无人机公路日常巡检方面具有显著优势,在未损失过多推理速度的情况下,有效减少了模型的参数量与计算开销,且模型检测精确率(Precision,  $R_p$ )和平均精度均值(Mean Average Precision,  $m_{AP}$ )分别达到78.26%和73.34%。改进算法兼顾检测精度与推理效率,能够更好地满足无人机公路日常巡检需求。

**关键词:**公路日常养护;目标检测;无人机巡检;航拍图像;深度学习

中图分类号:U418.6

文献标志码:A

## Research on Multi-Object Detection Algorithm for Routine Highway Inspection Based on UAV

MA Tao, TIAN Meijuan, WANG Zhipeng, DONG Jiazhi, ZHU Junqing\*

(School of Transportation, Southeast University, Nanjing, Jiangsu 210096, China)

**Abstract:** To address the problems of insufficient detection accuracy and poor real-time performance caused by small detection objects, complex backgrounds, and large calculation volume in routine highway inspection tasks using unmanned aerial vehicles (UAVs), this paper proposed an improved UAV-based routine highway inspection algorithm relying on YOLOv11n, YOLOv11-UR. The algorithm incorporated the multi-level channel and attention (MLCA) mechanism into the backbone network to fuse channel and spatial dimension information, integrate local and global receptive fields, and effectively enhance feature expression capability. It achieved a significant improvement in detection accuracy with only a small increase in parameters. In the Neck part, GSConv was introduced to replace standard convolution, making the output of the convolution calculation as close as possible to standard convolution while reducing computational costs. VoVGSCSP was introduced to replace C3k2, reducing the model parameter volume and computational complexity while enhancing feature extraction capability. Experimental results show that the YOLOv11-UR algorithm has significant advantages in UAV-based routine highway inspection. It effectively reduces the parameter volume and computational overhead of the model without losing much inference speed. The model detection precision ( $R_p$ ) and mean average precision ( $m_{AP}$ ) reach 78.26% and 73.34%, respectively. The improved algorithm balances detection accuracy and inference efficiency and can better meet the needs of UAV-based routine highway inspection.

**Keywords:** routine highway maintenance; object detection; UAV inspection; aerial image; deep learning

收稿日期:2025-06-17 修回日期:2025-10-24

基金项目:国家自然科学基金资助项目(编号:52208428)

作者简介:马涛,男,博士,教授. E-mail:matao@seu.edu.cn

\*通信作者:朱俊清,男,博士,副教授. E-mail:zhujq@seu.edu.cn

## 0 引言

中国公路网络规模日益增大,已形成世界规模最大的综合交通运输体系。与此同时,公路养护需求持续累积并不断演变,公路发展重心从以建设为主,向建养并重逐渐转变。截至2022年,公路养护里程已经达到535.03万km,占全国公路里程的99.9%。传统以人工为主的公路巡检方式存在工作量大、巡检效率低、响应不及时、作业易干扰交通等问题,难以满足公路运维精细化、高效化和智能化的需求。无人机具备快速部署、高空俯瞰、灵活机动、非接触式作业等优势,可显著提升巡检覆盖率与效率,降低人力成本,在电力管道巡检、边坡重建、交通流统计、标线检测、岩体检测、桥梁检测等领域已得到广泛应用<sup>[1-8]</sup>。无人机可实现对公路资产状况的快速检测与反馈,但受限于无人机采集的公路图像中目标种类繁多、尺度变化大、背景复杂,提升路面破损与设施损坏评估的准确性仍是关键技术难点。

目前,基于深度学习的目标检测算法主要可分为两类:基于CNN的目标检测、基于Transformer的目标检测<sup>[9-10]</sup>。其中基于CNN的目标检测又可分为两类,第一种为两阶段检测算法,其典型代表是基于region proposal的R-CNN系算法,如R-CNN<sup>[11]</sup>、Faster R-CNN<sup>[12]</sup>等。章洋等<sup>[13]</sup>采用Mask-RCNN对手机采集路面图像进行破损识别,结果表明:与SSD模型相比,该方法对破损的平均误检率、漏检率分别降低15.4%、19.6%,较好地满足了公路无损检测的实际需求;第二种为单阶段检测算法,代表性模型包括YOLO系列算法<sup>[14]</sup>和SSD算法<sup>[15]</sup>。苏卫国等<sup>[16]</sup>基于YOLOv3算法开展道路裂缝检测,精度达95%,检测速度达0.123 1 s/张,满足道路实时裂缝检测要求,但训练数据较少、裂缝类别单一;谢海波等<sup>[17]</sup>提出一种基于YOLOv5-CT和Ganomaly的半监督算法,解决了模型训练样本不平衡的问题,在少量负样本条件下训练出的模型检测精度达98.33%;Zhu等<sup>[18]</sup>使用Faster RCNN、YOLOv3和YOLOv4三种目标检测模型训练数据集,比较测试结果表明:YOLOv3展示了最佳的检测性能,平均精度为56.6%。基于Transformer的目标检测模型以DETR<sup>[19]</sup>、DINO<sup>[20]</sup>为代表,Wan等<sup>[21]</sup>基于DETR提出了BR-DETR用于检测混凝土桥梁的表面损伤,将平均精度均值( $m_{AP}$ )提升了1.9个百分点,召回率提升了0.8个百分点;Wang等<sup>[22]</sup>提出了一种针对混凝土裂缝实时检测模型RAI-DETR,采用自适应损

失函数Inner-IoU消除目标大小不一致对检测的影响,检测精度达82.5%;Zuo等<sup>[23]</sup>提出了Pavement-DETR模型,通过集成局部特征增强与边界框注意力机制,在UAV-PDD2023数据集上将平均精度均值( $m_{AP}$ )提升了7.7个百分点。

