

基于改进 YOLO11 的遥感图像检测算法^{*}冉 宁^{1,2} 宋子昊¹

(1. 河北大学电子信息工程学院 保定 071002; 2. 河北大学节能技术研发中心 保定 071002)

摘要: 针对遥感图像存在的图像背景复杂、小目标分布密集、目标尺度多样等问题,提出了一种基于 YOLO11 的改进算法。首先,在主干网络中引入幽灵卷积,在保证模型性能的前提下,显著减少计算量和参数量;其次,在主干网络设计了一个混合网络模块,其中包含 3 种类型的模块,以丰富信息流并增强骨干网络的特征提取能力;最后,采用了一种语义收集的跨层多特征融合方式,将原本的 P5 层替换为 P2 层,增强了网络的多尺度特征融合能力,有效提升了检测精度,改善了遥感小目标特征信息难以提取的缺陷。通过在 VisDrone2019、AI-TOD 和 DIOR 数据集上的实验结果表明,改进后的 YOLO11s 模型与原模型 YOLO11s 相比, *mAP*₅₀ 分别提升了 2.8%、5.1% 和 9.8%,参数量下降了 31%,验证了新算法的有效性。

关键词: 遥感图像;YOLO11;跨层多特征融合;幽灵卷积

中图分类号: TP11;TN98 **文献标识码:** A **国家标准学科分类代码:** 510.80

Remote sensing image detection algorithm based on improved YOLO11

Ran Ning^{1,2} Song Zihao¹

(1. School of Electronic Information Engineering, Hebei University, Baoding 071002, China;

2. Energy Saving Technology Research Center, Hebei University, Baoding 071002, China)

Abstract: To address the challenges of complex background, dense small target distribution, and diverse target scales in remote sensing images, an improved algorithm based on YOLO11 was proposed. First, ghost convolution was introduced into the backbone network to significantly reduce computational load and parameter count while maintaining model performance. Second, a hybrid network module was designed in the backbone, incorporating three types of modules to enrich information flow and enhance feature extraction capabilities. Finally, a semantic-aware cross-layer multi-feature fusion approach was adopted, replacing the original P5 layer with the P2 layer to strengthen multi-scale feature fusion capabilities, effectively improving detection accuracy and mitigating the difficulty in extracting small target features from remote sensing images. Experimental results on the VisDrone2019, AI-TOD and RSOD datasets demonstrated that the improved YOLO11s model achieved *mAP*₅₀ increases of 2.8%, 5.1% and 5.3% respectively compared to the original YOLO11s, with a 31% reduction in parameters, validating the effectiveness of the new algorithm.

Keywords: remote sensing images;YOLO11;cross layer multi feature fusion;ghost convolution

0 引言

随着卫星遥感技术的不断发展,遥感图像在环境监测^[1]、航空航天^[2-3]、海洋监控^[4]等领域应用日益广泛,其中小目标检测因能识别小型建筑物、低空飞行器等关键目标成为核心任务。由于传感器分辨率和成像条件的限制,小

目标(如车辆、船只等)往往仅占 10~30 pixel^[5],且常呈现密集分布、形态多样等特征。同时,复杂的地物背景、光照变化及噪声干扰进一步增加了检测难度,导致传统检测算法存在特征提取不充分、误检率高等问题。因此,研究高效的小目标检测方法具有重要的理论价值和实际意义。

随着深度学习技术的快速发展,遥感图像目标检测领

收稿日期:2025-09-25

^{*} 基金项目:国家自然科学基金(62373132)、河北省自然科学基金(F2025201023)、石家庄市驻冀高校基础研究项目(241791367A)、河北大学优秀青年科研创新团队建设(QNTD202411)、河北大学多学科交叉研究计划项目(DXK202409)、河北大学在读研究生校级创新能力培育项目(HBU2026SS002)资助

域取得了显著突破^[6]。卷积神经网络(convolutional neural networks, CNN)的广泛应用,不仅大幅提升了检测精度,还推动了该领域的技术革新。目前,目标检测算法依据检测方法的差异可划分为两类:一类是基于区域生成的两阶段检测方法,如 R-CNN^[7]、Faster R-CNN^[8]和 Masked R-CNN^[9]等;一类是基于回归的单阶段检测方法,如 YOLO 和 SSD 等。在遥感图像检测任务中,YOLO 系列算法长时间占据主流地位,但其特征金字塔设计存在特定的局限性。

