

DOI:10.20079/j.issn.1001-893x.240527001

# 基于多尺度特征的无人机目标识别算法\*

张博文, 薛波

(江苏理工学院 电气信息工程学院, 江苏 常州 213000)

**摘要:**针对无人机对于不同尺度的目标识别存在误检和漏检等问题,提出了一种多尺度融合机制的 YOLOv8-FDT 无人机目标识别算法。首先,在基线模型 Neck 层中添加动态上采样模块,旨在降低模型参数量,提高模型对于目标识别的实时性。此外,为了使得整个算法模型在特征融合阶段能够捕捉目标的不同尺度语义信息,融合自适应下采样和深度卷积,设计特征聚焦扩散金字塔网络 (Feature Diffusion Pyramid Network, FDPN)。通过无人机航拍数据集 VisDrone2019 的实验表明,改进后模型所有类别平均精度均值 (mean Average Precision, mAP) 相较基线模型提升 6.24%。

**关键词:**无人机;目标识别;特征聚焦;多尺度融合

开放科学(资源服务)标识码(OSID):



微信扫描二维码  
听独家语音释文  
与作者在线交流  
享本刊专属服务

中图分类号:TP391.4 文献标志码:A 文章编号:1001-893X(2025)11-1773-08

## UAV Target Recognition Based on Multi-scale Features

ZHANG Bowen, XUE Bo

(School of Electrical and Information Engineering, Jiangsu Institute of Technology, Changzhou 213000, China)

**Abstract:** In view of the problems of false detection and missed detection when an unmanned aerial vehicle (UAV) detects targets at different scales, a YOLOv8-FDT UAV algorithm model with a multi-scale fusion mechanism is proposed. First, a dynamic upsampling module is added to the Neck layer of the baseline model to reduce the number of model parameters and improve the real-time performance of the model for target recognition. In addition, in order to enable the entire algorithm model to capture different scale semantic information of the target in the feature fusion stage, adaptive downsampling and depth convolution are integrated to design the feature diffusion pyramid network (FDPN). Finally, experiments on the UAV aerial photography dataset VisDrone2019 show that the mean average precision (mAP) of all categories of the improved model is increased by 6.24% compared with that of the baseline model.

**Key words:** UAV; small target recognition; focus feature; multi-scale fusion

### 0 引言

近年来,无人机因具备快速启动、降落和重新部署的能力,从而能提高工作效率<sup>[1]</sup>,在各领域得到了迅速普及<sup>[2]</sup>。将先进的目标识别算法与无人机技术相结合,运用复杂的计算机视觉技术<sup>[3]</sup>,使得无人机能够实时准确地识别和跟踪目标。

目前主流的目标识别方法是引入特征金字塔网络,该网络在算法模型中结合了多级特征表示,以增

强对小物体的感知,例如 Faster R-CNN<sup>[4]</sup>、SSD<sup>[5]</sup>和 YOLO<sup>[6]</sup>等算法。此外,研究人员致力于改进网络架构,同时结合注意力机制、特定损失函数等方法进一步提高目标识别能力。李大湘等人<sup>[7]</sup>使用位置敏感目标检测模型以应对无人机在复杂场景中的目标识别,较基线模型精度提高 4.1%。Woo 等人<sup>[8]</sup>采用卷积注意力模块 (Convolutional Block Attention Module, CBAM),将空间注意力机制和通道注意力

\* 收稿日期:2024-05-27;修回日期:2024-08-19  
基金项目:国家自然科学基金资助项目(62003151)  
通信作者:薛波 Email:dxbo@jsut.edu.cn

机制相结合,实现对关键信息的关注和不必要信息的抑制,提高了无人机对于小目标的特征的提取能力。罗旭鸿等人<sup>[9]</sup>在 YOLOv5 模型的基础上,添加一层小目标检测层,提高小目标识别的准确性。Lin 等人<sup>[10]</sup>利用加权双向特征金字塔网络(Bidirectional Feature Pyramid Network, BiFPN)实现更复杂的特征融合,进一步捕捉小目标的语义信息。

