

DOI:10.19651/j.cnki.emt.2211146

基于改进 YOLOv4 的无人机航拍目标检测算法^{*}

赵耘彻² 张文胜^{1,2} 刘世伟³

(1. 河北省交通安全与控制重点实验室 石家庄 050043; 2. 石家庄铁道大学交通运输学院 石家庄 050043;
3. 沧州渤海新区黄骅市交通运输局 黄骅 061100)

摘要: 针对无人机航拍目标检测对检测速度的高要求以及航拍图像小目标较多时易出现漏检、误检的问题,提出一种基于改进 YOLOv4 的无人机航拍目标检测算法。首先,引入轻量级网络 MobileNetv3 替换 YOLOv4 的主干特征提取网络,并采用深度可分离卷积替换网络其余部分的 3×3 标准卷积,降低了模型复杂度,提升了检测速度;其次,增加了针对小目标的 104×104 的浅层检测层,将原特征提取网络的 3 种检测尺度扩展为 4 种,对应加深特征融合网络层数,提升了算法对小目标的检测精度;最后,采用 K-means++ 聚类算法重新设计了初始锚框,加快了网络的收敛速度。在无人机航拍数据集上进行了对比实验,结果表明所提算法与原算法相比,在保证平均检测精度的同时,提升了小目标检测精度,且模型参数量减少了 60%,检测速度提升了 15.2%,在实时性和准确性方面均有较好性能。

关键词: 目标检测;无人机;YOLOv4;轻量级网络;K-means++

中图分类号: TP391.41; V19 文献标识码: A 国家标准学科分类代码: 580.99

UAV aerial object detection algorithm based on improved YOLOv4

Zhao Yunche² Zhang Wensheng^{1,2} Liu Shiwei³

(1. Key Laboratory of Traffic Safety and Control of Hebei Province, Shijiazhuang 050043, China;
2. School of Traffic and Transportation, Shijiazhuang Tiedao University, Shijiazhuang 050043, China;
3. Cangzhou Bohai New Area Huanghua Transportation Bureau, Huanghua 061100, China)

Abstract: A UAV aerial object detection algorithm based on modified YOLOv4 is proposed in order to address the high need of detection speed for UAV aerial object detection as well as the issue of missed detection and false detection when there are many small targets in aerial images. Firstly, the lightweight network MobileNetv3 is introduced to replace the main feature extraction network of YOLOv4, and the depth separable convolution is used to replace the 3×3 standard convolution of the network, which reduces the complexity of the model and improves the detection speed. Secondly, the 104×104 shallow detection layer for small targets is added, the three detection scales of the original feature extraction network are increased to four, and the number of feature fusion network layers is increased. These changes increase the algorithm's accuracy in detecting small targets. Finally, the K-means++ clustering technique is used to redesign the initial anchor frame, accelerating the network's rate of convergence. The UAV aerial data set is used in a comparison experiment. The findings demonstrate that as compared to the original approach, the suggested technique not only ensures average detection accuracy but significantly enhances the detection accuracy of small targets. The detection time is 15.2% faster while the model parameters are lowered by 60%. It performs accurately and with good real-time performance.

Keywords: object detection; unmanned aerial vehicle; YOLOv4; lightweight network; K-means++

0 引言

无人机以其极高的灵活性、低成本、便携性等优势,广泛应用于交通监管、安全巡检、应急救灾等领域^[1]。通过无

人机航拍图像进行目标检测能够快速高效获取道路交通信息,助力智慧交通发展。

目标检测主要分为传统的目标检测算法和基于深度学习的目标检测算法。传统的目标检测算法主要通过

收稿日期:2022-08-22

*基金项目:中央引导地方科技发展资金(226Z6101G)、河北省及石家庄市引进国外智力项目(2021-2023)、石家庄市科技计划项目(221130134A)资助