YOLO 系列算法中的多尺度预测机制通过简单的特征拼接实现信息融合,导致浅层细节与深层语义^[10]交互不足。虽然 RetinaNet 算法通过焦点损失函数减轻了类失衡,但其特征金字塔在跨层特征补偿^[11]中缺乏动态调制能力。为了满足遥感图像小目标检测的需求,Wang 等^[12]提出通过超分辨率重建预处理来提高小目标的可见性,但是额外的网络分支使端到端训练复杂度翻了一倍。Zhou 等^[13]从数据增强的角度,采用背景替换的方法解决了特征信息不足的问题。然而,这项工作并不能有效地提高小目标的检测精度。冉宁等^[14]采用了加权双向特征金字塔(BiFPN+P2)的特征融合方式来增强了网络的多尺度特征融合能力,有效地提升了检测精度,但也同样面临着网络体积过于庞大的问题。Wang 等^[15]引入一种针对低质量样本的边界框回归损失函数(wise-IoU, WIoU)纳入边界框回归损失中,采用动态非单调机制设计更合理的梯度增益分配策略,有效降低了高质量样本和低质量样本的梯度增益。

虽然以上的研究发展已经有效的提高了遥感图像检测的准确性,但仍存在不足,如小目标特征不明显、网络体积臃肿和模型泛化能力差等问题。对上述挑战,基于 YOLO11 提出了一种跨层多特征融合的轻量化网络模型,增强了对微小遥感目标的检测能力。主要贡献为:

- 1)使用幽灵卷积替换主干网络中的传统卷积,在保证模型性能的前提下,降低模型的计算量和参数量。
- 2)设计了一个混合网络模块,该网络集成了 3 种类型的块以丰富信息流并增强骨干网络的特征提取能力。
- 3)引入了一种语义收集的跨层多特征融合方式,强化了小目标特征,增强特征处理能力。
- 4)去除 P5 层的同时增加了 P2 层,在高分辨率阶段提取更精细的特征,有效降低了模型的参数量。

1 YOLO11 网络

1.1 YOLO11 概述

本文采用 YOLO11 是 YOLO 系列算法的第 11 个版本,由 Ultralytics 公司 2024 年 9 月提出,通过系统性的架构创新实现了检测性能全面提升。

YOLO11 网络结构图和模块框架图如图 1、2 所示。该模型采用了优化后的骨干网络和颈部结构,其中骨干网络以创新的 C3k2 模块取代传统的 C2f 模块^[16],在保证特征提取能力的同时显著提升了参数效率。在特征融合方

面,模型在 SPPF 层后引入了跨阶段部分金字塔空间注意力模块(cross-channel parallel spatial attention, C2PSA),该模块通过将金字塔空间注意力机制与跨阶段部分连接相结合,实现了多尺度空间特征的动态重校准,有效解决了复杂场景下的检测挑战。C2PSA 模块^[17]采用了协调的多头自注意力架构和强化的前馈神经网络,不仅实现了跨特征子空间的全局交互建模,还通过嵌入的残差连接优化了梯度传播特性,同时保留了目标定位所需的细粒度空间信息。在检测头设计上,模型采用深度可分离卷积显著降低了计算开销,而不会牺牲表征能力。这种精简而高效的架构设计,配合优化的训练协议,使 YOLO11 在保持卓越检测精度的同时,实现了处理速度的显著提升,完美平衡了计算效率与检测性能的关系,为复杂视觉场景下的实时目标检测提供了新的解决方案。




图 1 YOLO11 网络模型

Fig. 1 YOLO11 network mode




图 2 YOLO11 模块框架

Fig. 2 Module framework of YOLO11

1.2 YOLO11 不足与局限

尽管 YOLO11 在目标检测领域取得了显著的进展,但在某些特定场景下仍存在一些局限性。在小目标检测方面,YOLO11 的网络结构和特征提取能力对极小尺寸目标的捕捉效果仍不理想。由于小目标在图像中所占像素较