以上方法虽然能进一步提升目标识别能力,但依然出现识别精度低和模型复杂度高问题,因此,本文以单阶段目标检测 YOLOv8 模型为基础,提出一种改进的无人机目标识别算法 YOLOv8-FDT。主要工作如下:设计特征聚焦扩散金字塔网络(Focusing Diffusion Pyramid Network, FDPN),将 Backbone 不同尺度的信息进行融合,使得网络具有丰富的上下文信息;在 Neck 层加入动态上采样模块,利用动态可调采用因子获取的采样集,提高目标识别的准确性并降低模型参数量。

### 1 无人机目标识别算法简介

无人机在目标识别过程中,通常需要同时监测多种类型的目标,而在目标出现重叠和特征信息模糊等情况下,不能有效地识别。目前主流的 YOLO 算法模型不仅能更为准确地识别小目标,例如人、车

辆、建筑物等,而且能够提高目标识别的实时性。融合 YOLOv8 的无人机目标识别算法,通过实验,处理图片信息的帧速率可达到 180.7,提高了无人机在处理大量目标时的效率<sup>[11]</sup>。YOLOv8 模型在 Backbone 和 Neck 层使用多个 Conv,其结构主要由 Conv2d、BatchNorm2d、SiLU 组成,多个 Conv 排列组合使得模型具有较高的检测精度和速度,并且利用特征重用来解决梯度弥散问题,从而保证在很大程度上保留原始数据<sup>[12]</sup>。

如图 1 所示,输入特征具有多尺度信息,存在远小近大情况。首先,模型将图片尺寸调整为 640×640。其次,在 Backbone 层中所有模块按照顺序进行连接,采用跨级特征融合网络(CSPDarknet53 to 2-Stage FPN, C2f)模块和快速空间金字塔池化(Fast Spatial Pyramid Pooling, SPPF)模块,利用 C-2f 的梯度分流,并结合 SPPF 融合大尺度信息,从而增强模型特征提取能力。然后,在 Neck 层使用自上而下的特征融合方式<sup>[13]</sup>,结合特征金字塔网络和路径聚合网络,有助于增强特征图信息流,提高颈部网络特征融合能力。最后,引入无锚框目标检测(Anchor-Free)检测头<sup>[14]</sup>,检测头由回归和分类分支组成,使用二元交叉熵损失进行分类,使用分布式焦点损失进行定位,更好地权衡预测框和实际框<sup>[15]</sup>。