SIFT、方向梯度直方图、Haar 等为设计的方法进行特征提取,之后通过支持向量机、Adaboost、可变形部件模型等方法进行分类,但传统目标检测算法存在检测速度慢和鲁棒性差的弊端。与此相比,基于深度学习的目标检测算法在检测精度与速度上都取得了较大的突破。基于深度学习的目标检测算法分为如下两类:基于候选区域的两阶段目标检测算法和基于回归的单阶段目标检测算法^[2]。两阶段代表性目标检测算法在第一阶段进行候选区域提议,第二阶段进行候选框精确回归,代表算法有 R-CNN^[3]、Fast R-CNN^[4]、Faster R-CNN^[5]、以及 Mask R-CNN^[6]。这一类目标检测算法检测精度较高,但耗时较长,难以满足无人机航拍目标检测任务对实时性的要求。单阶段目标检测算法只需一次提取特征即可得到最终的检测结果,代表算法有 YOLO 系列算法以及 SSD 算法^[7],其大大提升了检测速度,因此选用单阶段目标检测算法更加满足需求。

与常规视角拍摄图片不同,无人机航拍图像中车辆等目标所占像素很小,分布密集,检测背景较为复杂,容易出现漏检、错检等问题,增加了目标检测的难度^[8]。为此,国内外众多学者对目标检测算法进行了改进以提高航拍目标检测效果。Vaddi 等^[9]提出了一种具有改进的焦点损失函数的深层特征金字塔结构,减少正、负样本之间的不平衡,提升了检测速度。刘芳等^[10]将深度可分离卷积和残差网络相结合,通过语义特征指导网络在多尺度特征图上自适应生成候选框,有效提升了无人机航拍目标检测精度。裴伟等^[11]在 SSD 算法基础上,引入了跳跃连接机制以降低提取特征的冗余度,并充分利用不同层之间的相关性,将低层高分辨率特征与高层语义特征相结合,增大了感受野,提高了网络对小目标检测能力。

以上算法均在一定程度上提升了航拍目标检测速度与精度,但仍存在如下问题:1)小目标深层特征提取能力较差,2)模型参数量较大,对硬件设备要求较高,难以部署在嵌入式设备与移动设备中。

本文综合衡量算法检测精度与检测速度,以 YOLOv4 作为基础算法,并针对无人机航拍目标检测对模型轻量化和小目标检测准确度的要求,进行了以下改进:

1)引入轻量级网络 MobileNetV3 进行特征提取,并采用深度可分离卷积替换空间特征金字塔池化(spatial pyramid pooling, SPP)模块和 PANet 模块中 3×3 的标准卷积,大大降低了模型大小,提高了检测速度,便于后续将模型部署到移动端。

2)新增一层针对小目标的浅层检测层,对应加深特征融合网络深度,避免小目标语义信息的丢失,提高算法对小目标的检测精度。

3)通过 K-means+十聚类算法对目标候选框进行聚类分析,得到更适用于航拍目标的初始锚框,进一步提升算法检测精度。

1 YOLOv4 算法的网络结构

YOLOv4^[12]在 YOLOv3 的基础上尝试了大量的调优手段,加深网络模型,在检测准确度和速度方面都得到了提升,其主要网络结构由主干特征提取网络、特征金字塔网络以及预测网络组成。

1.1 特征提取网络

YOLOv4 的主干特征提取网络为 CSPDarknet53,其最基本的模块是由一个二维卷积 Conv2D、一个正则化 BN 层和 Mish 激活函数层组成的卷积层。CSPDarknet53 网络将 Darknet53 中的残差块替换为 CSP 结构^[13],每个 CSP 结构分别包含残差单元个数为 1、2、8、8、4 个。CSP 结构如图 1 所示。

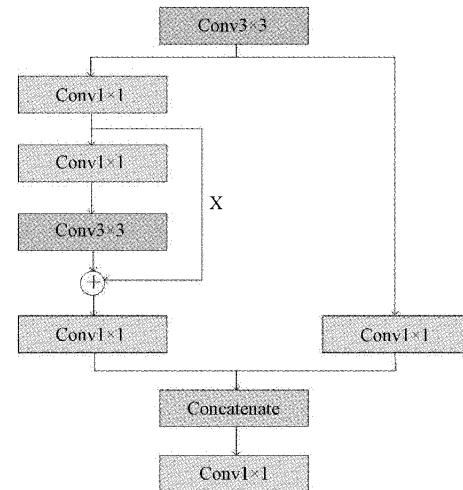


图 1 CSP 结构

1.2 特征金字塔网络

YOLOv4 的特征金字塔网络将 SPP^[14]、特征金字塔网络(feature pyramid network, FPN)和像素聚合网络(pixel aggregation network, PAN)相结合,实现特征多尺度融合^[15]。SPP 模块接连在 CSPDarknet53 网络之后,通过 SPP 模块可以增加网络的感受野,实现局部特征和全局特征的融合,与传统的 $k \times k$ 最大池化的方式相比,能够丰富特征图的表达能力。