为进一步提高无人机巡检任务中目标检测模型的适用性与实时性,近年来国内外学者在轻量化检测网络方面开展了诸多研究。He等<sup>[24]</sup>提出的YOLOv7 BiFPN-G通过引入BiFPN,在将参数量压缩至7.4 M的同时,在平均精度均值等指标上优于YOLOv5-s等轻量模型,为边缘部署提供了可行方案;Zhu等<sup>[25]</sup>基于YOLOv8构建了适用于公路巡检的轻量化模型UM-YOLO,提升平均精度均值( $m_{AP}$ )的同时,将计算负荷减少了约14%;Niu等<sup>[26]</sup>提出SBiFPN作为特征融合网络,实现跨级加权融合,提升了特征融合效率。

然而,目前使用无人机进行公路巡检仍存在一些问題,如缺少针对公路巡检目标的无人机采集图像,现有的开源数据集类别数目过少、标签分布不平衡。此外,现有模型大多侧重于路面病害检测,针对交通基础设施检测的模型较少,检测精度、速度难以满足公路实时巡检需求。因此,本文针对现存的问题设计了一种适用于无人机公路日常巡检的多目标识别算法。首先,确定无人机采集公路图像飞行参数,根据公路日常巡检的任务需求选择检测对象,建立无人机公路数据集。然后,建立无人机公路日常巡检算法YOLOv11-UR。最后,通过消融试验、对比试验和可视化对比,分析本文提出改进方法的有效性,验证YOLOv11-UR的优越性。

## 1 无人机公路数据集构建

为解决现有开源数据集中部分类别数量过少、缺少针对交通基础设施的标注的问题,本文构建了无人机公路数据集。数据集图像采集工作在江苏省南京市某典型双向四车道省道上进行,该路段重载交通通行频繁,路面服役压力较大,病害类型分布丰富,具有较强的代表性。图像采集采用无人机以低空飞行方式对路面进行俯拍,具备非接触式、高覆盖率、低交通干扰等特点,共获取公路图像1 800张。

### 1.1 无人机飞行参数

考虑无人机巡航能力、抗风能力,平衡安全性和可行性,采用目前已稳定投入使用的商用级大疆Mavic 3 Pro无人机作为图像采集设备。确定无人机

相机参数,其中像素为1 200万(4 032×2 268),焦距为19.35 mm,传感器尺寸为1/1.3英寸(9.65 mm×7.2 mm)。通过调研路侧障碍物高度、航拍图像实际效果影响,确定无人机飞行参数,其中飞行高度为50 m,飞行速度为3 m/s,拍摄角度为垂直俯拍,拍摄时间间隔为2 s。无人机采集图像的总参数如表1所示。

表1 无人机参数汇总

Table 1 Summary of UAV parameters

成像尺寸/ pixel×pixel	镜头尺寸/ mm×mm	焦距/ mm	飞行高 度/m	飞行速度/ (m·s <sup>-1</sup> )	飞行角度	拍摄间 隔/s
4 032×2 268	9.65×7.2	19.35	30	2	垂直俯拍	1

### 1.2 数据集建立及预处理

根据《公路养护技术标准》(JTG 5110—2023)和《公路沥青路面养护技术规范》(JTG 5142—2019),结合实际工程调研结果,明确了公路日常巡检的重点内容与技术要求。在综合考虑无人机巡检作业特性与应用可行性的基础上,本文将巡检对象划分为沥青路面病害和交通基础设施损坏两大类,具体巡检目标如图1所示。其中,沥青路面病害包括:纵向裂缝、横向裂缝、斜向裂缝、龟裂、坑槽、块状修补、条状修补;交通基础设施损坏包括:标线缺失、排水设施损坏、路缘石损坏、护栏损坏、绿化带侵占、路面积水、路面抛洒物,共14类。



图1 巡检目标示意图

Figure 1 Illustration of inspection objects

将无人机采集的大尺寸公路图像裁剪为640×640的小尺寸图像,以适应目标检测模型的输入规格并满足算力需求。采用数据增强方法对样本量较少的类别进行扩充,随机组合翻转、平移、旋转、亮度调整、噪声添加及随机遮挡等操作,以提升模型对少样本类别的识别能力。数据增强过程如图2所示。




图2 数据增强

Figure 2 Data augmentation

使用LabelImg对无人机采集图像进行标注,标注过程如图3所示。数据集中不同类别标签数量见图4。最终构建数据集包括7 020张图像、16 008个标签,按7:1:2划分为训练集、验证集和测试集。

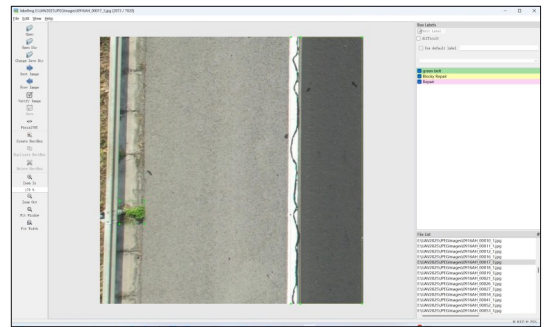


图3 数据标注

Figure 3 Data annotation




图4 数据集类别分布

Figure 4 Category distribution of dataset

## 2 试验方法

### 2.1 改进YOLOv11模型

YOLOv11<sup>[27]</sup>是Ultralytics于2024年提出的全新SOTA(State-of-the-Art)一阶段目标检测算法,在YOLO系列基础上延续并革新了经典的主干-颈部-