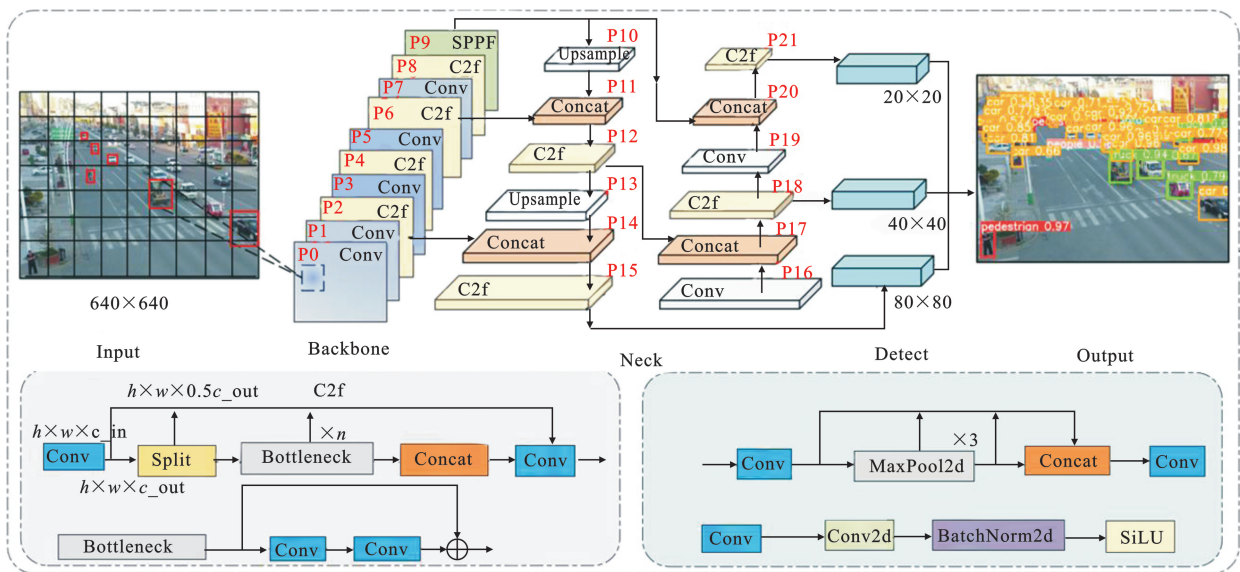


图 1 YOLOv8 算法结构示意图

### 2 改进的无人机目标识别算法

无人机结合 YOLOv8 算法能够实现对目标的识别,但存在一定的局限性。在复杂场景中目标存在

不同的尺度(目标尺寸大小不统一),如行人、车辆等目标在输入特征图中所占像素比例偏小,并且伴随着目标出现远小近大的问题,单一尺度的特征提

取往往无法有效地捕捉到不同尺度目标的重要特征,最终导致模型出现误检或漏检等情况<sup>[16]</sup>。因此,本文基于 YOLOv8n 模型,对无人机目标识别算法进行改进,提出了 YOLOv8-FDT。改进算法框图如图 2 所示,在 P14、P21 将传统卷积替换 DySample,在 Neck 层的 P10、P17 添加 FocusFeature 以融合 Backbone 层 P4、P6、P9 特征图信息。

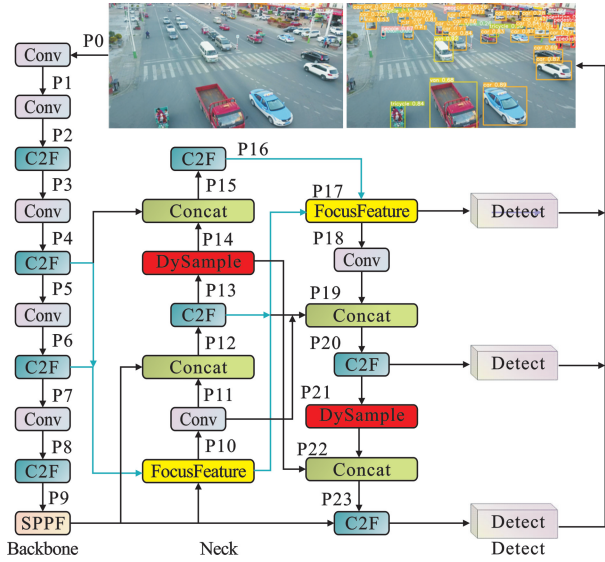


图 2 YOLOv8-FDT 算法结构示意图

### 2.1 动态上采样

上采样的本质属于点采样,动态上采样(Dynamic Sample, DySample)在网络训练过程中并不需要定制 CUDA 包,并且参数数量和 CPU 内存占用率进一步降低。如图 3 所示,动态上采样的一般步骤如下:首先,输入特征图  $X \in H \times W \times C$ ,经过动态采样生成器;其次,产生采样集  $S$ ,采样因子为  $s$ ;最后,网格采样函数通过采样集的位置,对输入特征进行重采样,生成上采样特征  $X'$ ,如式(1)所示:

$$X' = \text{grid\_sample}(X, S) \quad (1)$$




图 3 动态上采样示意

具体实现动态的上采样,需在动态采样生成器中生成动态的偏移量。图 4 所示为静态采样与动态

采样之间的对比,展示了动态采样集是如何产生的。

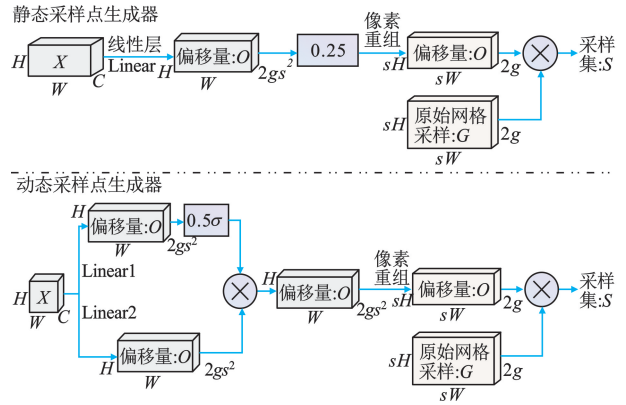


图 4 动态采样点生成器示意

对于静态采样点生成器,输入特征图  $X \in H \times W \times C$ ,使用输入和输出通道数为  $C$  和  $2s^2$  的线性层,生成  $2s^2 \times H \times W$  的偏移量  $O$ ,如式(2)所示:

