

## 【航空管理与安全】

## 基于改进 YOLOv8n 的无人机目标检测算法

余华东<sup>1</sup>, 张步忠<sup>2</sup>, 耿家礼<sup>1</sup>, 刘华喜<sup>1</sup>

(1. 安徽财贸职业学院 信息工程学院, 安徽 合肥 230601;

2. 安庆师范大学 计算机与信息学院, 安徽 安庆 246001)

**摘要:**针对无人机在复杂环境下对目标检测精度低、泛化力弱等问题,提出了一种基于改进 YOLOv8n 的无人机目标检测算法。首先,在原 YOLOv8n 的 C2f 模块中引入了可以优化网络效率的 ESP 模块来改进 Bottleneck 结构,降低了原模型的参数量和计算量;其次,添加一个小目标检测层以提高无人机对目标的监测能力;最后,在颈部模块相继引入轻量级上采样算子与注意力机制,增强了上采样特征融合,提高了无人机的目标检测精度。实验结果表明,改进后的算法与原算法相比,在无人机目标检测应用上降低了模型参数量,在 VisDrone2019 数据集上,  $mAP@0.5$  和  $mAP@0.5:0.95$  分别高达 85% 和 75%, 比原算法分别提高了 2% 和 1.5%。高精度检测结果和降低的模型参数量充分证明了改进后算法的有效性和实用性。

**关键词:**目标检测; YOLOv8n; 上采样算子; 注意力机制; 特征融合

**中图分类号:** V 19; TP 391 **文献标识码:** A DOI:10.13486/j.issn.2097-4973.2025.04.003

近年来,无人机凭借其独到的便捷性和优越性,在军用、民用以及商业等领域的应用愈来愈广泛<sup>[1]</sup>。目标检测技术作为近几年人工智能发展热点中的一项关键技术日趋成熟。然而,对于复杂环境下的小目标物体(尺寸小于  $32 \times 32$ )存在色差、能见度等问题,目标检测技术亟待进一步完善<sup>[2]</sup>。

随着人工智能的快速发展,深度学习被愈来愈多地应用在目标检测方面。当前深度学习检测方法主要分为两类<sup>[3]</sup>:检测精度较高的双阶段目标检测算法(如 R-CNN、Fast R-CNN、Faster R-CNN 等)<sup>[4-6]</sup>和检测速度较快、模型参数量更少的单阶段目标检测算法(如 SSD、YOLO 等)<sup>[7-8]</sup>。双阶段目标检测算法首先会生成大量候选框,接着逐个对候选框进行特征提取、分类和边界框回归,达到对目标的定位和检测,这样会导致计算量随候选框数量线性增长,从而加大计算复杂度;单阶段目标检测算法不存在提取候选区的流程,它将整张图作为输入数据,在输出层直接反馈边界框的坐标和特征信息,虽在精度方面有所欠缺,但实时性更为出色,检测速度也更快<sup>[9]</sup>。目前,在无人机执行目标检测任务时,常用算法当属单阶段目标检测算法里的 YOLO 系列算法。

当环境复杂、光线模糊或遮挡干扰时,无人机视角下的目标检测尚不理想。为提升无人机在复杂环境下的目标检测性能,相关学者进行了一系列研究。Cao 等在 YOLOv5 网络结构上增加多尺度特征融合模块来提高小目标的监测精度,因要处理和融合不同尺度的特征图,从而增加了模型的计算复杂度和推理时间<sup>[10]</sup>。Li 等提出用自适应特征融合技术来弥补模型在小目标识别上的短板,采用更为轻量级的

收稿日期:2025-02-24

基金项目:安徽省高校自然科学研究重点项目(2024AH050023);安徽省职业与成人教育学会教育教学研究规划课题(AZCJ2024008);安徽省质量工程教育教学一般研究项目(2023jyxm1548)

第一作者简介:余华东(1984—),男,安徽太湖人,讲师,硕士,主要从事人工智能研究。E-mail:171083414@qq.com

C3GhostV2 网络架构代替 YOLOv7 模型的主干模块,但这样做会导致泛化力弱<sup>[11]</sup>。史涛等基于 YOLOv8n 提出 CF-FPN 特征融合结构,采用具有长程依赖性和自适应能力的 SPPF-LSKA 模块,此模块虽然能够对不同尺度特征的冲突信息起到抑制作用,但在目标被遮挡时,其效果便会大打折扣<sup>[12]</sup>。张芯源等提出的 YOLOv7-tiny 算法虽然属于轻量化设计,推理速度快,但小目标漏检率高<sup>[13]</sup>。Zhang 等在对抗学习增强小目标特征方面有所创新,虽然显著提升了小目标 *mAP*,但模型复杂、实时性低、依赖对抗训练,跨数据集性能波动较大<sup>[14]</sup>。上述研究虽然对小目标检测算法做了诸多改良,但都未能平衡小目标检测中模型复杂度与检测精度之间的关系,目标检测的研究还有很大空间有待探索。本文在 YOLOv8n 的基础上进行改进,弥补了传统特征融合对低分辨率特征利用不足(导致小目标容易漏检),缺乏能动态特征筛选机制(如未引入注意力)、模型冗余等缺陷,改进后的算法在降低参数数量的同时保障了检测精度,对无人机视角下复杂环境中边界模糊或具有遮挡等干扰的目标物体检测适应性高。