少,其特征信息在经过网络的多层处理后容易丢失,导致检测精度下降;其次,YOLO11 的检测头设计主要针对中等和较大尺寸的目标,对于多尺度变化的目标,尤其是极小尺寸目标,其检测能力有限,容易出现漏检现象。在复杂背景环境下,YOLO11 的检测性能也会受到一定影响。当检测图像中存在背景遮挡或小目标相互重叠时,模型容易出现误检或漏检的情况。YOLO11 在多模态检测任务中,缺乏自动识别主导模态的机制,这在实际应用中可能会限制其灵活性。虽然 YOLO11 在某些数据集上通过引入改进模块(如多光谱 PGI 和轻量级交叉注意力机制)取得了一定的性能提升,但这些改进在不同数据集上的效果并不稳定,且提升幅度有限。所以 YOLO11 在特定场景下的表现仍有待优化。例如,在低角度视角或针对某些特定类别目标(如卡车)的检测任务中,其检测精度和鲁棒性仍需进一步

提升。这些问题表明,尽管 YOLO11 在遥感目标检测领域已经取得了领先地位,但其在应对复杂的实际应用场景时,仍存在一些需要解决的挑战。

2 改进 YOLO11 算法

基于 YOLO11 模型的基础上,通过在主干网络中引入幽灵卷积模块降低计算复杂度和参数量;设计了混合网络架构(multi channel feature extraction,MCNet)增强特征表达能力。此外,采用语义收集的跨层特征融合机制并将原本的 P5 层替换为 P2 层,以保留更丰富的空间细节,提升小目标检测性能。这些改进显著增强了模型在复杂场景下对微小目标的敏感性与识别精度,在实现模型轻量化的同时保持优异的检测性能。改进后的网络模型结构如图 3 所示。




图 3 改进的 YOLO11 结构
Fig. 3 Improvement of YOLO11 structure

2.1 幽灵卷积

为了更好地实现模型轻量化和检测性能之间的平衡,本文使用幽灵卷积来取代主干层的传统卷积。幽灵卷积(ghost convolution,GhostConv)是一种新型的高效轻量级卷积操作,其核心思想是在少量“内在特征图”的基础上,通过低成本的线性变换生成更多“幽灵特征图”,以此减少冗余计算并保持特征表达能力^[18]。如图 4 所示,GhostConv 首先利用标准卷积生成一部分基础特征映射,然后通过一组廉价的线性操作(如逐通道卷积)扩展特征空间,从而在较低计算代价下实现与标准卷积相当的特征维度。




图 4 GhostConv 模块细节
Fig. 4 GhostConv module details

卷积滤波器,通过经济高效的变换生成少量的内在特征映射,从而减少了冗余计算,如式(1)所示。

$$Y = X \times f \tag{1}$$

其中, $X \in R_{c \times h \times w}$ 表示输入特征映射。所使用的


滤波器用 f 表示,并且 $f \in R_c \times k \times k \times m$ 。 $Y \in R_h \times w \times m$ 是由初级卷积产生的 m 个特征映射的集合。 h 和 w 项分别表示高度和宽度; C 表示用于输入的通道总数; M 为输出通道总数;而 k 是卷积核的大小。

为了获取想要的 n 个特征映射, Y 中的每个固有特征都需要经过高性价比的线性运算,生成 s 个鬼影特征,鬼影特征 y_{ij} 表述如下:


$$y_{ij} = \Phi_{i,j}(y'_i), \forall i = 1, \dots, m, j = 1, \dots, s \quad (2)$$

其中,卷积特征集合 Y 中的每个通道用 y_i 和 φ_i 表示, j 表示一个简单的线性变换。

与传统卷积相比,幽灵卷积在遥感小目标检测中表现出独特优势。遥感图像通常分辨率极高,小目标像素占比低且背景区域复杂,传统卷积在此类数据上容易产生大量与小目标无关的冗余特征,导致小目标特征被淹没。幽灵卷积通过削减冗余卷积核并利用线性映射生成附加特征图,使得模型在保持计算效率的同时,更聚焦于显著区域的细节特征。如图 5 所示,特征图可视化结果显示,幽灵卷积能够更好地保留小目标的边缘与纹理信息,从而在遥感场景中提高小目标的检测灵敏度与特征分辨力。