$$O = \text{Linear}(X) \quad (2)$$

设置采样因子  $s$  为 0.25。经过像素重组,重塑为  $2 \times sH \times sW$  的偏移量  $O$ ,表达式如下:

$$O = 0.25 \text{Linear}(X) \quad (3)$$

$$S = G + O \quad (4)$$

式中: $O$  表示偏移量; $G$  表示原始采样网络;采样集  $S$  表示偏移量  $O$  与原始采样网络  $G$  之和。图 3 和图 4 中, $g$  为将特征图分为  $g$  组。

而动态采样点生成器,结合双线性差值法,依然采用线性投影得到偏移量,通过结合 sigmoid 函数与 0.5 静态因子的乘积,得到  $[0, 0.5]$  可调的动态因子,然后经过像素重塑得到偏移量  $O$ ,如式(5)所示:

$$O = 0.5 \text{sigmoid}(\text{Linear1}(X)) \times \text{Linear2}(X) \quad (5)$$

### 2.2 特征扩散聚焦金字塔网络

特征聚焦扩散金字塔网络,主要思想是借用特征聚焦(Focus Feature)这一结构,使得在特征融合阶段能够进一步获取目标的不同尺度语义信息。如图 5 所示,Focus Feature 主要由自适应下采样和深度卷积组成。首先,特征聚焦模块接收 3 个尺度特征的输入,经过自适应下采样和  $1 \times 1$  的卷积操作;然后,将 3 个不同尺度信息进行整合,并且利用一组并行深度卷积和身份映射,且每个卷积核的大小设置为 1、3、5、7 以获得更多的感受野;最后,使用  $1 \times 1$  卷积调整通道数,与 Concat 中的目标信息进行整合相加输出。在 FDPN 网络中,如图 2 所示,将

Backbone 层中的 P4、P6、P9 作为 3 个不同尺度的输入,在 Neck 层中引入 Focus Feature,整合与 Backbone 中的语义信息,使得浅层与深层信息得以充分融合,以提高模型对于复杂背景下小目标识别的能力。




图 5 特征聚焦结构示意

自适应下采样 (Adaptive Downsample, ADown) 模块引入平均池化层和最大池化层,如图 6 所示。平均池化在输入端将特征图分为两部分,将区域内的图像取平均值,如式(6)所示:

$$\text{AvgPool}(x)_{i,j} = \frac{1}{k_h \times k_w} \sum_{m=0}^{k_h-1} \sum_{n=0}^{k_w-1} x_{i+m,j+n} \quad (6)$$

式中:  $k_h$  和  $k_w$  表示池化核的高度和宽度;  $x_{i,j}$  表示输入特征图  $(i,j)$  的像素值。最大的池化则是将池化区域最大值作为池化结果,而不考虑具体的位置信息。这使得最大池化具有对于输入数据的平移操作不敏感的特性,即使输入数据发生平移,选取的最大值仍然保持不变,如式(7)所示:

$$\text{MaxPool}(x)_{i,j} = \max_{m=0}^{k_h-1} \max_{n=0}^{k_w-1} x_{i+m,j+n} \quad (7)$$

在 Focus Feature 结构中加入 ADown 通过减少参数量来降低模型的复杂度,有助于提高模型的运行效率。




图 6 自适应下采样结构示意

深度卷积 (Depthwise Convolution, DWConv) 是一种通道之间独立进行卷积操作的方式,对输入的每个通道单独进行卷积操作,一个卷积核只处理一个输入通道,若输入特征图具有 3 个输入通道,则由 3 个独立的卷积核进行处理,适用于移动设备等资源受限的场景<sup>[17]</sup>。在 Focus Feature 结构中使用一