头部(Backbone-Neck-Head)三段式架构。其主干网络主要由 Conv、C3k2、SPPF 及 C2PSA 模块组成, C3k2 动态卷积模块在  $3 \times 3$  与  $5 \times 5$  间动态选择卷积核, 扩展感受野, 使模型能够捕捉更广泛的上下文信息; C2PSA 通过在 C2f 模块中引入 Position-Sensitive Attention(PSA), 通过多头注意力机制和前馈神经网络帮助模型更好地聚焦于目标物体特征, 增强特征提取能力。在颈部阶段, YOLOv11 使用 FPN+PAN 网络架构, 加强不同尺度特征层信息的融合与利用。在头部阶段, YOLOv11 在分类分支引入深度可分离卷积(DWConv), 提升检测精度的同时显著降低了参数量与计算量。

由于无人机在公路日常巡检中检测目标小、图像背景复杂、噪声多、推理速度慢, 难以满足实时检测需求, 容易导致误检、漏检, 检测效果不佳。因此, 本文针对以上问题对 YOLOv11 进行改进, 提出 YOLOv11-UR 模型, 结构图如图 5 所示。

**2.1.1 基于混合局部通道注意力机制的主干网络**

原 YOLOv11n 的主干网络主要依赖标准卷积进行特征提取, 其在全局上下文信息建模和通道间依

赖关系捕获方面存在局限, 这可能导致模型对遮挡、小目标等困难样本的感知能力不足。为解决上述局限, 本文在 YOLOv11n 的主干网络中引入混合局部通道注意力机制(Mixed Local Channel Attention, MLCA)<sup>[28]</sup>。

MLCA 模块的设计核心在于同时兼顾通道维度的重校准与空间局部-全局信息的协同建模。其作用机理分述如下:

(1) 输入特征图经由局部平均池化(LAP)处理, 以保留并强化其局部空间结构信息, 防止后续全局平均池化(GAP)操作造成空间细节的丢失。在此基础上, 输入特征向量被解耦为两个功能互补的并行分支。其中一条分支通过全局平均池化将空间信息压缩至通道维度, 实现高效捕获图像级的全局上下文语义。与此同时, 另一条分支则保留并传递经局部平均池化提取的细粒度空间特征, 维持对目标边缘等局部细节的高响应, 保障后续定位任务的精确性。这种并行分支架构, 完成了对全局上下文与局部细节两种不同尺度与性质的特征信息的利用。

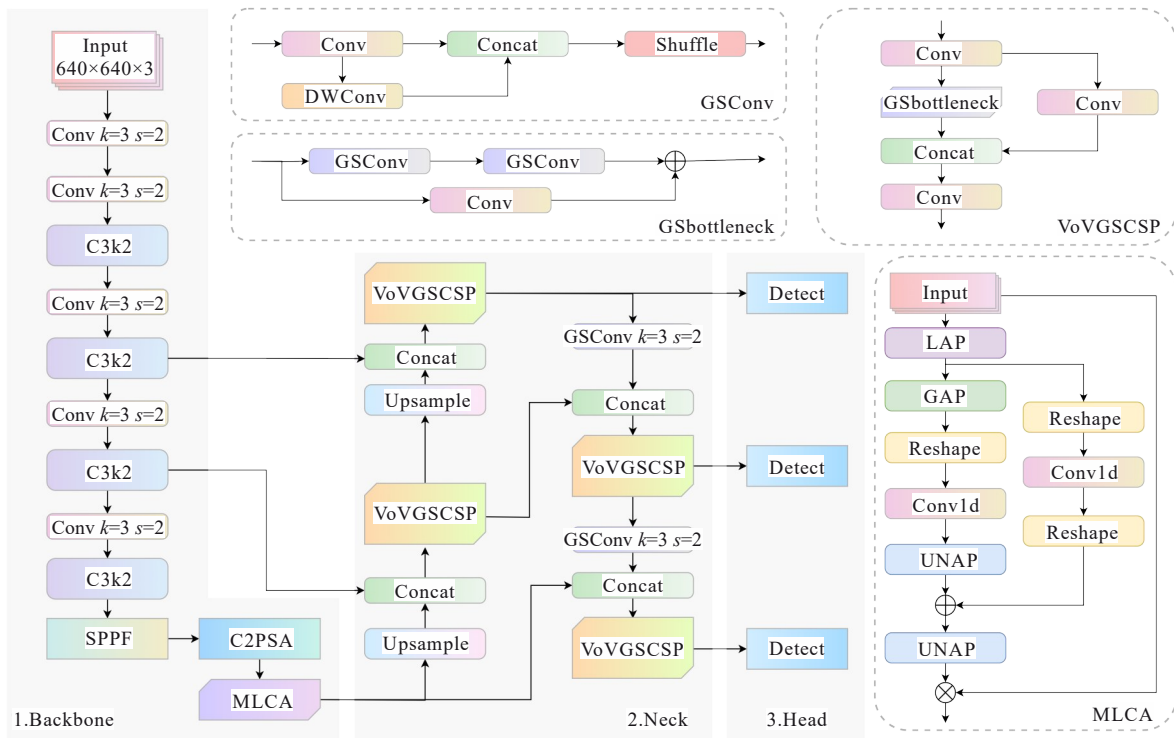


图5 YOLOv11-UR网络结构图  
 Figure 5 Architecture of YOLOv11-UR network

(2) 两条分支分别通过一维卷积(Conv1d)进行特征编码与降维, 高效地建立通道间的非线性依赖

关系, 实现对不同通道特征的自适应重加权, 让模型关注更具判别性的特征通道。

(3) 通过反池化(UNAP)操作将两条分支恢复至原始分辨率,并进行逐元素相加融合。这一融合过程实现了局部细节与全局上下文的互补与增强:全局信息为局部特征提供了语义指导,而局部信息则弥补了全局池化带来的空间细节损失。

YOLOv11-UR的主干网络与原模型中单纯的前向卷积堆叠相比,通过引入MLCA,以内嵌的方式显式地建模了通道注意力和空间注意力,形成了更高效的特征表示,显著增强了模型在复杂环境中对目标的表征与判别能力。