### 1 原 YOLOv8n 算法原理

原 YOLOv8n 是 YOLO 系列算法的第 8 代版本,是一种实时高效准确地识别图像中存在的各种目标的检测算法。原 YOLOv8n 算法的体系架构设计逻辑,涵盖骨干区域(Backbone)、颈部区域(Neck)和检测头部组件(Head)。图 1 展示了原 YOLOv8n 算法结构。

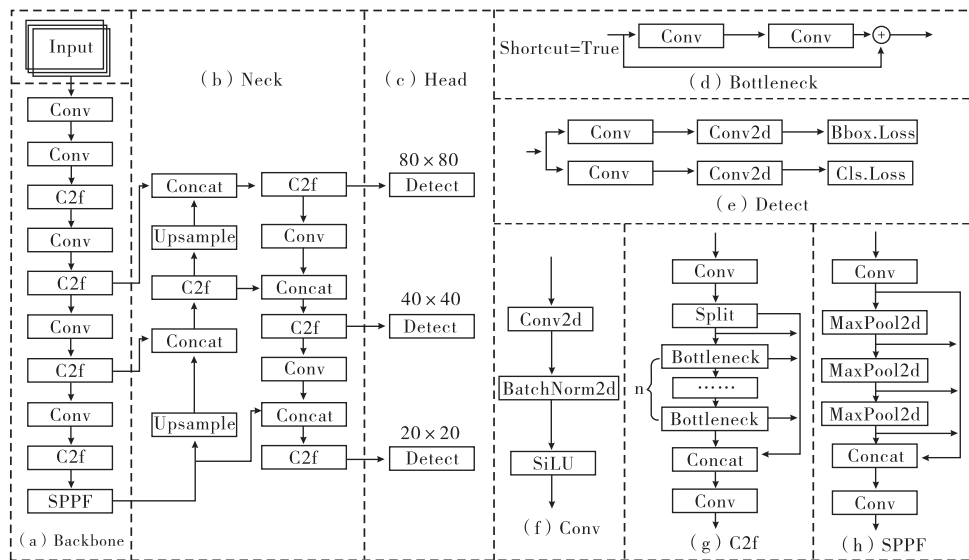


图 1 原 YOLOv8n 模型结构

原 YOLOv8n 算法:C2f 模块采用跨阶段局部网络以获得更丰富的梯度流,增强了模型对不同尺寸物体的检测能力。SPPF 模块先将尺寸各异的子特征图实施池化操作,再将生成的结果进行集成,有效捕捉不同比例的特征信息,得到固定尺寸的输出,实现了局部特征与全局特征的融合,能够更好地提取特征。Neck 模块采用基于特征金字塔网络(Feature Pyramid Network,FPN)设计思想的路径聚合网络(Path Aggregation Network With,PAN)结构<sup>[15]</sup>,将上层特征融入浅层网络特征中,检测头使用目前主流的解耦头结构(Decoupled-head),将分类和检测头分离,各自计算损失,只保留解耦的分类和回归损失,以提高运算效率。但是,原 YOLOv8n 算法模型在复杂场景下,对模糊、较小、不规则及遮挡的目标物体检测精度不高,模型参数量较大,实时性也不理想,容易产生误检、漏检。

### 2 改进后的 YOLOv8n 算法

为了提高无人机目标检测的精准度,改进后的 YOLOv8n 算法内容如下:在 C2f 中引入 ESP 模块替

换 Bottleneck 中原有的一个卷积,这样可以提取网络降低原模型参数量和计算量;为减小无人机飞行过程中对小目标出现误检和漏检的发生率,添加小目标检测层,提高对空中小目标的检测能力;在 Neck 部引入轻量级上采样算子(Content-aware Reassembly of Features, CARAFE)与注意力机制(Efficient Channel Attention, ECA)<sup>[16]</sup>,引入一种新的度量方法(NWD)<sup>[17]</sup>来优化损失函数,减少上采样过程中的信息损失,提取目标特征,有效地提高模型对空中模糊目标和小目标的检测精度。