组并行的 DWConv,并且对整合的图片信息采用不同的卷积核,使得 DWConv 可以捕获输入数据中的局部空间关系,对不同通道的特征进行独立学习。

### 3 实验结果与分析

#### 3.1 数据集简介

VisDrone2019 数据集<sup>[18]</sup> 由天津大学和 AISKYEYE 团队收集。数据集包括训练集 6 471 张,验证集 548 张,测试集 3 190 张,一共有 10 个类别,并且数据集中每个类别数量由各种无人机摄像头捕获,覆盖范围广泛,包括行人、车辆、自行车等。

#### 3.2 实验环境搭建与参数配置

实验环境和硬件平台包括 CPU R9-7945HX、GPU RTX4060 (8 GB 内存)、Ubuntu 操作系统、CUDA10.2、Python3.9、Pytorch11.8。

在模型训练过程中,输入图像采用 640×640,轮数 200, Batch-size 为 16,优化器使用 SGD,并采用数据增强,其他参数信息如表 1 所示。

表 1 训练参数设置

参数名称	参数配置
Workers	8
Data enhancement	Mosaic
Patience	100

#### 3.3 评估指标

为了展示改进算法的识别效果,采用精确度 (Precision, P)、召回率 (Recall, R)、平均精度均值 (mean Average Precision, mAP)、参数量作为参考指标。P 和 R 的表达式如下所示:

$$P = \frac{TP}{TP+FP} \quad (8)$$

$$R = \frac{TP}{TP+FN} \quad (9)$$

式中: TP 表示预测目标与实际目标都为真; FP 表示类别预测为真,实际为假; FN 表示类别预测为假,实际为真。

由于在无人机目标识别过程中存在多个类别,例如车、行人、自行车、公交车等,单从 P、R 无法衡量模型性能。在模型的训练过程中,每个类别都可以得到对应的 PR 曲线,曲线下的面积为平均精度值 (Average Precision, AP), mAP 表示所有类别的平均精度值,因此模型评估使用 mAP 来衡量网络运行效率,表达式如下所示:

$$AP = \int_0^1 P(R) dR \quad (10)$$

$$mAP = \frac{\sum_{i=1}^N AP(i)}{N} \quad (11)$$

### 3.4 消融实验

对所提算法进行消融实验, 评估指标为

Precision、Recall、mAP<sub>50</sub> 和 mAP<sub>50-95</sub>。相比于基线模型, 待检测目标的平均精度提高 6.24%。同时, 为了验证本文提出 DySample 性能, 对比 Carafe 下采样, 实验表明 DySample 的参数量比 Carafe 下采样参数量更低, 具体信息如表 2 所示。

表 2 消融实验

YOLOv8n	FDPN	DySample	Carafe	Precision/%	Recall/%	mAP <sub>50</sub> /%	参数量/10 <sup>6</sup>
✓				50.31	36.13	36.25	3.1
✓	✓			54.08	36.33	39.33	3.3
✓		✓		53.23	38.06	40.01	2.9
✓			✓	54.17	36.79	39.45	3.4
✓	✓	✓		58.88	39.54	42.49	3.0
✓	✓		✓	50.47	35.16	36.50	3.6

### 3.5 模型对比与可视化分析

为了验证本文提出的模型对小目标识别的性能优势, 将 YOLOv8n 基线模型、改进模型与相关领域具有代表性的目标检测算法如 YOLOv5s、YOLOv6、YOLOv7 等进行对比, 评估指标主要为 P、R、mAP<sub>50</sub>、mAP<sub>50-95</sub>、参数量、模型大小。实验结果如表 3 所示, 改进的模型在保证目标识别精度的同时使得模型参数量降低, 提高了无人机目标识别速率。同时, 本文将 YOLOv8-FDT 与 Faster-RCNN<sup>[19]</sup>、Cascade R-CNN<sup>[19]</sup>、RetinaNet<sup>[19]</sup>、CenterNet<sup>[19]</sup> 算法进行对比, 如表 4 所示。相比于传统算法, 改进的模型在 mAP<sub>50</sub> 和 mAP<sub>50-95</sub> 上提升明显。