在 YOLOv4 网络中,引入了 PANet 结构^[16],在 FPN 的基础上添加了自底向上的特征金字塔,PANet 将 13×13 的特征图经过两次上采样后的结果分别与 26×26 、 52×52 的特征图相拼接,之后再通过类似的方法自顶向下进行特征融合。进而从不同的主干层对不同的检测层进行参数聚合,进一步提升网络的特征提取能力。

1.3 预测网络

YOLOv4 在 13×13 、 26×26 、 52×52 三种尺度上进行预测,根据特征金字塔网络输出的特征信息对先验框进行调整得到特征层的预测结果,通过最大值抑制算法输出最终的预测结果。

2 算法改进

2.1 网络的轻量化

YOLOv4 的主干特征提取网络虽然能提取有效的特征信息,但该网络的模型参数量较大,在检测的实时性方面有所欠缺,因此,本文将其主干网络替换为轻量级的 MobileNetV3 网络^[17]。MobileNetV3 包括 Large 和 Small 两种结构,本文使用 Large 结构。MobileNetV3 网络主要有以下 3 个特点:

1) 深度可分离卷积

MobileNetV3 通过使用深度可分离卷积(depthwise separable conv)^[18]来替代普通卷积块。普通卷积过程如图 2 所示,深度可分离卷积过程如图 3、4 所示。

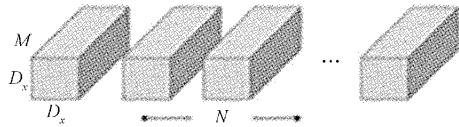


图 2 普通卷积过程

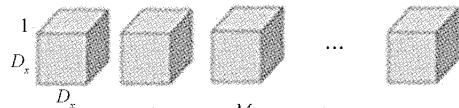


图 3 深度卷积过程

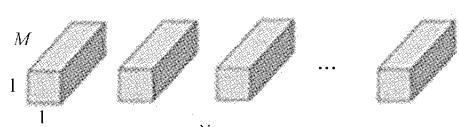


图 4 逐点卷积过程

在图 2~4 中, D 表示卷积核尺寸, M 表示卷积核个数, N 表示输出特征图个数,则使用普通卷积块的计算开销为:

$$D \times D \times M \times N \quad (1)$$

而使用 DSC 的计算开销为:

$$D \times D \times M \times 1 + 1 \times 1 \times M \times N \quad (2)$$

两者相比结果为:

$$\frac{D \times D \times M \times 1 + 1 \times 1 \times M \times N}{D \times D \times M \times N} = \frac{1}{N} + \frac{1}{D^2} \quad (3)$$

2) 残差倒置结构与线性瓶颈

传统的残差块内部是先对输入特征图进行降维操作,再提取特征,最后进行升维使通道数和输入特征图一样,而残差倒置结构与之相反,这样倒置的残差块结构呈现像瓶颈一样两端小中间大的形状^[19]。由于非线性激活函数 ReLU 会在低维信息映射到高维信息这一过程中造成信息损失,因此采用线性激活函数替代 ReLU,这一结构便称为线性瓶颈。其结构如图 5 所示,图 5(a) 为 stride 为 1 时的结构图,图 5(b) 为 stride 为 2 时的结构图。

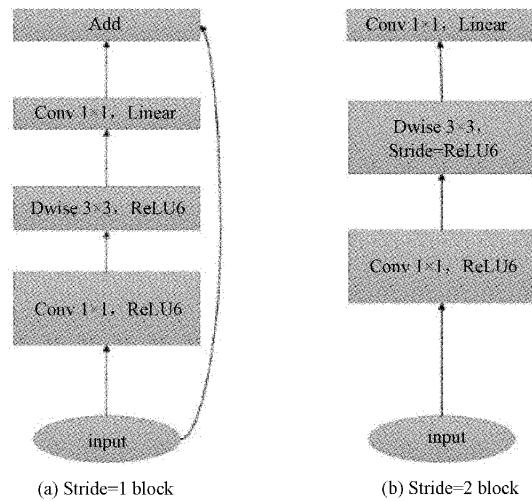


图 5 线性瓶颈结构

3) 注意力机制

MobileNetV3 将 SE 轻量级注意力机制^[20]引入线性瓶颈结构中,此轻量级注意力机制主要包括挤压和激励两个过程,在每个通道上提取特征后通过挤压操作获取图像的全局特征,再通过激励操作生成每个通道的权重,之后将特征图与其对应的权值进行加权计算,从而让网络重点关注权重高的特征通道,即激励对识别任务有用信息,并抑制对识别任务无用的信息^[21]。