(a) 传统卷积特征图
(a) Traditional convolutional feature map



(b) 幽灵卷积特征图
(b) Ghost convolution feature map

图 5 特征图可视化对比

Fig. 5 Feature map visualization comparison

2.2 MCNet 模块

原始 YOLO11 的特征提取模块 C3k2 采用双卷积融合提取特征图信息,然而在实际的遥感小目标图像检测中,往往因为小目标分布密集、形状多样等问题无法提取完整的特征图信息。为了解决此类问题,设计了多通道特征提取网络(MCNet),如图 6 所示。

该架构由 3 种典型的卷积变体组成:用于通道特征重新校准的 1×1 旁路卷积,用于有效空间特征处理的深度可分离卷积(depthwise seperable convolution, DSCnv),以及用于增强特征的 GhostC2f 模块。这种结构在保持计算




图 6 MCNet 模块结构

Fig. 6 MCNet module structure

效率的同时,弥补了传统双卷积结构对遥感图像空间特征不敏感的缺陷,从而显著提升了主干部分 5 大核心阶段里每一项基础特征的语义深度。MCNet 模块可以表述为:

$$\begin{cases} X_m = \text{Conv}_1(X_{in}) \\ X_1 = \text{Conv}_2(X_m) \\ X_2 = \text{DSCnv}(X_m) \\ X_3, X_4 = \text{Split}(X_m) \\ X_5 = \text{GhostBottleneck}_1(X_4) \\ X_6 = \text{GhostBottleneck}_2(X_5) \\ \vdots \\ X_{4+n} = \text{GhostBottleneck}_n(X_{3+n}) \end{cases} \quad (3)$$

其中, X_m 的通道号为 $2c$ 。而每一个 $X_1, X_2, \dots, X_{4+n}$ 的通道数为 c 。

最后,将 3 类特征的语义信息通过串联运算融合压缩,然后进行 1×1 卷积运算,生成通道数为 $2c$ 的 X_{out} 。该方法保留原始特征在多尺度卷积上的差异表达,从而有效抑制遥感目标的漏检。 X_{out} 表述为:

$$X_{out} = \text{Conv}_0(X_1 \parallel X_2 \parallel \dots \parallel X_{4+n}) \quad (4)$$

MCNet 模块通过“通道重标定—空间解耦—冗余特征扩张”的协同机制,有效缓解了遥感影像中小目标特征易被背景淹没、尺度变化大、细节丢失等问题。该结构在保持网络轻量化的同时,增强了特征表达的丰富性与区分性,使网络能够更好地捕获小目标的边缘、纹理及空间结构信息。此外,MCNet 的多路径特征融合设计能够在不同尺度上保留目标的多样化表征,从而提高了对密集或微小目标的响应能力,为遥感小目标检测提供了一种较为高效、稳健且具有一定解释性的特征提取方案。

2.3 改进特征融合方式(跨层特征融合+P2)

在 YOLO 算法中,颈部负责融合多尺度特征进行最终的目标检测。YOLO11 的 Neck 沿用路径聚合网络

(PANet^[19])架构,它在特征金字塔网络(FPN)之上额外铺设了一条自下而上的路径,使高层特征富含语义、底层特征精确定位,从而更充分地耦合浅层与深层信息,显著提升检测精度。然而,这种结构仍以“高分辨率→低分辨率”的单向融合为主,在小目标检测中容易丢失信息;且融合策略局限于传统加权求和,易致部分特征丢失。受到 Hyper-YOLO 中语义收集设计思想的启发,采用了跨层特征融合方式对 5 个特征集{B1,B2,B3,B4,B5}进行预处理。融合后的特征集上集成了跨级别和跨位置的信息,最终在 3 个不同尺度上生成最终的语义特征,具体实现过程如图 7 所示。




图 7 Neck 特征融合结构
Fig. 7 Neck feature fusion structure

同时,选择用 P2 层来替代 YOLO11 原有的 P5 层结构。不同于 P5 层生成的低分辨率特征图,P2 层生成的高分辨率特征图在捕捉小目标细节方面表现更为出色。遥感图像中的小目标通常尺寸较小、与背景相似,低分辨率特征容易丢失目标细节,而 P2 层能够保留更多的边缘、纹理等细节信息,为小目标检测提供更精确的定位和识别能力。此外,特征金字塔网络中的不同层级具有不同的响应机制:低层(如 P2)更注重细节信息,适合小目标的检测,而高层(如 P5)侧重全局语义信息。通过替换 P5 层,P2 层的高分辨率特征有效提升了模型对小目标的敏感性和检测精度。实验结果表明,模型在遥感小目标检测任务中的精度获得了明显改善。