### 2.1.2 轻量级卷积模块

在颈部部分,本文采用轻量级卷积方法GSConv<sup>[29]</sup>取代标准卷积,以实现计算效率与特征表达能力的平衡。GSConv模块结合了标准卷积(Conv)与深度可分离卷积(Depthwise Separable Convolution, DWConv)的优势。输入特征首先通过一个标准卷积层提取跨通道的语义信息,同时生成较高维度的特征表示;随后该输出进入一个深度可分离卷积层以进一步细化通道内部特征。两路特征在通道维度上进行拼接(Concat),再经过通道重排(Shuffle)操作,实现不同卷积特征间的充分融合。Shuffle的随机通道置换使得标准卷积提取的高层信息能够有效渗透到深度可分离卷积所生成的轻量特征中,从而在降低参数量与计算量的同时保持良好的特征表达能力。

与YOLOv11n中使用的标准卷积相比,GSConv显著减少了卷积计算中的通道间冗余操作,使网络在保持近似特征分布的情况下大幅降低了FLOPs和参数量,实现了在不牺牲检测精度的前提下有效提升模型的实时性能,同时也为后续特征聚合模块的轻量化提供了基础。

### 2.1.3 特征提取单元

YOLOv11n中的C3k2模块主要依赖多层标准卷积堆叠,尽管能够捕获丰富语义信息,但在计算复杂度与参数规模方面较为冗余。为进一步提升特征提取效率并增强特征聚合能力,本文引入基于VoVNet<sup>[30]</sup>思想的VoVGSCSP模块替代YOLOv11n颈部的C3k2模块。该模块融合了VoVNet中的One-Shot Aggregation(OSA)特征聚合机制与GSConv的轻量卷积策略,旨在通过高效的特征重用与聚合实现结构简化与性能提升。

OSA结构的核心思想是将多个特征提取单元的输出在通道维度上一次性聚合,再通过卷积实现整

合与降维。这种方式避免了传统串联或多级残差堆叠带来的重复计算与梯度阻塞,使浅层特征能够在一次聚合中直接参与深层特征融合,从而获得更加丰富的语义表达。

基于此思想,在VoVGSCSP结构中,输入特征首先通过两条并行的卷积分支进行初步特征变换,其中一条分支进入轻量特征提炼单元GSBottleneck。GSBottleneck内部由两层串联的GSConv组成,以逐层提炼特征并压缩通道维度,同时保留一条经标准卷积的残差路径,通过逐元素相加的方式与主干输出融合,兼顾特征重用与信息流通;另一条主分支则通过一层卷积对输入特征进行线性变换与通道调整,以保留主要语义信息并维持特征完整性。随后,两路特征在通道维度上进行级联(Concat),并通过最后一层卷积实现统一的通道整合与信息融合,输出最终的高效特征图。

VoVGSCSP借助GSConv与OSA机制,将不同层次的特征一次性聚合并通过轻量卷积整合,既保持了特征的多样性与表达能力,又有效降低了计算量和参数占用。此外,GSBottleneck中的残差连接改善了信息流动与梯度传播,使得模型在轻量化的同时仍能保持稳定训练与较高的检测精度。

综上所述,VoVGSCSP在结构上实现了VoVNet中快速特征聚合思想与GSConv轻量化特征提炼的有机结合,不仅弥补了YOLOv11n在计算效率与信息融合上的不足,同时在不显著增加模型复杂度的条件下提升了特征提取与融合的能力,为后续检测提供了更具判别性的语义信息支撑。

## 2.2 试验环境与训练参数

本试验硬件配置由计算节点与图形处理器组成:中央处理器采用Intel Core i9-10900X,主要用于数据预处理和辅助计算任务,图形处理器选用NVIDIA GeForce RTX 2080 Ti,以加速深度学习模型的训练过程。试验软件环境采用Windows 11操作系统,编程环境基于Python 3.9解释器与PyTorch 2.0.0深度学习框架,并使用CUDA 11.8以充分利用GPU计算能力。通过Anaconda进行依赖库配置与版本控制,确保试验的可复现性。

模型训练参数设置如下:迭代周期(epoch)设置为350次,批处理规模(batch size)设定为32,数据加载线程数为4,优化算法采用动量随机梯度下降法(Stochastic Gradient Descent, SGD),基础学习率设置为0.01,动量因子为0.9,权重衰减系数配置为

0.000 5。输入数据维度经标准化预处理统一调整为 $640 \times 640$ 像素分辨率,所有试验都在相同的超参数下进行,不加载任何预训练权重。

### 2.3 评价指标

为全面评估模型性能,本文采用多项评价指标进行定量分析,主要包括:精确率(Precision,  $R_p$ )、召回率(Recall,  $R_R$ )与F1-Score( $F_1$ ),用于衡量模型对正负样本的判别能力;平均精度(Average Precision,  $A_p$ )与平均精度均值(Mean Average Precision,  $m_{AP}$ ),反映模型在一定置信度阈值下的预测性能;计算效率方面,采用每秒处理帧数(Frames Per Second, FPS)代表推理速度,每秒浮点运算量(FLOPs)评估模型的理论计算复杂度,参数量(Param)衡量模型的存储与部署开销。

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

式中: $A$ 为预测边框; $B$ 为实际边框。

$$R_p = \frac{T_p}{T_p + F_p} \quad (2)$$

$$R_R = \frac{T_p}{T_p + F_N} \quad (3)$$

$$F_1 = \frac{2T_p}{2T_p + F_p + F_N} \quad (4)$$

$$A_p = \int_0^1 R_p(R) dR_R \quad (5)$$

$$m_{AP} = \frac{1}{n} A_p \quad (6)$$

本实验选择IoU阈值为0.5。 $T_p$ 为检测结果大于0.5且分类正确的数量; $F_p$ 为检测结果小于0.5或者分类不正确的数量, $F_N$ 为存在实际边框而未被检测出的数量, $n$ 代表类别数量。其中, $m_{AP}$ 通过对不同召