表 3 不同 YOLO 模型对比

模型	Precision/%	Recall/%	mAP <sub>50</sub> /%	mAP <sub>50-95</sub> /%	参数量/10 <sup>6</sup>	模型大小/MB
YOLOv3-Tiny <sup>[20]</sup>	37.20	24.10	31.50	18.0	4.5	24.4
YOLOvX <sup>[21]</sup>	42.70	31.30	31.20	16.00	2.0	26.5
YOLOv5s <sup>[19]</sup>	46.40	34.60	34.40	19.00	7.2	14.0
YOLOv6 <sup>[20]</sup>	39.80	29.40	29.10	17.00	5.0	8.7
YOLOv7 <sup>[20]</sup>	50.20	41.10	37.90	19.90	3.0	72.0
YOLOv8n	50.31	36.13	36.25	24.42	3.1	22.5
YOLOv8-FDT	58.88	39.54	42.49	27.88	3.0	20.1

表 4 传统算法模型对比

模型	mAP <sub>50</sub> /%	mAP <sub>50-95</sub> /%
Faster-RCNN	37.20	21.90
Cascade R-CNN	39.10	24.30
RetinaNet	19.10	10.60
CenterNet	33.70	18.80
YOLOv8-FDT	42.49	27.88

将数据集中的 10 个目标类别的平均精度与改进模型 YOLOv8-FDT 进行比较, 如图 7 所示, 包括 Pedestrian、Bicycle、People、Motor 等在特征图中占据较少像素点的目标。实验结果表明, 改进模型在目标识别方面的平均精度优于基线模型。另外, 如 Van、Bus、Awning-tricycle 等特征图中占据较多像素点的目标, 改进模型的 mAP<sub>50</sub> 提高了约 10%, 证明本文提出的改进模型能够有效处理多尺度目标识别任务场景。




图 7 不同类别的平均精度对比

使用混淆矩阵将目标检测问题转化为一个回归问题来预测目标的边界框和类别, 如图 8 所示, (a) 表示基线模型训练结果, (b) 表示改进模型训练结果。每一列代表真实类别, 每一行代表预测类别, 对角线表示正确识别样本数量。上三角为假阳性, 表示模型将背景或其他类别分类成当前类别, 区域数值越高表明模型存在较多误检。下三角为假阴性, 表示模型未能正确检测真实存在的样本, 区域的数值较高时, 表明模型在这些类别上存在漏检问题。可以看出改进的模型较基线模型能够有效地降低漏检误检概率。

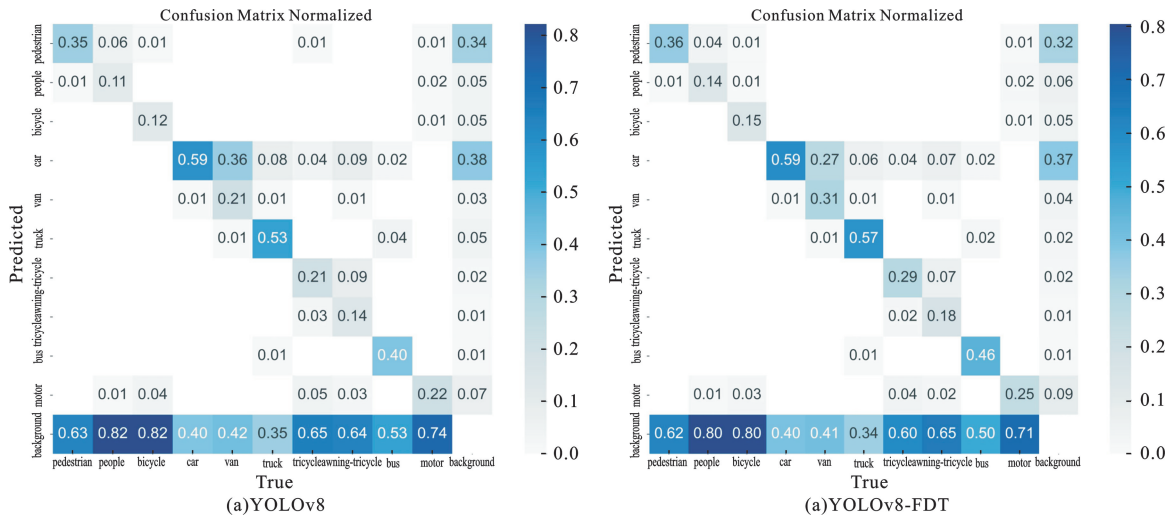


图 8 混淆矩阵

图 9 为在 Visdrone2019 验证集里的图片训练出来的效果,图 9(a) 所示基线模型会出现误检情况,基线模型将桶识别成车辆,而利用改进的模型,能够准确识别不同的类别,并未出现误检情况。此外,目标识别过程中会出现重叠覆盖的情况,如图 9(b) 所示当车辆和行人重叠时,基线模型将其识别在同一