此外,MobileNetV3 在主干网络中将部分层的激活函数由 swish 替换为 h-swish,在注意力模块中将 sigmoid 替换为 h-sigmoid, $h\text{-}swish$ 、 $h\text{-}sigmoid$ 的计算公式分别如式(4)、(5)所示。

$$h\text{-}swish = x \cdot \frac{\text{ReLU6} + (x + 3)}{6} \quad (4)$$

$$h\text{-}sigmoid = \frac{\text{ReLU6} + (x + 3)}{6} \quad (5)$$

由上文可知,与标准卷积相比,深度可分离卷积能够大幅降低计算开销,原始网络结构中在 PANet 和 SPP 模块中存在大量的标准卷积,本文采用深度可分离卷积替换原网络中 PANet 和 SPP 模块中的 3×3 标准卷积,进一步降低了模型参数量。

2.2 目标预测网络改进

由于无人机航拍视角下的行人等目标尺寸较小,导致高层特征层会丢失小尺度信息,为了提取更多的小目标特征信息,提高算法对小目标的检测精度,本文对目标预测网络进行改进,增加一个新的检测层,尺寸为 104×104 ,用于提取浅层信息。为了匹配新增检测层,对应加深 PANet 的深度,在 PANet 结构中,深层特征通过上采样后与浅层特征进行融合,将融合结果输入到下一个检测层,直至新增检测层能够融合前三层特征信息,由此能够获得更大的特征图进而提升网络对小目标检测的检测效果。改进后的网络结构如图 6 所示。