回率点上的准确率进行平均,计算Precision-Recall( $R_p$ - $R_R$ )曲线面积得到; $m_{AP}$ 表示对所有类别的 $A_p$ 值求平均值,能够反映整个模型的准确率<sup>[31]</sup>。

## 3 试验结果与分析

### 3.1 消融试验

为了验证本文提出的各个模块对模型性能改进的有效性,采用逐步添加改进模块的方式在无人机公路数据集上进行消融试验。具体步骤如下:首先以YOLOv11n为基准模型,每组试验采用相同的训练策略、保持所有的参数一致,逐步引入MLCA注意力机制、GSConv和VoVGSCSP,共进行了6组消融试验。试验结果如表2所示,其中“√”表示添加了该模块。

从表2试验结果可以看出:在YOLOv11n的基础上,随着各个模块的逐步添加,改进模型均能在检测性能呈现出明显上升趋势的同时降低模型的参数量、计算量。试验A表示在主干网络中添加MLCA注意力机制后,召回率和 $m_{AP}$ 分别提高了1.72个百分点和0.5个百分点,同时在模型参数量、计算量和检测帧率上也没有明显的负面效果,说明该策略在提升模型特征提取能力的同时实现了复杂性与性能增益的平衡;试验B表示在Neck部分引入GSConv代替标准卷积后,精确率和 $m_{AP}$ 分别提高了1.95个百分点和0.73个百分点,同时参数量降低了3.47%、FPS增长了9.98%,均为对比策略中最优结果;试验C表示在Neck部分引入VoVGSCSP模块代替C3k2模块后,精确率、召回率、F1-Score和 $m_{AP}$ 分别提高了0.9个百分点、1.71个百分点、1.32个百分点和0.88个百分点,计算量也降低至5.9 G。在以上单个改进点中,

表2 消融试验结果

Table 2 Results of ablation experiments

改进策略	MLCA	GSConv	VoVGSCSP	Param	Flops/G	Size/MB	FPS/(f·s <sup>-1</sup> )	$R_p$ /%	$R_R$ /%	$F_1$ /%	$m_{AP}$ /%
YOLOv11n				2 584 882	6.3	5.3	247.44	77.76	63.43	69.14	70.25
A	√			2 584 892	6.3	5.3	246.02	76.01	65.15	69.43	70.75
B		√		2 495 122	6.2	5.1	272.13	79.71	63.01	69.66	70.98
C			√	2 572 354	5.9	5.3	252.74	78.66	65.14	70.46	71.13
D	√	√		2 495 132	6.2	5.1	125.78	73.94	66.61	69.30	70.94
E	√		√	2 662 124	6.1	5.4	120.98	75.56	67.21	70.65	72.85
F		√	√	2 572 354	5.9	5.3	248.80	78.92	65.04	70.51	71.12
G(本文模型)	√	√	√	2 572 364	5.9	5.3	237.88	78.26	66.60	71.40	73.34

注:Param表示模型参数量;Flops表示计算量;Size表示模型文件大小;FPS表示每秒能处理的图像帧数。

VoVGSCSP在预测能力方面的提升最为显著,而GSConv模块在模型轻量化方面表现最突出。

试验D、E、F代表了3个改进模块的不同组合,用以验证模块之间的协同作用。从试验结果可以看出:试验E在各项指标上表现最优, $m_{AP}$ 较基线模型提高了约2.6个百分点,说明MLCA与VoVGSCSP的结合能够在保持较低计算量的同时显著增强特征表达能力。相比之下,试验F在参数量略有增加的情况下仍保持较高的FPS,说明GSConv和VoVGSCSP的组合在轻量化方面的优势有效缓解了结构复杂度带来的计算开销。总体而言,3种组合试验均较单一模块进一步提升了检测性能,验证了各模块间的互补性与有效性。

试验G即为本文提出的YOLOv11-UR,该模型在多项评价指标中均取得最佳表现。其中,召回率和F1-Score分别达到66.6%和71.4%, $m_{AP}$ 高达73.34%,提高了3.09个百分点。显著提升预测性能的同时,相较基准模型实现了更低的参数规模与计算量,其中参数量降低了0.48%、计算量降低了6.35%。

综上所述,消融试验证明了各模块的有效性,所提出的改进策略在准确性与推理效率之间实现了良好平衡,能够满足无人机在公路日常巡检场景中的任务需求。

### 3.2 对比试验

为了全面评估本文提出模型在无人机公路日常巡检中的性能,本文将其与基于CNN和基于Transformer的目标检测算法中具有代表性的5种算法进行横向对比试验,包括:YOLOv5n、YOLOv8n、YOLOv12n、RT-DETR-R18<sup>[32]</sup>和原始YOLOv11n。每组算法在相同数据集上进行测试并记录结果,对比试验结果如表3所示。

根据表3可以观察到:在百万参数量级的目标检测算法中,本文提出的YOLOv11-UR,保持较高推理速度的同时,在精确率、召回率、F1-Score和 $m_{AP}$ 方面均明显高于其他主流目标检测算法,其中精确率、 $m_{AP}$ 分别高达78.26%和73.34%。

各模型预测 $R_p$ - $R_R$ 曲线对比如图6所示,YOLOv11-UR的 $R_p$ - $R_R$ 曲线能够完全覆盖同参数量级的目标检测算法。

表3 对比试验结果

Table 3 Comparative experimental results

算法	Param/ M	Flops/ G	Size/ MB	FPS/ (f·s <sup>-1</sup> )	$R_p$ /%	$R_R$ /%	$F_1$ / %	$m_{AP}$ / %
YOLOv5n	2.51	7.1	5.0	264.17	71.29	56.04	61.82	63.46
YOLOv8n	3.01	8.1	6.0	270.34	72.42	61.68	65.54	67.63
YOLOv11n	2.58	6.3	5.3	247.44	77.76	63.43	69.14	70.25
YOLOv12n	2.51	5.8	5.2	178.31	66.64	62.34	64.05	65.65
RT-DETR-R18	19.89	57.0	38.6	107.65	79.26	69.25	73.71	72.67
YOLOv11-UR(本文模型)	2.57	5.9	5.3	237.88	78.26	66.60	71.40	73.34