目标框内,而改进的模型将行人与车辆分开识别。图 9(c) 所示基线模型出现漏检情况,而改进的模型一定程度克服了漏检问题,并且每个类别的识别精度均有提升。图 9(d) 所示为在城市和人口密集区域下的目标识别结果。



图 9 模型识别的结果

改进模型在特殊场景下的识别能力如图 10 所示。在雾天中,能见度较低,图像被雾气所遮挡,导致目标物体的边缘模糊不清。其次,进行噪声测试。噪声会对目标的识别造成干扰,增加识别难度。然后,进行黑夜场景的测试。在黑夜中,光

线不足,图像变得昏暗,目标物体的细节难以区分。最后,进行多尺度、复杂背景和目标被遮挡情况的测试。实验结果表明,改进的模型在特殊场景下均能实现小目标的识别,并能保持良好的识别精度。

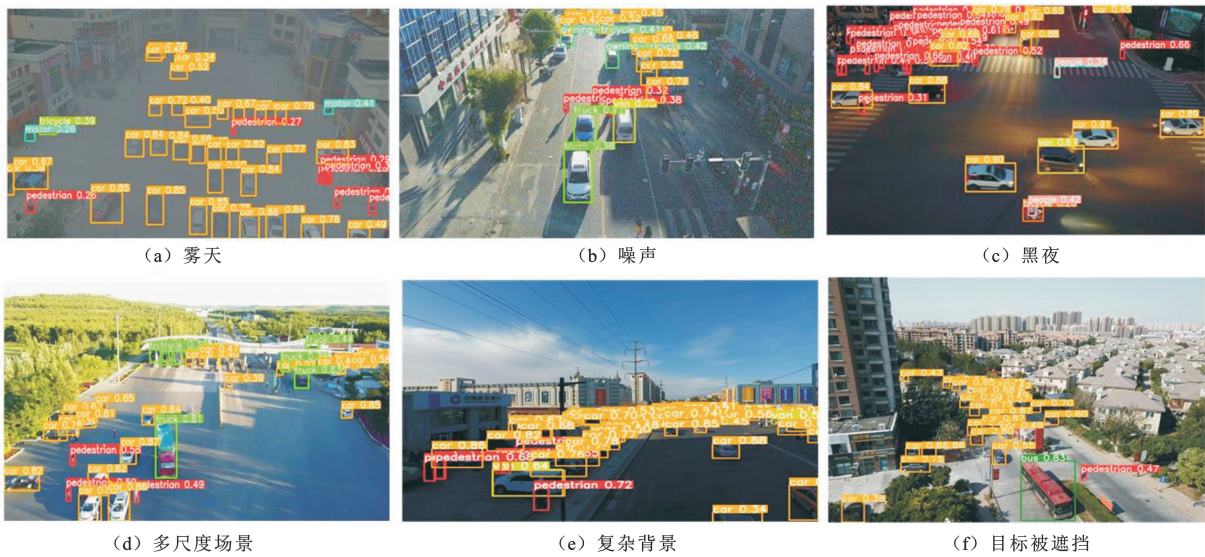


图 10 不同场景下的目标识别结果

#### 4 结束语

无人机在目标识别<sup>[22]</sup>过程中存在漏检、误检和识别精度低等问题。本文在 YOLOv8n 基线模型上提出 YOLOv8-FDT 模型,设计扩散聚焦金字塔网络,获取不同尺度的图片语义信息,以提高算法在密集场景下的表现。同时,将基线模型 Neck 层传统卷积替换 DySample,降低模型参数量以实现检测的实时性。通过 Visdrone2019 数据集实验表明,改进的模型较基线模型平均精度提高 6.24%,使得无人机能够应对复杂场景的目标识别任务。