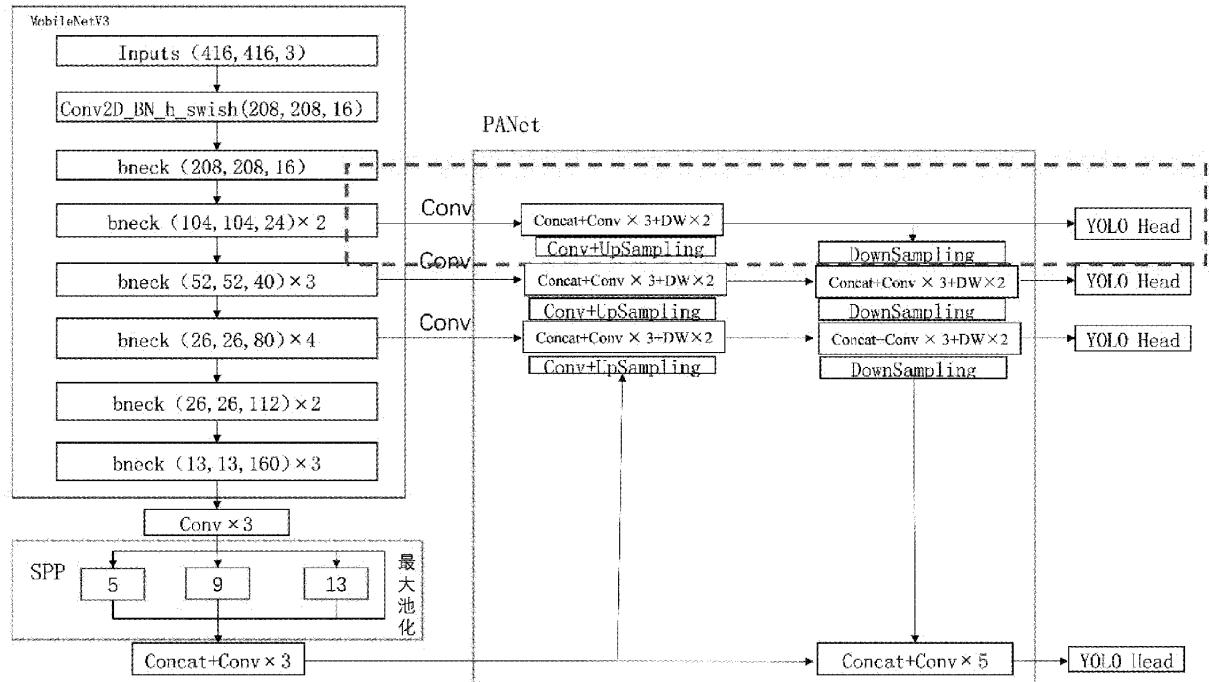


图 6 改进后的网络结构

2.3 K-means++聚类重设锚框

K-means 聚类算法随机选取数据集中 K 个点作为聚类中心, 导致聚类结果的好坏依赖于初始聚类中心的选择^[22], K-means++算法为解决该局限性, 在选择初始化聚类中心时要保证聚类中心之间的距离尽可能远。由于 YOLOv4 算法的初始锚框与本文所用航拍数据集目标尺寸相差较大, 采用原始锚框严重影响算法的性能, 本文通过 K-means++算法对数据集进行聚类分析, 重新设计先验锚框的大小, 使其与目标边界框匹配程度更高, 聚类效果图如图 7 所示, 由于改进后的网络添加了新的检测层, 预设锚框数量从 9 个加至 12 个, 分别用于 104×104 , 52×52 , 26×26 和 13×13 四个不同尺度的检测层中, 聚类得到的锚框尺寸如表 1 所示。

表 1 锚框分配表

104×104	52×52	26×26	13×13
(1,2)	(14,21)	(29,23)	(58,33)
(2,5)	(16,32)	(30,54)	(120,135)
(8,9)	(19,15)	(44,22)	(102,82)

3 实验结果与分析

3.1 环境配置与训练参数

本文实验使用的环境配置如表 2 所示。

为了达到更好的训练结果, 本文训练时使用 YOLOv4 在 Pascal VOC 数据集上的预训练权重进行迁移学习, 采

用 Adam 优化器进行训练, 使用余弦退火策略更新学习率, 最大学习率设置为 0.001, 最小学习率设置为 0.000 01, 动量参数为 0.937, 批量大小为 8, 训练批次为 1 000。

表 2 环境配置

名称	配置
CPU	Intel i5 6500H
GPU	Nvidia Tesla k80
操作系统	Ubuntu 16.04
数据处理	Python3.6 OpenCV

3.2 数据集预处理与数据增强

本文所采用的实验数据集由两部分组成, 一部分来自无人机影像数据集 Visdrone2019、另一部分来自论文作者利用无人机拍摄的数据集, 该数据集共涉及 8 种类别, 分别是汽车、行人、公交车、自行车、三轮车、货车、摩托车以及卡车。其中包含训练集 7 748 张、测试集 3 815 张以及验证集 652 张。训练数据集前需将标签格式转换为 id、x、y、w、h 格式, 并进行归一化处理。

本文通过随机缩放、缩放、平移、色彩变换等基本方法以及 mosaic 方法进行数据增强, mosaic 方法主要思想是将 4 张图片随机排列拼接成一张图片后输入训练网络, 采用数据增强的方法能够对原始数据集进行扩充, 避免过拟合现象的发生。

3.3 评价指标

目标检测模型通常从检测速度与检测精度两个角度对性能进行评估, 本文采用的评价指标如下:

1)查全率(Precision)和召回率(Recall):查全率即计算全部准确的预测框的数量除以全部的预测框的数量。召回率即所有正样本检测框和标注的所有真实样本的比值。查全率和召回率的公式如下:

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

其中, TP (true positive)表示能够正确识别出目标的检测框数量, FP (false positive)表示将非目标判定为目标的检测框数量, FN (false negative)指的是将目标判定为非目标的检测框的数量。

2)平均精度(AP)和均值平均精度(mAP):单个目标类别的平均精度定义为 Precision-Recall 曲线下方的面积。均值平均精度即所有类别的平均精度的均值。AP 和 mAP 的计算公式如下:

$$AP = \int_0^1 P_{\text{smooth}}(r) dr \quad (8)$$

$$mAP = \frac{\sum_n AP_n}{N} \quad (9)$$

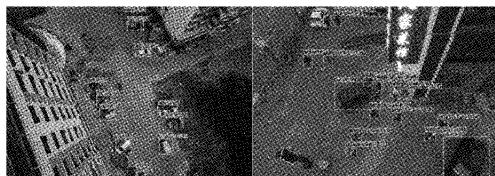
3)帧率(fps):通常使用帧率衡量模型的检测速度,即一秒钟模型能够预测图像的个数。