### 2.1 优化损失函数

原 YOLOv8n 算法采用  $CIoU$  作为损失函数以提高目标检测的准确性和稳定性。其公式<sup>[18]</sup>如下:

$$CIoU = 1 - IoU + \left( \frac{p^2(b, b^{gt})}{c^2} \right) + \alpha v。$$

式中:  $p^2(b, b^{gt})$  表示预测框和真实框中心点之间欧氏距离的值;  $c$  代表可以完全涵盖预测框和真实框的最小边界框的对角线长度;  $\alpha$  是平衡参数;  $v$  代表预测框和真实框长宽比方面的差值<sup>[19]</sup>;  $IoU$ <sup>[20]</sup> 即交并比,是衡量网络预测结果和真实结果之间准确程度的指标,不同形状的目标其  $IoU$  值差异显著,尤其是那些较小的目标,位置上的微小偏差都会导致  $IoU$  降低,进而导致预测不够准确。

为弥补  $IoU$  的缺陷,这里引入 NWD 来代替传统的交并比度量方法, NWD 对不同形态的目标几乎不敏感,它使用归一化 Wasserstein 距离来评估高斯分布相似程度,把边界框作为二维高斯分布来构建,赋予中心最高权重,且像素的重要程度依次朝边界呈递减态势。多数不同形态的小目标物体并非典型的矩形,其边界框内时常存在背景元素,前景元素多分布在边界框中心位置,背景元素基本分散在边界框的边缘地带。故而,两个边框间的相似程度能够等价转换为两个高斯分布间的分布距离, NWD 尤其适合对小目标开展检测。NWD 的计算公式如下:

$$NWD(N_x, N_y) = \exp\left(-\frac{\sqrt{W_2^2(N_x, N_y)}}{C}\right)。$$

式中:  $W_2^2(N_x, N_y)$  表示距离度量,  $C$  表示与数据集密切关联的常数。

### 2.2 改进后的 C2f 模块

#### 2.2.1 可变形卷积

传统的卷积对规则形状的中、大型目标检测应用较好,但对形态多变的小目标检测应用不甚理想。为弥补传统卷积的缺点,引入可变形卷积(deformable convolution)<sup>[21]</sup>。可变形卷积于传统卷积的采样位置增添偏移量,从而扩大了卷积核的范围,同时根据输入的不同特征图实时做出调整,使其更适合处理形态复杂的物体,尤其在小目标检测方面表现出色。

可变形卷积对某个采样点的输出  $p_0$  特征值

$$y(p_0) = \sum_{n=1}^n w_n \cdot x(p_0 + p_n + \Delta p_n) \cdot \Delta m_n。$$

式中:  $n$  表示卷积核的个数;  $w_n$  表示第  $n$  个位置的权重;  $p_n$  表示第  $n$  个位置的偏移量;  $\Delta p_n$  和  $\Delta m_n$  分别表示第  $n$  个位置的科学系偏移量和调制标量;  $\Delta m_n$  用来计算偏移量权重,当遇到无关信息时直接变为 0<sup>[22]</sup>。可变形卷积操作流程如图 2 所示。




图 2 可变形卷积的操作流程

#### 2.2.2 C2f 模块

ESP 模块采用 GhostNet 网络结构,是基于 EP 模块<sup>[23]</sup>的改进,ESP 模块包括高效多尺度轻量化卷积(Efficient Multi-scale Lightweight Convolution, EMSLC)和逐点卷积两部分。用 ESP 模块替代 C2f 中 Bottleneck 结构中的第二个卷积,这样可以降低模型参数量和计算量。在非工作状态下,ESP 模块将一半通道进行操作,这样可以减少模块中的参数冗余和计算。EMSLC 模块可以通过多尺度卷积的方式进行

不同视角下的特征提取,这使得网络可以从输入图像中获取更多特征信息,同时通过分组操作降低网络的计算成本。逐点卷积可以实现物体宽度( $w$ )和高度( $h$ )不变,通过改变输入特征图的通道数,以较小的计算成本对通道信息进行重新分配,在保持模型性能的同时,减少资源消耗,且不影响空间维度。

ESP 模块工作原理为:第 1 步,将输入通道分成四组,这样可以减少模块中的参数量和计算量,提高网络效率。第一组通过连接  $1 \times 1$  Ghost 的卷积,采用 Ghost 卷积可减少计算量,并提高网络的计算效率;为避免采用过多的 Ghost 卷积使模型特征提取能力下降,所以第二、三、四组通道分别采用  $3 \times 3$ 、 $5 \times 5$ 、 $7 \times 7$  的普通卷积方式。第 2 步,每组通道采用不同大小的卷积获取不一样尺度的特征,有效减少了特征图间的冗余性和相似性。第 3 步,为了使各组通道提取的不同特征相关信息之间进行交互,需要用  $1 \times 1$  的卷积核进行逐点卷积,从而实现跨通道的特征融合,增强特征表达能力,这样 4 个  $1/4$  通道合并为一个通道,输出最终的特征图。ESP 模块工作原理见图 3,在 C2f 结构中引入 ESP 模块前后对比见图 4。