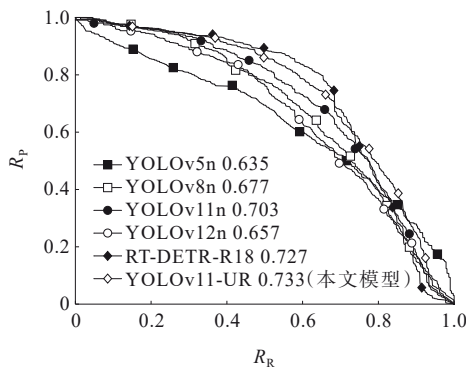


图6  $R_p$ - $R_R$ 曲线对比图

Figure 6 Comparison of  $R_p$ - $R_R$  curves

与千万参数量级的RT-DETR-R18算法相比,YOLOv11-UR在未损失过多精确率、召回率、F1-

Score的情况下,取得了更好的 $m_{AP}$ 结果( $m_{AP}$ 比RT-DETR-R18高0.67个百分点,参数量、计算量和模型尺寸分别仅为RT-DETR-R18的12.9%、10.4%和13.7%,且推理速度实现了1.2倍的提升。

综上所述,通过本文提出的改进策略,YOLOv11-UR可以在不显著降低推理速度的前提下,降低计算开销与内存占用,同时大幅提升模型的检测性能,充分体现了YOLOv11-UR在无人机公路日常巡检应用中的价值和优越性。

### 3.3 可视化对比结果

为了全面直观地比较本文改进算法YOLOv11-UR与其他主流目标检测算法在无人机公路巡检场景的检测效果,展示不同算法的可视化检测结果。

通过保留训练 YOLOv5n、YOLOv8n、YOLOv11n、YOLOv12n、RT-DETR-R18 和 YOLOv11-UR 时准

确率最高的权重文件,在测试集上进行检测和对比,可视化对比结果如图 7 所示。



图 7 不同模型检测效果实例  
Figure 7 Detection results of different models

从图 7(a)可以看出:在右上角目标密集区域, YOLOv5n、YOLOv8n、YOLOv12n 和 RT-DETR-R18 算法均出现了不同程度的冗余检测框重叠现象,即对同一检测目标生成了多个重叠检测框,导致目标定位不准确;此外, YOLOv5n 和 RT-DETR-R18 的检测结果中出现了假阳性,将路面阴影和水渍识别为块状修补或坑槽; YOLOv8n、YOLOv11n 和 YOLOv12n 均存在一定程度的检测框缺失情况,未能有效检测路面抛洒物和条状修补。相比之下,本文提出的 YOLOv11-UR 准确识别出了图像中全部病害及路面抛洒物,检测框定位精准、无错检漏检现象,表现出优越的准确性与鲁棒性。在图 7(b)中,5

种对比算法均未能识别出标线缺失区域,表明该类目标特征不明显、形态表现复杂,模型在特征学习时存在困难,而 YOLOv11-UR 实现了缺失部位的准确定位,与 Ground Truth 几乎完全重合,展现出对该类弱特征目标更强的特征提取能力。在图 7(c)中, YOLOv5n 和 RT-DETR-R18 对同一条横向裂缝输出多个重叠检测框;图 7(d)中, YOLOv11n 未能检测出图像右下角的龟裂病害;图 7(e)中, YOLOv11n 和 RT-DETR-R18 漏检了图像右上角的斜向裂缝;在图 7(f)中,只有 YOLOv11-UR 实现了对路面病害有效、精确、无重叠框的检测,表现出更强的特征提取能力和空间定位精度。

无人机巡检所捕获的公路图像常伴有复杂的背景干扰与密集的小尺寸目标,这对检测模型的鲁棒性与精确性提出了更高要求。为此,本文选取复杂背景与小目标场景进行深度对比,以验证YOLOv11-UR在应对这些实际挑战时的性能提升。如图8所示,在存在树枝遮挡的复杂场景中,

基线模型YOLOv11n因背景干扰产生了假阳性检测。而YOLOv11-UR则凭借更强的抗干扰能力,准确识别出了块状修补与路面抛洒物,并取得较高的置信度分数。在图9的小目标坑槽检测中,YOLOv11-UR同样克服了基线模型的漏检问题,成功定位目标。