3.4 有效性分析

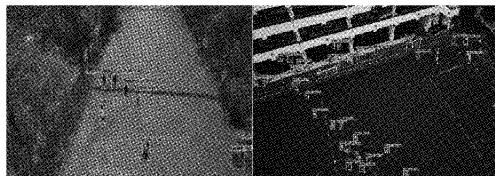
为了验证本文所改进的算法在实际场景中的有效性,本文选取无人机影像数据集中具有代表性的图像进行测试,检测结果如图 7 所示,图 7(a)为不同光照环境下目标检测效果图,图 7(b)为多尺度目标检测效果图,图 7(c)为小目标检测效果图,由识别效果图可知,图像中的车辆、行



(a) 不同光照环境下的目标检测效果图



(b) 多尺度目标检测效果图



(c) 小目标检测效果图

图 7 目标检测效果图

人等目标基本都被正确检测与识别,漏检、错检目标数目极少,充分说明本文所优化的检测算法能够有效检测无人机航拍图像中车辆、行人等目标,并且对小目标也达到了较好的检测效果。

3.5 对比实验

为了验证提出的改进方法的有效性,本文设置了对比实验,将本文改进算法同原始 YOLOv4 算法在无人机航拍数据集中进行测试,采用各个类别的 AP 值、mAP、fps 等评价指标进行性能的评估,结果如表 3 所示。

表 3 单个类别对比实验

类别	YOLOv4	本文算法
汽车	59.42	56.83
行人	18.30	19.91
公交车	52.53	50.11
自行车	8.65	9.22
三轮车	16.81	17.24
卡车	50.04	48.79
摩托车	16.52	17.03
货车	42.85	40.16
mAP/%	33.13	32.41
fps/(帧/s)	46	53
模型大小/MB	245.20	102.40

由表 3 可知,本文在保证大型目标有着较高的平均精度的前提下,提升了行人、自行车等小目标的检测精度,且大大降低了模型大小,检测速度提升为 53 帧/s,达到了实时性的要求。

为了验证所提算法的优越性,将本文算法与 YOLOv3、YOLOv4-tiny 等目标检测领域效果较好的主流算法在本文所用无人机航拍数据集上进行实验对比,结果如表 4 所示。

表 4 对比实验

算法	mAP/%	fps	模型大小
YOLOv3	27.36	38	236.50
YOLOv4	33.13	46	245.20
YOLOv4-tiny	28.02	54	23.10
Centernet	29.69	43	131.40
YOLOv5m	30.88	48	42.40
YOLOv5s	27.95	52	14.50
本文算法	32.41	53	102.40

由表 4 可知,本文算法与 YOLOv4-tiny、YOLOv5m 和 YOLOv5s 这类轻量化算法相比,虽然模型大小较大,但检测精度分别提升了 4.39%、1.53% 和 4.46%,并且在检测速度上也有很好的表现,能够满足实时性的需求。综合考虑 mAP、fps 以及模型大小 3 个评价指标,本文算法性能

较好,更适用于无人机航拍目标检测这一应用场景。

3.6 消融实验

为了进一步验证本文算法所用的各个改进方法对原

始算法的优化效果,在 YOLOv4 的基础上设计了四组消融实验,实验结果如表 5 所示,其中“—”代表未使用该改进方法,“√”代表使用了该改进方法。

表 5 消融实验

实验	MobileNetV3	新增检测层	K-means++	mAP/%	fps/(帧/s)	参数量	模型大小/MB
实验 1	—	—	—	32.76	46	64 429 405	245.20
实验 2	√	—	—	30.21	56	11 425 561	44.56
实验 3	√	√	—	31.55	53	27 985 996	102.40
实验 4	√	√	√	32.02	53	27 985 996	102.40

由表 5 可知,特征提取网络替换为 MobileNetV3 后,Fps 提升了 21.7%,参数量和模型大小都大大减少了,但 mAP 下降了 2.55%,主要原因是轻量级特征提取网络在降低模型参数量的同时,也降低了特征表征能力,新增检测层后 mAP 较实验 2 上升了 1.34%,原因在于新增检测层提高了对小目标的特征提取能力,进一步提升了检测精度。实验 4 即为本文算法,与原算法相比,mAP 降低了 0.74%,Fps 提升了 15.2%。综上,本文算法在保证检测精准度的同时,降低了模型参数量与模型权重文件大小,提升了检测速度。