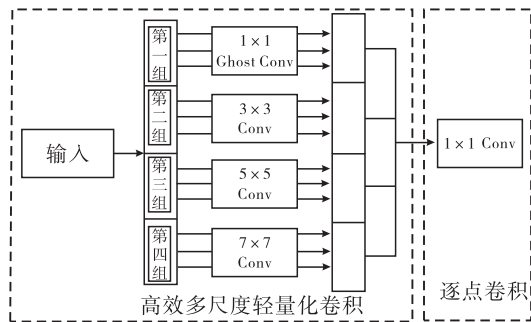


图 3 ESP 模块工作原理

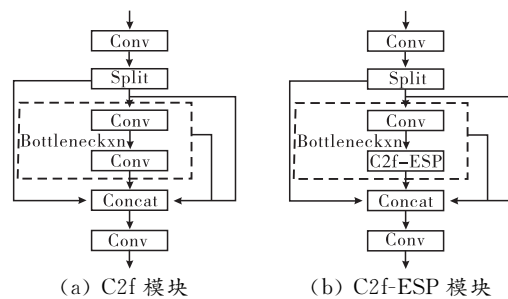


图 4 引入 ESP 模块前后对比图

将本文改进 ESP 模块后算法与原 YOLOv8n 模型进行对比分析:本文算法通过分组扩张卷积增大感受野,引入了通道注意力权重优化模块,降低了参数量及计算效率,使目标检测的精准率和召回率分别提升了 6.1% 和 0.4%。这种方法特别适合用在无人机端侧部署上(例如嵌入式处理器、GPU 等硬件设备),当无人机在执行低空拍摄任务且面对复杂环境时,针对其中小目标的检测具备较高的适配性和有效性。

### 2.3 小目标检测层

原 YOLOv8n 模型对被遮挡或模糊的小目标特征信息提取较难,为解决此类问题,在原 YOLOv8n 模型中增添了面向小目标的检测层,把浅层特征与深层特征整合后再进行检测,令网络更加聚焦小目标样本,进而改善检测成效。为保留小目标的更多细节,将输出特征图由原算法模型尺寸增添为  $160 \times 160$  输出。图 5 为两种算法的特征对比图。

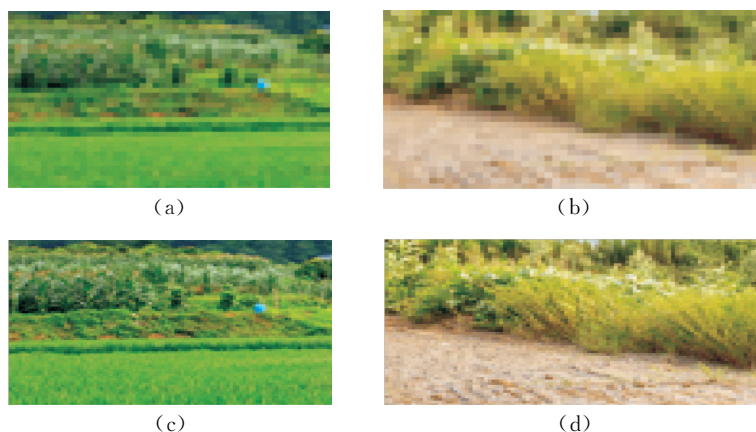


图 5 特征对比图

通过图 5 可看出,原算法采样的倍数大,小目标在 32 倍的下采样中,深层特征图捕捉到小目标的特征

信息较少,不利于小目标检测,如图 5(a)(b)所示。改进后的 YOLOv8n 算法模型,将特征图增添为  $160 \times 160$  输出,从而导致计算量增大。为了解决计算量增大问题,用添加的小目标检测层替换原本的  $20 \times 20$  的特征图输出,这不仅保障了计算量,还提高了对小目标的检测性能,如图 5(c)(d)所示。

本文算法加入小目标检测层后,与传统特征金字塔对比分析如表 1 所示。

表 1 小目标检测层与传统特征金字塔(FPN/PANet)对比结果

对比维度	原 YOLOv8n (传统 FPN)	本文算法 (新增小目标检测层)	优势与适用性
特征融合策略	固定权重多尺度融合	动态权重分配(DWF)+ 高分辨率浅层特征强化	自适应融合深浅层特征,减少小目标特征丢失
检测头设计	3 个检测头( $80 \times 80$ 、 $40 \times 40$ 、 $20 \times 20$ )	增加 $160 \times 160$ 检测头	直接检测 $16 \times 16$ 像素以下目标,解决无人机图像中小目标占比高的问题。以极小计算代价换取小目标 $mAP @ 0.5$ 提升了 0.9% (VisDrone2019 测试结果)