3 实验分析

3.1 实验环境

本研究的实验环境配置详情如表 1 所示。硬件上采用 4 张 NVIDIA RTX 3090 显卡(单卡显存 24 G),中央处理器选用 Intel Xeon Gold 6226R;深度学习软件环境为 Ubuntu 22.04、Python 3.10、CUDA 12.1、PyTorch 2.1.0。实验参数设置包括:模型训练总轮次(Epochs 设为 100),批处理大小(batch size)为 16,输入图像尺寸(image size)固定为 640×640,其他超参数均保持框架默认配置。

表 1 实验环境

名称	配置信息
操作系统	Ubuntu 22.04
开发语言	Python3.10
深度学习框架	Cuda12.1+pytorch2.1.0
GPU	RTX 3090(24 G)×4
CPU	Intel Xeon Gold 6226R×2

3.2 数据集

为了验证改进算法的有效性,在 AI-TOD 遥感数据集、DIOR 遥感数据集和 VisDrone2019 数据集上进行了实验。AI-TOD 数据集是专为航空图像中的小目标检测而设计的专用基准,包括 28 036 张高分辨率航空图像和 8 个典型遥感类别^[20],数据集被划分为训练子集(11 214 张)、验证子集(2 804 张)和测试子集(14 018 张)。DIOR 数据集是一个在遥感图像目标检测领域应用广泛的大规模公开数据集,该数据集包括 23 463 张图像和 20 种类别^[21],数据集被划分为训练子集(5 862 张)、验证子集(5 863 张)和测试子集(11 738 张)。VisDrone2019 数据集是天津大学实验室团队^[22]在各种复杂场景和光照条件下进行拍摄的,该数据集包含 8 629 张高分辨率静态图像和 10 个类别,分为训练子集(6 471 张)、验证子集(548 张)和测试子集(1 610 张)。

3.3 实验评估指标

为了直观对比改进前后模型性能,实验选取以下评估指标:准确率(P)、召回率(R)、平均精度均值(mAP)、参数量及计算量(GFLOPs)。计算公式为:

$$P = \frac{TP}{TP + FP}$$
 (5)

$$R = \frac{TP}{TP + FN}$$
 (6)

$$AP = \int_0^1 P(R) dR$$
 (7)

$$mAP = \frac{1}{k} \sum_{i=1}^k AP_i$$
 (8)

其中,TP(真阳性)为正确识别的阳性样本,FP(假阳性)为错误分类为阳性的阴性样本,FN(假阴性)为未被发现或被错误分类为阴性的阳性样本。AP 定义为以 P 准确率(P)为纵轴、召回率(R)为横轴所绘曲线下的面积;k 代表数据集的目标类别总数。

3.4 消融实验

为了验证 3 个模块的有效性,在 VisDrone2019 数据上进行消融实验。实验结果如表 2 所示。基于 YOLO11s 原模型为基线,引入各模块进行实验。其中,模块 A、模块 B、模块 C 分别代表幽灵卷积、MCNet 模块、跨层特征融合+P2,“/”代表应用了该模块或方法。

Baseline 表示原始算法 YOLO11s,其 P、mAP50、参数量和 GFLOPs 分别为 41.9%、30.8%、9.41 和 21.3。将

表 2 VisDrone2019 验证集消融实验

Table 2 Ablation study on the VisDrone2019 validation set

模块	模块 A	模块 B	模块 C	$P/\%$	$mAP50/\%$	$Params/10^6$	$GFLOPs$
Baseline				41.9	30.8	9.41	21.3
YOLO11s+A	✓			42.4	30.8	8.46	18.6
YOLO11s+B		✓		41.9	31.1	9.38	19.8
YOLO11s+C			✓	45.5	34.5	7.32	27.4
YOLO11s+A+B+C	✓	✓	✓	44.4	33.6	6.46	23.7