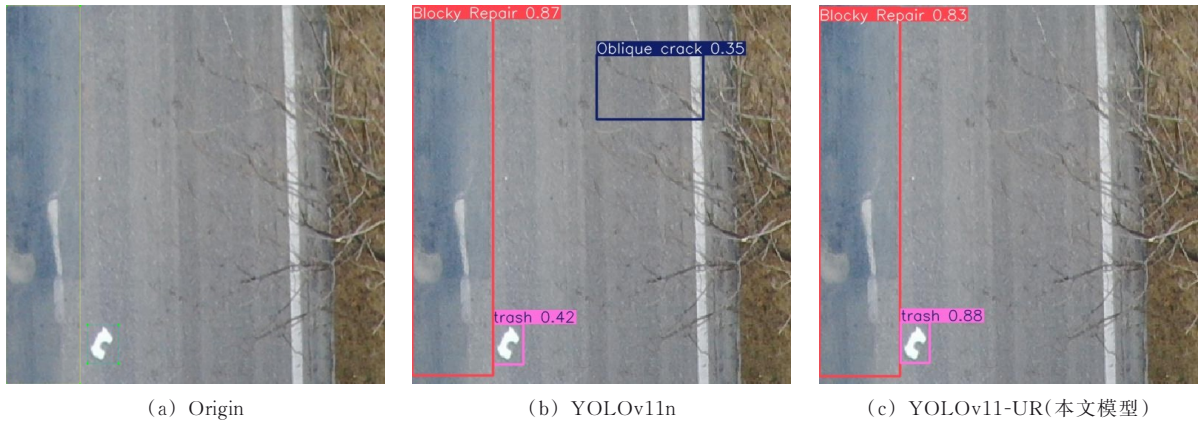


图8 复杂背景下的抗干扰能力对比

Figure 8 Comparison of anti-interference capability in complex backgrounds




图9 小目标检测能力对比

Figure 9 Comparison of small object detection capability

综上所述,YOLOv11-UR在无人机公路巡检场景中展现出较现有主流算法更为优越的检测精度,特别是在应对小尺度、弱特征、复杂形态病害及高噪声干扰场景方面,具有更高的鲁棒性与泛化能力。

### 3.4 实地验证

为了直观表现本文提出的模型YOLOv11-UR在无人机实时公路巡检中的实际应用性能,本文选取南京市某双向四车道公路作为试验区域开展实地验证。实地采集工作场景及检测结果如图10所示。结果表明:YOLOv11-UR可以实现对公路病害与交通基础设施的实时、快速、精准检测,满足无人机实

时公路巡检需求。

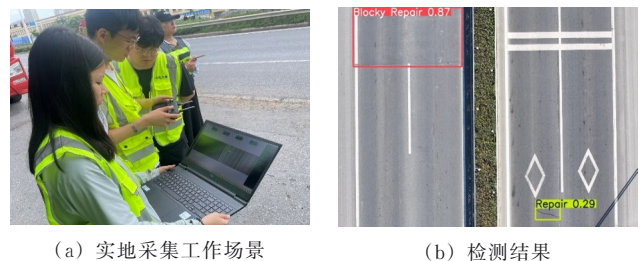


图10 YOLOv11-UR在无人机公路巡检中的实地验证场景

Figure 10 Field validation scenarios of YOLOv11-UR in UAV-based highway inspection

## 4 结论

针对无人机公路日常巡检目标尺度小、对象种类多、背景环境复杂,检测精度、速度难以满足实时巡检需求等问题,本文提出一种基于YOLOv11n的改进目标检测算法YOLOv11-UR,得出以下结论:

(1) 根据现行标准和规范,结合实际工程调研结果,分析确定无人机公路日常巡检对象,建立了包含7 020张无人机采集路面图像的数据集。

(2) 提出了适用于无人机公路日常巡检的YOLOv11-UR目标检测算法。通过消融试验,验证本文提出的各个改进模块对模型检测性能的贡献,相较原始YOLOv11n模型,参数量降低了0.48%、计算量降低了6.35%, $m_{PA}$ 提高了3.09个百分点,高达73.34%。

(3) 对比试验结果表明,YOLOv11-UR在保持较高推理速度的同时,在精确率、召回率、F1-Score和 $m_{PA}$ 上,显著优于同参数量级的主流算法。 $m_{PA}$ 比千万级参数量的RT-DETR-R18高0.67个百分点,进一步验证了本文所提模型在轻量化与性能平衡方面的优势。

目前YOLOv11-UR已能够基本满足无人机公路日常实时巡检的需求,但在某些情况下仍存在漏检和误检的现象。在未来的研究中,可以通过在更大规模的数据集训练中提升模型泛化性,通过对抗训练网络提升模型鲁棒性,进一步增强模型在复杂环境中的适应能力。

### 参考文献:

#### References:

- [1] 赵文俊,刘凯,许国伟,等.基于EDR-YOLOv7的架空输电线路无人机巡检边缘端目标检测方法[J/OL].南方电网技术,1-10(2025-02-19)[2025-05-12].<http://kns.cnki.net/kcms/detail/44.1643.tk.20250219.1327.008.html>.  
ZHAO Wenjun, LIU Kai, XU Guowei, et al. Edge-end target detection method for UAVs inspection of overhead transmission lines based on EDR-YOLOv7[J/OL]. Southern Power System Technology, 1-10 (2025-02-19) [2025-05-12]. <http://kns.cnki.net/kcms/detail/44.1643.tk.20250219.1327.008.html>.
- [2] KHALILULLAH I. Unmanned aerial vehicle and artificial intelligence assisted oil and gas pipeline inspection system [D]. Beaumont: Lamar University-Beaumont, 2021.
- [3] 相诗尧,徐润,张常勇,等.基于无人机倾斜摄影技术的高速公路边坡三维重建[J].中外公路,2020,40(5): 10-12.
- [4] XIANG Shiyao, XU Run, ZHANG Changyong, et al. Three-dimensional reconstruction of highway slope based on UAV oblique photography technology[J]. Journal of China & Foreign Highway, 2020, 40(5): 10-12.
- [5] WANG Z P, ZHU J Q, MA T. Deep learning - based detection of vehicle axle type with images collected via UAV[J]. Journal of Transportation Engineering, Part B: Pavements, 2024, 150(3): 04024032.
- [6] BU T X, ZHU J Q, MA T, et al. Pavement point cloud upsampling based on transformer: toward enhancing 3D pavement data[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(12): 21647-21657.
- [7] ZHU J Q, BU T X, MA T, et al. Raster-based point cloud mapping of defective road marking: Toward automated road inspection via airborne LiDAR[J]. Journal of Transportation Engineering, Part B: Pavements, 2024, 150(2): 04024015.
- [8] 李会兴,张敬,张健南,等.改进YOLO模型的岩体节理特征快速检测与应用[J/OL].中外公路,1-13(2025-09-26)[2025-10-20]. <https://link.cnki.net/urlid/43.1363.U.20250926.1043.020>.  
LI Huixing, ZHANG Jing, ZHANG Jiannan, et al. Rapid detection and application of rock mass joint features with the improved YOLO Model[J/OL]. Journal of China & Foreign Highway, 1-13(2025-09-26)[2025-10-20].<https://link.cnki.net/urlid/43.1363.U.20250926.1043.020>.
- [9] 黄蓉,李睿,翟雨辰,等.基于改进YOLOv5算法的桥梁表观病害检测[J/OL].中外公路,1-10(2025-08-05)[2025-10-20]. <https://link.cnki.net/urlid/43.1363.U.20250805.1009.002>.  
HUANG Rong, LI Rui, ZHAI Yuchen, et al. Bridge apparent disease detection based on improved YOLOv5 algorithm[J/OL]. Journal of China & Foreign Highway, 1-10 (2025-08-05) [2025-10-20]. <https://link.cnki.net/urlid/43.1363.U.20250805.1009.002>.
- [10] BU T X, LIU X Y, ZHU J Q, et al. Unsupervised pavement anomaly detection via conditional diffusion model and domain adaptive feature selection[J]. Computer-Aided Civil and Infrastructure Engineering, 2025, 40(28): 5195-5211.
- [11] ZHONG J T, ZHU J Q, JU H Y, et al. Multi-scale feature fusion network for pixel-level pavement distress detection [J]. Automation in Construction, 2022, 141: 104436.
- [12] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Columbus: 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014: 580-587.
- [13] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