### 2.4 上采样算子

为了提高无人机在复杂环境中对小目标的特征提取能力,有效搜集更多的上下文信息,最大化地保留输入特征图像的局部信息,在原算法 neck 中用轻量级上采样算子 CARAFE<sup>[24]</sup> 替换原算法中使用的最近邻上采样操作,在保持轻量级设计<sup>[25]</sup>的同时,增强对小目标的感知。为进一步增强对小目标特征的识别精度,在每个 CARAFE 操作之后引入在 SE<sup>[26]</sup>基础上改进后的注意力机制 ECA<sup>[27]</sup>。

ECA 采用一维卷积代替全连接层,用有利于学习网络特征的不降维跨通道交互机制使模型参数变小的同时,仅需增加少量参数就可以提高目标检测性能。在 ECA 模块中,输入特征图首先通过全局平均池化,将大小由变  $C \times W \times H$  为  $1 \times 1 \times C$ ;接着,开展卷积核大小为  $K$  的一维卷积运算,构建局部通道间的跨通道通信;最后,将经 Sigmoid 函数生成的一维向量与平均池化前的输入特征图相乘,最终得到特征图。ECA 原理结构如图 6 所示。




图 6 ECA 原理结构图

ECA 的结构中  $K$  与  $C$  存在映射关系,具体如公式如下:

$$K = \varphi(C) = \left\lfloor \frac{\log_2 C}{\gamma} + \frac{\beta}{\gamma} \right\rfloor_{\text{odd}} \quad (1)$$

式中: $K$  表示卷积核的大小, $C$  表示通道数,odd 代表奇数, $\lfloor t \rfloor_{\text{odd}}$  则表示距离  $t$  最近的奇数。 $\gamma$  和  $\beta$  分别设置为 2 和 1,以调整  $C$  和卷积核之间的比例。

输入特征图尺寸  $H \times W \times C_{\text{in}}$ ,卷积核  $K \times K \times C_{\text{out}}$ ,卷积层的  $FLOPs$  主要由卷积核的计算量决定, $FLOPs$  用来衡量模型的计算复杂度,其计算公式如下:

$$FLOPs = 2 \times C_{in} \times C_{out} \times K \times K \times H_{out} \times W_{out}。$$

式中:  $C_{in}$  和  $C_{out}$  分别表示输入和输出特征图的通道数,  $H_{out}$  和  $W_{out}$  分别表示输出特征图的高度和宽度,  $K$  与式(1)中同义。

改进后 YOLOv8n 算法中 CARAFE 与 ECA 模块并非独立工作,而是通过特征“增强-融合-校准”的协同机制,贯穿于特征提取、多尺度融合和检测输出的全过程,其工作流程如下:

第 1 步,输入特征图,在 Backbone 模块进行特征提取,用 ESP 模块替代原 C2f 模块,通过多分支膨胀卷积提取多尺度特征,保留小目标的边缘和纹理信息。

第 2 步,在自顶向下路径中应用 CARAFE 上采样和 ECA 注意力机制,CARAFE 负责将深层低分辨率特征图(如  $20 \times 20$ )上采样至高分辨率(如  $40 \times 40$ ),其动态生成上采样核的特性,有效缓解了双线性插值导致的细节模糊问题,有助于恢复更精细的空间信息。

第 3 步,将上采样后的特征图与浅层特征图进行融合,而 ECA 注意力(自底向上路径)可以在特征融合后对特征图进行最后依次通道校准,这样可以确保复杂环境中小目标的特征响应,减少漏检。