4 结 论

本文提出了一种基于改进 YOLOv4 的无人机航拍目标检测算法,将特征提取网络由 CSPDarknet53 替换为轻量级网络 MobileNetV3,并引入深度可分离卷积替换网络中 3×3 的标准卷积,降低了网络中的参数量,提升了检测速度,便于后续部署到移动端和嵌入式设备;将原网络的 3 种检测尺度扩展为 4 种,新增一层 104×104 的检测层,提取更多浅层信息,便于航拍图像中小目标的检测;通过 K-means++聚类算法重新设置初始锚框,更符合航拍场景下的目标尺寸,加快了网络的收敛速度。实验结果表明,提出的算法与其它主流算法相比,较好地平衡了模型大小、检测速度以及检测精度,更适用于无人机航拍目标检测任务。

参考文献

- [1] 吕晓君,向伟,刘云鹏. 基于强化底层特征的无人机航拍图像小目标检测算法[J]. 计算机应用研究,2021,38(5):1567-1571.
- [2] 陈科圻,朱志亮,邓小明,等. 多尺度目标检测的深度学习研究综述[J]. 软件学报,2021,32(4):1201-1227.
- [3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [J]. IEEE Computer Society,2014:580-587.
- [4] GIRSHICK R. Fast R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision,
- 2015: 1440-1448.
- [5] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39 (6): 1137-1149.
- [6] HE K, GKIOXARI G, P DOLLAR, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017: 2980-2988.
- [7] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[J]. Proceedings of the 14th European Conference on Computer Vision (ECCV), Amsterdam, Netherlands: Springer, 2016: 21-37.
- [8] 江波,屈若锟,李彦冬,等. 基于深度学习的无人机航拍目标检测研究综述[J]. 航空学报,2021,42 (4): 137-151.
- [9] VADDI S, KIM D, KUMAR C, et al. Efficient object detection model for real-time UAV application[J]. Computer and Information Science, 2021, 14(1):45.
- [10] 刘芳,吴志威,杨安皓,等. 基于多尺度特征融合的自适应无人机目标检测[J]. 光学学报,2020,40 (10): 133-142.
- [11] 裴伟,许晏铭,朱永英,等. 改进的 SSD 航拍目标检测方法[J]. 软件学报,2019,30(3):738-758.
- [12] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection [J]. ArXiv Preprint, 2020, ArXiv: 2004.10934.
- [13] WANG C Y, LIAO H, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, New York: IEEE Press, 2020: 1571-1580.
- [14] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern

- Analysis & Machine Intelligence, 2014, 37 (9): 1904-16.
- [15] LI Z, LANG C, LIEW J H, et al. Cross-layer feature pyramid network for salient object detection[J]. IEEE Transactions on Image Processing, 2021, 30: 4587-4598.
- [16] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[J]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2018. 8759-8768.
- [17] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3 [C]. 2019 IEEE/CVF International Conference on Computer Vision(ICCV), IEEE, 2020: 1314-1324.
- [18] 彭继慎,孙礼鑫,王凯,等.基于模型压缩的 ED-YOLO 电力巡检无人机避障目标检测算法[J].仪器仪表学报,2021,42(10):161-170.
- [19] 陈欣佳,刘艳霞,洪晓斌,等.基于 SSD-CF 的无人艇目标检测跟踪方法[J].中国测试,2019,45(2):145-150.
- [20] HU J, LI S, GANG S. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018:7132-7141.
- [21] 薄景文,张春堂.基于 YOLOv3 的轻量化口罩佩戴检测算法[J].电子测量技术,2021,44(23):105-110.
- [22] 谢俊章,彭辉,唐健峰,等.改进 YOLOv4 的密集遥感目标检测[J].计算机工程与应用,2021,57(22):247-256.

作者简介

赵耘彻,硕士研究生,主要研究方向为图形图像处理、目标检测。

E-mail:zhaoyunche1998@163.com

张文胜(通信作者),博士,主要研究方向为遥感图像处理、交通仿真技术研究。

E-mail:zws@stdu.edu.cn