主干网络中的传统卷积替换为幽灵卷积后,参数量下降了 10.1%,计算量减少了 12.2%,同时 P 和 $mAP50$ 分别提升了 0.5%和 0.3%,说明幽灵卷积能够在降低模型复杂度的同时保持精度;在主干网络部分加入 MCNet 模块后, $mAP50$ 上升了 0.3%,参数量略微下降,计算量降低了 8.9%,实现了轻量化;在颈部网络引入多尺度跨层特征融合+P2 结构后, P 提升了 3.6%, $mAP50$ 提高了 3.7%,显著增强了特征表达能力;最后同时添加所有改进模块,与 Baseline 相比 P 和 $mAP50$ 分别提高了 2.5%和 2.8%,参数量减少了 31.4%,虽然计算量略微上升,但其他各项指标均有不同程度的提升,证明所提出的方法能够在保证精度的同时显著降低模型复杂度。

3.5 对比实验

为了验证改进后模型的有效性,设置相同的模型参数,在 VisDrone2019 数据集上与其他经典算法如 YOLOv5、YOLOv8s、YOLO11s、YOLOv12s、YOLOv13s 进行对比试验,实验结果如表 3 所示。

表 3 VisDrone2019 数据集的对比实验数据

Table 3 Comparative experimental data for the VisDrone2019 dataset

模型	$P/\%$	$R/\%$	$mAP50/\%$	$Params/10^6$
YOLOv5	41.2	32.5	30.0	9.11
YOLOv8s	42.5	33.7	31.6	11.1
YOLO11s	41.9	33.0	30.8	9.41
YOLOv12s	40.9	31.8	29.5	9.23
YOLOv13s	40.3	30.4	28.2	9.00
改进 YOLO11s	44.4	35.6	33.6	6.46

由表 3 可以得出,YOLOv8s 网络模型在各代 YOLO 模型中具有较高的检测精度,但其参数量和计算量过高,存在着网络体积过于庞大的问题;YOLOv5 虽然具有较低的参数量和计算开销以及轻量的网络结构,但在遥感小目标检测任务中无法兼顾检测精度,检测效果欠佳;YOLOv12s 与 YOLOv13s 在增加参数量的同时并未带来检测精度与召回率的提升,反而出现性能下降,说明单纯依赖模型规模的扩大并不能很好地适应遥感小目标检测任务。相比之下,YOLO11s 在精度与召回率上优于 YOLOv5 和 YOLOv8s,但其模型参数量依然较大,存在计

算开销过高的问题。相比 YOLO11s,改进后的模型精度 P 和 $mAP50$ 分别提升了 2.5%和 2.8%,参数量减少了 31.4%,在检测性能提升的同时,降低了模型的参数量,实现了网络的轻量化。实验验证了改进后 YOLO11s 模型的有效性,提升了遥感小目标检测的性能。

为了验证本文模型的泛化性,设置相同的模型参数,数据集由 VisDrone2019 数据集换成 AI-TOD 数据集和 DIOR 数据集,通过实验可得各项性能指标的结果,如表 4、5 所示。

表 4 AI-TOD 数据集的对比实验数据

Table 4 Comparative experimental data for the AI-TOD dataset

模型	$P/\%$	$R/\%$	$mAP50/\%$	$Params/10^6$
YOLOv5	52.9	29.2	29.6	9.11
YOLOv8s	56.0	31.8	32.1	11.10
YOLO11s	57.9	29.3	29.3	9.41
YOLOv12s	54.0	28.2	28.3	9.23
YOLOv13s	43.6	34.9	33.5	9.00
改进 YOLO11s	60.0	33.0	34.4	6.46


表 5 DIOR 数据集的对比实验数据

Table 5 Comparative experimental data for the RSOD dataset

模型	$P/\%$	$R/\%$	$mAP50/\%$	$Params/10^6$
YOLO11s	73.3	67.0	68.7	9.41
改进 YOLO11s	84.1	72.5	78.5	6.46


由表 4 和 5 可以得出,改进后的 YOLOv11s 网络模型在各项性能指标上均有明显提升。相较于原模型 YOLO11s,在 AI-TOD 数据集上 P 、 R 、 $mAP50$ 分别提升了 2.1%、3.7%、5.1%;在 DIOR 数据集上 P 、 R 、 $mAP50$ 分别提升了 10.8%、5.5%、9.8%,证明了改进方法在保证网络轻量化的同时有效增强了模型对目标的检测能力。改进后的算法有效改善了遥感小目标特征提取的缺陷,YOLO11s 算法与改进后算法的小目标检测层特征图如图 8 所示。