第 4 步,由 Head 模块中小目标检测层( $160 \times 160$ )输出。

改进后的 YOLOv8n 模型结构如图 7 所示。

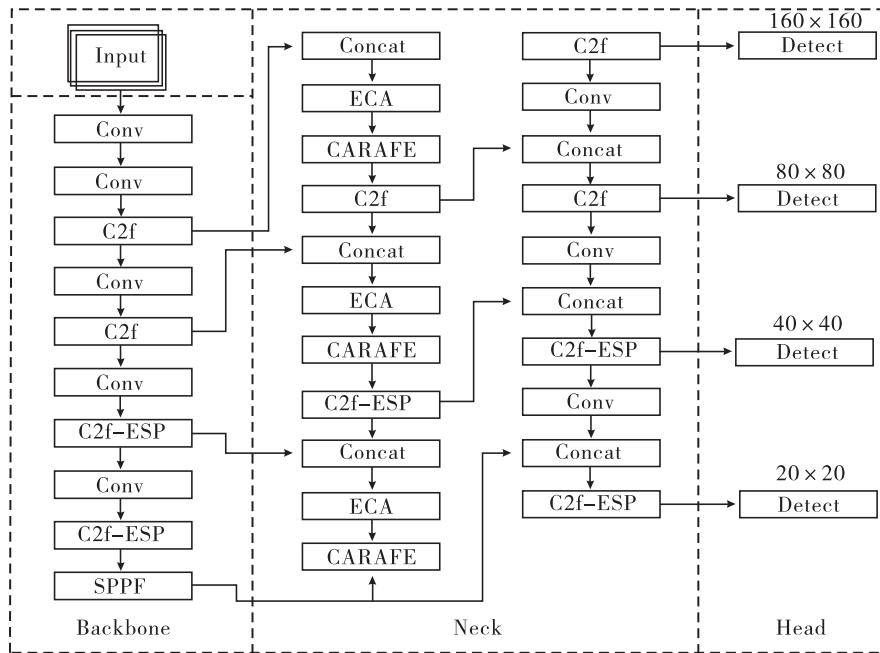


图 7 改进后的 YOLOv8n 模型结构

### 3 实验与结果分析

#### 3.1 实验环境配置

实验平台的操作系统为 Ubuntu 20.04 LTS,CPU 为 Intel Core i9-13900H CPU@2.4GHZ,GPU 为 NVIDIA RTX 3060 12G。实验环境为 pytorch 2.0、python 3.8。实验在 YOLOv8n 模型上进行训练,训练轮数为 150,早停机机制设置为 30,批大小(batch)设为 4,采用标准的输入尺寸  $640 \times 640$ 。

#### 3.2 数据集与评价指标

本文选用 VisDrone2019 作为实验数据集,该数据集主要由小目标组成,包含多种复杂场景和视觉下的无人机航拍图像及视频。从包含 7500 张图片的数据集中取 500 张用于实验训练。采用平均精度均值 ( $mAP@0.5$ )、平均  $mAP$  值 ( $mAP@0.5;0.95$ )、精确率  $P$  (Precision)、召回率  $R$  (Recall)、参数量

(Params)和每秒检测帧数(FPS)作为评价指标<sup>[28]</sup>,全面评估算法的性能。计算如公式如下:

$$P = \frac{TP}{TP + FP}, R = \frac{TP}{TP + FN},$$

$$mAP = \frac{1}{N} \sum_{i=1}^n AP_i, AP = \int_0^1 P(R) dR。$$

式中:TP 是正确检测目标样本数;FP 是错误检测目标样本数;FN 表示漏检目标样本数;n 表示包含类别特征图的总数;AP 表示对不同类别进行目标检测得出的平均精度,是基于 P(纵轴)、R(横轴)曲线计算出的面积。

### 3.3 对比实验

将本文算法与不同版本的 YOLO 系列模型算法在数据集 VisDrone2019 上的表现进行对比。结果显示,改进后 YOLOv8n 算法的  $mAP@0.5$  和  $mAP@0.5:0.95$  分别达到了 85% 和 75%,较基础模型 YOLOv8n 分别提升了 2% 和 1.5%;在精确率和回收率等指标上均有显著提升,同时保持了较高的 FPS。本文算法能以较少的参数量取得高精度的检测结果,证明了其具备广阔的应用前景和价值。具体数据如表 2 所示。

表 2 改进算法与其他算法对比

模型名称	$mAP@0.5/\%$	$mAP@0.5:0.95/\%$	P/%	R/%	FPS	参数量
原 YOLOv8n	83.0	60.0	77.0	90.1	32	25
改进后 YOLOv8n(本文算法)	85.0	75.0	88.0	92.0	35	20
YOLOv3	65.2	51.3	71.5	80.0	25	60
YOLOv4	78.2	52.4	73.5	82.1	28	70
YOLOv5	80.6	54.5	74.0	84.3	29	50
YOLOv7	84.7	56.1	75.0	89.6	30	45

### 3.4 消融实验分析

为了验证改进算法对小目标检测的有效性,以 YOLOv8n 为基准模型进行消融实验。在相同任务下,实验结果表明,每一个改进措施都对算法性能的提升起到了积极作用,增强了模型对小目标的检测能力。消融实验结果如表 3 所示。

表 3 消融实验结果

算法	$mAP@0.5/\%$	$mAP@0.5:0.95/\%$	P/%	R/%	FLOPs(G)
原 YOLOv8n	83.0	60.0	77.0	90.1	8.20
YOLOv8n+ESP	83.2	63.1	83.1	90.5	7.90
YOLOv8n+ESP+P2	83.9	64.6	84.9	91.0	7.70
YOLOv8n+ESP+P2+CARAFE	85.0	75.0	87.7	91.8	7.50
YOLOv8n+ESP+P2+CARAFE+ECA(本文算法)	85.0	75.0	88.0	92.0	7.10