- [13] 章洋,何莉,汤青洲,等.基于智能手机的农村公路路面破损检测方法[J].中外公路,2023,43(2):51-57.  
ZHANG Yang, HE Li, TANG Qingzhou, et al. Detection method of rural road pavement damage based on smart phone[J]. Journal of China & Foreign Highway, 2023, 43(2): 51-57.
- [14] REDMONJ, DIVVALAS, GIRSHICKR, et al. You only look once: Unified, real-time object detection[C]//Las Vegas: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- [15] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multiBox detector[M]//Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [16] 苏卫国,王景霄.基于YOLO v3深度学习算法的道路裂缝识别模型研究[J].中外公路,2023,43(2):58-63.  
SU Weiguo, WANG Jingxiao. Research on road crack recognition model based on YOLO v3 deep learning algorithm[J]. Journal of China & Foreign Highway, 2023, 43(2): 58-63.
- [17] 谢海波,朱玮峻,张璧,等.面向高强度螺栓检测的YOLOv5-Ganomaly联合算法研究[J].中外公路,2024,44(4):171-179.  
XIE Haibo, ZHU Weijun, ZHANG Bi, et al. Research on YOLOv5-ganomaly joint algorithm for high-strength bolt detection[J]. Journal of China & Foreign Highway, 2024, 44(4): 171-179.
- [18] ZHU J Q, ZHONG J T, MA T, et al. Pavement distress detection using convolutional neural networks with images captured via UAV[J]. Automation in Construction, 2022, 133: 103991.
- [19] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[J]. Lecture Notes in Computer Science, 2020, 12346: 213-229.
- [20] ZHANG H, LI F, LIU S L, et al. DINO: DETR with improved DeNoising anchor boxes for end-to-end object detection[EB/OL].(2022-03-08)[2025-05-20].<https://arxiv.org/abs/2203.03605>,arXiv:2203.03605.
- [21] WAN H F, GAO L, YUAN Z D, et al. A novel transformer model for surface damage detection and cognition of concrete bridges[J]. Expert Systems with Applications, 2023, 213: 119019.
- [22] WANG Q Y, CHEN B. A novel transfer learning model for the real-time concrete crack detection[J]. Knowledge-Based Systems, 2024, 301: 112313.
- [23] ZUO C H, HUANG N X, YUAN C, et al. Pavement-DETR: A high-precision real-time detection transformer for pavement defect detection[J].Sensors,2025,25(8):2426.
- [24] HE J J, WANG Y C, WANG Y T, et al. A lightweight road crack detection algorithm based on improved YOLOv7 model[J]. Signal, Image and Video Processing, 2024, 18(1): 847-860.
- [25] ZHU J Q, WU Y X, MA T. Multi-object detection for daily road maintenance inspection with UAV based on improved YOLOv8[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(11): 16548-16560.
- [26] NIU G Z, LI G M, WANG C Y, et al. LBN-YOLO: A lightweight road damage detection model based on multiscale contextual feature extraction and fusion[J]. Structural Control and Health Monitoring, 2025, 2025(1): 5595809.
- [27] KHANAM R, HUSSAIN M. YOLOv11: an overview of the key architectural enhancements[EB/OL]. (2024-10-23) [2025-05-20]. <https://arxiv.org/abs/2410.17725>, arXiv: 2410.17725v1.
- [28] WAN D H, LU R S, SHEN S Y, et al. Mixed local channel attention for object detection[J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106442.
- [29] LI H L, LI J, WEI H B, et al. Slim-neck by GSConv: A lightweight-design for real-time detector architectures[J]. Journal of Real-Time Image Processing, 2024, 21(3): 62.
- [30] LEE Y, HWANG J W, LEE S, et al. An energy and GPU-computation efficient backbone network for real-time object detection[C]//Long Beach: 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2019: 752-760.
- [31] 潘晓英,贾凝心,穆元震,等.小目标检测研究综述[J].中国图象图形学报,2023,28(9):2587-2615.  
PAN Xiaoying, JIA Ningxin, MU Yuanzhen, et al. Survey of small object detection[J]. Journal of Image and Graphics, 2023, 28(9): 2587-2615.
- [32] ZHAO Y A, LYU W Y, XU S L, et al. DETRs beat YOLOs on real-time object detection[C]//Seattle: 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024.