为了直观的对比,将 YOLO11s 算法与改进后的算法在 AI-TOD 数据集、Visdrone2019 数据集的部分图像进行



(a) YOLO11s小目标检测层特征图

(a) YOLO11s small object detection layer feature map



(b) 改进后小目标检测层特征图

(b) Improved small object detection layer feature map

图 8 改进前后的检测层特征图对比

Fig. 8 Comparison of feature maps in the detection layer before and after improvement

检测效果展示,这些图像涵盖了多种复杂环境,包括交通流量密集的城市路口、停放大量车辆的居住区及卫星遥感图像。这些场景具有不同的挑战性,例如照片清晰度低、目标密集分布、目标尺寸较小等,能够充分考验检测模型的鲁棒性和适应性。

实验结果如图 9 所示,从检测结果对比可以观察到,




图 9 改进前后效果对比

Fig. 9 Comparison of detection results before and after improvement

在目标尺寸较小、目标过于密集的情况下,原 YOLO11 模型容易出现漏检和误检,尤其是在背景复杂的场景中。相比之下,改进后的 YOLO11 模型能够准确的检测出部分原模型漏检的小目标,同时降低误检率,提高精度。实验结果表明,改进后的模型在小目标、密集目标以及低像素等条件下具有更强的鲁棒性,能够有效降低漏检率和误检率,提升检测性能。实验结果证明了改进后的 YOLO11 模型在实际应用场景中的可行性和优越性,改进后的算法在一定程度上解决了目标漏检、误检的问题,并在检测精度上有进一步提升。

4 结 论

为了解决遥感小目标图像中目标密集、目标尺寸过小、特征表征能力有限、检测精度退化等问题,本研究提出了一种基于 YOLO11 的改进型遥感小目标轻量化检测算法。首先,引入幽灵卷积替代主干网络中的传统卷积,在保证检测性能的前提下有效降低了模型的计算量和参数量;其次,在主干网络中设计了混合网络模块,该模块包含 3 种类型的结构单元,以丰富信息流并增强骨干网络的特征提取能力;然后,采用语义收集的跨层多特征融合方式,并将原本的 P5 层替换为 P2 层,进一步强化了网络的多尺度特征融合能力。实验结果表明,改进后的 YOLO11 模型在典型遥感小目标数据集上检测精度较原始模型有所提升,验证了所提方法的有效性。但本研究实验数据主要集中于常规小目标场景,对极端小目标(如像素面积 $<10\times10$)的检测性能尚未进行系统验证,未来将进一步研究此类场景下的小目标检测算法,以增强模型的适应能力。

参考文献

[1] 李泽胤,李栋,房建东,等.改进的 YOLOv8n 遥感图像轻量化检测模型[J]. 电子测量技术, 2025, 48(6): 130-142.
LI Z Y, LI D, FANG J D, et al. Improved YOLOv8n lightweight detection model for remote sensing images[J]. Electronic Measurement Technology, 2025, 48(6): 130-142.

[2] 高宇,张旭,李红,等.遥感卫星视轴指向在轨测量数据去噪处理方法与 BiLSTM-CNN 算法实现[J]. 仪器仪表学报, 2025, 46(6): 330-337.
GAO Y, ZHANG X, LI H, et al. Denoising method for on-orbit line-of-sight measurement data of remote sensing satellites and its BiLSTM-CNN-based implementation [J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 330-337.

[3] 吴海滨,左云逸,王爱丽,等. CNN 结合 Transformer 的高光谱图像和 LiDAR 数据协同地物分类方法[J]. 仪器仪表学报, 2025, 46(8): 286-301.
WU H B, ZUO Y Y, WANG AI L, et al. Collaborative land classification method using CNN combined with Transformer for hyperspectral images