### 3.5 检测效果对比

为验证本文算法目标检测的有效性,挑选白昼和夜晚两种不同场景进行目标检测实验。白昼,原算法尽管有效检测出了近距离的目标,对于后排、边缘车辆及行人等小目标却出现了漏检问题;夜晚,原算法对

较远处及模糊地带的小目标存在漏检情况。针对原算法检测中存在的漏洞,本文算法在一定程度上有所改善,能将不易察觉到的小目标成功检测,准确率更高。实验结果如图 8 所示,(a)(c)为原算法检测结果,(b)(d)为改进后的算法检测结果。

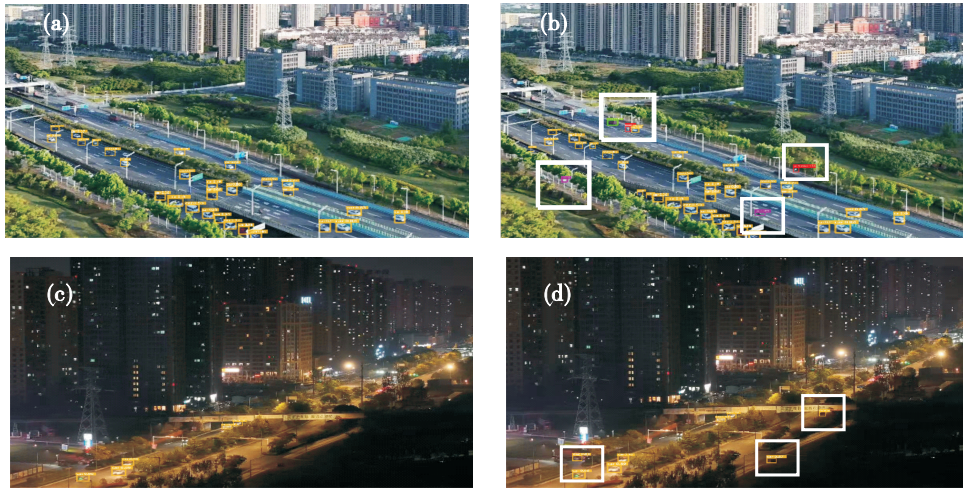


图 8 算法检测效果对比图

#### 4 结论

本文针对无人机在复杂环境下目标检测精度低、泛化力弱的问题,提出了一种基于改进 YOLOv8n 的检测算法,并通过实验验证了其有效性。本文算法通过对原 YOLOv8n 网络结构优化,降低了模型参数量,在保证精度的同时显著提升推理效率。通过新增小目标检测层及改进特征融合与注意力协同机制,在降低参数量的同时,使 FLOPs 降低了 13.4%, $mAP@0.5$  和  $mAP@0.5:0.95$  分别达到 85% 和 75%,较原 YOLOv8n 算法提升了 2% 和 1.5%。本文算法的轻量化设计与高精度特性,能够更快地完成计算,满足实时性需求,对环境复杂、遮挡等干扰的情况下的目标检测具有较强的鲁棒性。本文算法还可广泛应用于无人机农业巡检(对农作物进行病害鉴别)、城市安防(低空目标追踪)、自动驾驶等领域。接下来,将结合模型量化技术进一步压缩计算量,将软件、算法或系统优化调整,使其能够适配边缘端硬件(如传感器、嵌入式设备、智能终端等);针对特殊光照或目标模糊等问题下的目标检测进行优化特征增强模块,并加强对多任务扩展(如目标检测-分割联合建模)的探索,以增强算法适用性。

#### 参考文献:

- [1] 孙佳宇,徐民俊,张俊鹏,等. 优化改进 YOLOv8 无人机视角下目标检测算法[J]. 计算机工程与应用,2025,61(1):109-120.
- [2] ZHAO C, LIU R W, QU J, et al. Deep learning-based object detection in maritime unmanned aerial vehicle imagery: review and experimental comparisons[J]. Engineering applications of artificial intelligence,2024,128:107513.
- [3] 张艳,张明路,吕晓玲,等. 深度学习小目标检测算法研究综述[J]. 计算机工程与应用,2022,58(15):1-17.
- [4] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2014:580-587.
- [5] GIRSHICK R. Fast R-CNN[C]. 2015 IEEE International Conference on Computer Vision (ICCV),

2015:1440-1448.