下一步工作将继续提高算法对于小目标的识别能力,同时降低模型的参数量和推理时间,提高模型在不同数据集上和更为复杂场景的泛化能力。

#### 参考文献:

- [ 1 ] 黄巍,陈俊良,李犹海. 无人机自组网技术综述与发展展望[J]. 电讯技术,2022,62(1):138-146.
- [ 2 ] LAW H, DENG J. CornerNet: detecting objects as paired keypoints[C]//2018 European Conference on Computer Vision. Munich: IEEE, 2018: 765-781.
- [ 3 ] LIU S, HUANG D. Receptive field block net for accurate and fast object detection [ C ]//2018 European Conference on Computer Vision. Cham: Springer, 2018:

- 385-400.
- [ 4 ] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [ C ]//The 28th International Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2015: 91-99.
- [ 5 ] 杨艳红,钟宝江,徐云龙. 改进的 SSD 算法在智慧交通中的应用[J]. 电讯技术,2022,62(2):259-265.
- [ 6 ] LIM J S, ASTRID M, YOON H J, et al. Small object detection using context and attention [ C ]//2021 International Conference on Artificial Intelligence in Information and Communication. Jeju Island: IEEE, 2021: 181-186.
- [ 7 ] 李大湘,辛嘉妮,刘颖. 位置敏感 Transformer 航拍图像目标识别模型[J]. 光学精密工程,2024,32(5):727-739.
- [ 8 ] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//2018 European Conference on Computer Vision. Cham: Springer, 2018: 3-19.
- [ 9 ] 罗旭鸿,刘永春,楚国铭,等. 基于改进 YOLO5 无人机图像目标检测算法[J]. 无线电工程,2023,53(7):1528-1535.
- [ 10 ] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [ C ]//2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2980-2988.

- [ 11 ] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [ C ]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE, 2017:7263-7271.
- [ 12 ] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv-7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [ C ]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE, 2023:7464-7475.
- [ 13 ] DU D, ZHU P, WEN L, et al. VisDrone-DET2019: the vision meets drone object detection in image challenge results [ C ]//2019 IEEE/CVF International Conference on Computer Vision Workshops. Seoul: IEEE, 2019:213-226.
- [ 14 ] 张利丰, 田莹. 改进 YOLOv8 的多尺度轻量型车辆目标检测算法 [ J ]. 计算机工程与应用, 2024, 60 ( 3 ): 129-137.
- [ 15 ] TANG W, SUN J, WANG G. Horizontal feature pyramid network for object detection in UAV images [ C ]//2021 China Automation Congress. Beijing: IEEE, 2021:7746-775.
- [ 16 ] CHENG Q Q, WANG H J, AING X C, et al. A UAV target detection algorithm based on YOLOv4-Tiny and improved WBF [ C ]//The 14th International Conference on Wireless Communications and Signal Processing. Nanjing: IEEE, 2022:122-126.
- [ 17 ] TAN M X, PANG R M, GUO S L. EfficientDet: scalable and efficient object detection [ C ]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020:10778-10787.
- [ 18 ] LIU W J, QIANG J, LI X X, et al. UAV image small object detection based on composite backbone network [ J ]. Mobile Information Systems, 2022 ( 15 ): 1-11.
- [ 19 ] WANG G, CHEN Y, AN P. UAV-YOLOv8: a small-object-detection model based on improved YOLOv8 for UAV aerial photography scenarios [ J ]. Sensors, 2023, 23 ( 16 ): 7190-7197.
- [ 20 ] TAHIR N U A, LONG Z, ZHANG Z. PVswin-YOLOv8s: UAV-based pedestrian and vehicle detection for traffic management in smart cities using improved YOLOv8 [ J ]. Drones, 2024, 8 ( 3 ): 84-89.
- [ 21 ] 孙佳宇, 徐民俊, 张俊鹏. 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, 2024, 23 ( 8 ): 1-13.
- [ 22 ] 李佳霖, 李卫东, 王廉钧, 等. 基于残差网络高分辨距离像的无人机识别 [ J ]. 现代雷达, 2024, 46 ( 7 ): 30-36.

#### 作者简介:

张博文 男, 1999 年生于江苏连云港, 硕士研究生, 主要研究方向机电产品检测与智能控制。

薛波 男, 1982 年生于江苏徐州, 博士, 副教授、硕士生导师, 目前主要从事机器学习、统计信号处理、无线传感器网络等方面的研究。