- and LiDAR data[J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 286-301.
- [4] 柯淇晟,花强,张博.基于改进 YOLOv8 的遥感图像目标检测[J]. 河北大学学报(自然科学版),2025,45(3): 309-316.
- KE Q SH, HUA Q, ZHANG B. Remote sensing image object detection based on improved YOLOv8[J]. Journal of Hebei University(Natural Science Edition), 2025, 45(3): 309-316.
- [5] 闫钧华,张琨,施天俊,等.融合多层次特征的遥感图像地面弱小目标检测[J]. 仪器仪表学报,2022,43(3): 221-229.
- YAN J H, ZHANG K, SHI T J, et al. Ground weak target detection in remote sensing images by integrating multi-level features[J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 221-229.
- [6] 薛林雁,李轩昂,齐晁仪,等.基于改进 YOLOv5s 的肠镜息肉多分类实时检测方法[J]. 河北大学学报(自然科学版),2024,44(4):424-432.
- XUE L Y, LI X ANG, QI CH Y, et al. Multi-classificationreal-time detection method of colonoscopic polyps basedon improved YOLOv5s[J]. Journal of Hebei University (Natural Science Edition), 2024, 44(4): 424-432.
- [7] GIRSHICK R, DONAHUE J, DARRELL T, et al. Region-based convolutional networks for accurate object detection and segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 38(1): 142-158.
- [8] REN SH 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.
- [9] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R-CNN [C]. IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [10] JIANG P Y, ERGU D J, LIU F Y, et al. A review of YOLO algorithm developments [J]. Procedia Computer Science, 2022, 199: 1066-1073.
- [11] YANG ZH L, LIU Y. A steel surface defect detection method based on improved RetinaNet[J]. Scientific Reports, 2025, 15(1): 6045.
- [12] WANG X, YAN J K, CAI J Y, et al. Super-resolution reconstruction of single image for latent features[J]. Computational Visual Media, 2024, 10: 1219-1239.
- [13] ZHOU H L, MA AI T, NIU Y F, et al. Small-object detection for UAV-based images using a distance metric method[J]. Drone, 2022, 6(10): 308.
- [14] 冉宁,施高朗,张少康,等.基于 YOLOv8 的遥感小目标检测算法[J]. 电子测量与仪器学报, 2025, 39(5): 197-207.
- RAN N, SHI G L, ZHANG SH K, et al. Remote sensing small target detection algorithm based on YOLOv8[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5): 197-207.
- [15] WANG G, CHEN Y F, AN P, et al. UAV-YOLOv8: A small-object-detection model based on improved YOLOv8 for UAV aerial photography scenarios[J]. Sensors, 2023, 23(16): 7190.
- [16] SAPKOTA R J, MENG ZH CH, CHURUVIYA M, et al. Comprehensive performance evaluation of YOLOv12, YOLO11, YOLOv10, YOLOv9 and YOLOv8 on detecting and counting fruitlet in complex orchard environments [J]. ArXiv preprint arXiv: 2407. 12040, 2024.
- [17] 吴葛,朱宇凡,贾泽宇.改进 YOLO11 的 PCB 表面缺陷检测方法 [J]. 电子测量技术, 2025, 48 (14): 136-145.
- WU G, ZHU Y F, JIA Z Y. Improved PCB surface defect detection method based on YOLO11 [J]. Electronic Measurement Technology, 2025, 48(14): 136-145.
- [18] CAO J SH, BAO W SH, SHANG H X, et al. GCL-YOLO: A GhostConv-based lightweight yolo network for UAV small object detection[J]. Remote Sensing, 2023, 15(20): 4932.
- [19] FENG Y F, HUANG J G, DU SH Y, et al. Hyper-YOLO: When visual object detection meets hypergraph computation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47(4): 2388-2401.
- [20] WANG J W, YANG W, GUO H W, et al. Tiny object detection in aerial images [C]. 2020 25th International Conference on Pattern Recognition (ICPR), 2021: 3791-3798.
- [21] LI K, WAN G, CHENG G, et al. Object detection in optical remote sensing images: A survey and a new benchmark[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 159: 296-307.
- [22] DU D W, ZHU P F, WEN L Y, et al. VisDrone-DET2019: The vision meets drone object detection in image challenge results [C]. IEEE International Conference on Computer Vision Workshop, 2019: 213-226.

作者简介

冉宁(通信作者),博士,副教授,主要研究方向为深度学习、目标检测等。

E-mail:ranning87@hotmail.com

宋子昊,硕士研究生,主要研究方向为深度学习、目标检测。

E-mail:1209408321@qq.com