- [6] 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.
- [7] LYU Z, JIN H, ZHEN T, et al. Small object recognition algorithm of grain pests based on ssd feature fusion[J]. IEEE access, 2021, 9:43202-43213.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016:779-788.
- [9] 王燕妮, 张婧菲. 改进 YOLOv8 的无人机小目标检测算法[J/OL]. 探测与控制学报(2024-12-12) [2025-02-07]. <https://link.cnki.net/urlid/61.1316.TJ.20241212.1003.005>.
- [10] CAO S, WANG T, LI T, et al. UAV small object detection algorithm based on an improved YOLOv5s model[J]. Journal of visual communication and image representation, 2023, 97:103936.
- [11] LI S, WANG S, WANG P. A small object detection algorithm for traffic signs based on improved YOLOv7[J]. Sensors, 2023, 23(16):7145.
- [12] 史涛, 崔杰, 李松. 优化改进 YOLOv8n 实现实时无人机车辆检测的算法[J]. 计算机工程与应用, 2024, 60(9):79-89.
- [13] 张芯源, 高志刚, 冯建文. 基于 YOLOv7-tiny 的轻量级密集人群场景行人检测算法[J]. 软件工程, 2025, 28(1):46-51.
- [14] ZHANG X P, WU J G, PENG Z H, et al. SODNet: small object detection using deconvolutional neural network[J]. IET image processing, 2020, 14(8):1662-1669.
- [15] 梁鑫. 复杂道路环境下的交通标志焦策算法研究[D]. 武汉:中南民族大学, 2023.
- [16] 李培坤, 李锋, 葛忠显, 等. 基于改进 YOLOv8n 的水下目标检测算法[J]. 电子测量技术, 2025, 48(3):172-179.
- [17] WANG J, XU C, YANG W, et al. A normalized Gaussian Wasserstein distance for tiny object detection[J]. arXiv preprint arXiv, 2021:2110.13389.
- [18] 李甜, 林贵敏, 余焯楷. 改进 YOLOv5s 的车辆目标检测研究[J]. 时代汽车, 2024(1):16-18.
- [19] 王健, 肖迪, 冯李航, 等. 基于改进 YOLOv8s 的 PCB 小目标缺陷检测模型[J/OL]. 计算机工程与应用(2024-08-20) [2025-01-17]. <https://link.cnki.net/urlid/11.2127.tp.20240819.1152.016>.
- [20] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[C]//Proceedings of the AAAI conference on artificial intelligence, 2020, 34(7):12993-13000.
- [21] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks[C]//Proceedings of the IEEE international conference on computer vision, 2017:764-773.
- [22] 梁秀满, 贾梓涵, 刘振东, 等. 改进 YOLOv8n 的无人机航拍图像检测算法[J]. 电光与控制, 2025, 32(1):34-40.
- [23] ZHANG X R, WANG Y L, FANG H S. Steel surface defect detection algorithm based on ESI-YOLOv8n[J]. Materials research express, 2024, 11(5):056509.
- [24] WANG J Q, CHEN K, XU R, et al. CARAFE: Content-aware reassembly of features[C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019:3007-3016.
- [25] 卢开喜, 段先华, 陶宇诚, 等. KThin-YOLOV7: 轻量级的焊接件表面缺陷检测[J]. 电子测量技术, 2024, 47(7):9-18.

- [26] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018:7132-7141.
- [27] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020:11531-11539.
- [28] 张相胜, 沈庆. 基于改进 YOLOv3 的多目标跟踪算法研究[J]. 激光与光电子学进展, 2021, 58(16): 190-200.

## Algorithm research in UAV view based on improved YOLOv8n object detection

YU Huadong<sup>1</sup>, ZHANG Buzhong<sup>2</sup>, GENG Jiali<sup>1</sup>, LIU Huaxi<sup>1</sup>

(1. *Information Engineering College, Anhui Finance & Trade Vocational College, Hefei 230601, China;*

2. *School of Computer Science and Information, Anqing Normal University, Anqing 246001, China*)

**Abstract:** This paper proposes a drone object detection algorithm based on YOLOv8n to address the problems of low object detection accuracy and weak generalization force in complex environments. The improved algorithm introduces an ESP module that can optimize network efficiency in C2f to improve the Bottleneck structure, reducing the parameter amount and calculation amount of the original model; adding a small object detection layer to improve the object detection ability; introducing lightweight upsampling operators and attention mechanisms in the Neck part, enhancing the upsampling feature fusion and improving the object detection accuracy. Experimental results show that compared with the original algorithm, the improved algorithm not only reduces the model parameters, but also increases by 85% and 75% on the VisDrone2019 dataset, respectively, 2% and 1.5% higher than the original algorithm. The high-precision detection results and reduced model parameters fully prove the effectiveness and practicality of the improved algorithm.

**Keywords:** object detection; YOLOv8n; up-sampling operator; attention mechanism; feature fusion

(责任编辑:唐立平)

**引用格式** 余华东,张步忠,耿家礼,等. 基于改进 YOLOv8n 的无人机目标检测算法[J]. 山东航空学院学报, 2025, 42(4): 20-29.

YU H D, ZHANG B Z, GENG J L, et al. Algorithm research in UAV view based on improved YOLOv8n object detection[J]. Journal of Shandong University of Aeronautics, 2025, 42(4): 20-29.