

DOI:10.19651/j.cnki.emt.2416849

面向无人边防的复杂环境遮挡小目标检测算法*

王慧云¹ 赵俊生¹ 王禹^{1,2} 李鑫延¹ 王淋¹

(1.中北大学机械工程学院 太原 030051; 2.中北大学省部共建动态测试技术国家重点实验室 太原 030051)

摘要: 面对边境复杂环境导致的人工巡检难题和安全风险,部署无人化监控系统对我国边防至关重要。由于摄像头与入侵目标间距离差异导致所拍图像尺度变化显著问题,以及监控目标采用遮挡策略,现有无人边防系统面临误检、漏检率高和实时性不足的挑战。针对该问题,提出了一种平均精度更高、参数量更少、普适性更强的 FDB-YOLOv5 遮挡小目标检测算法。首先,采集大量不同遮挡面积的人员样本构建数据集;其次,设计了 Faster_C3 新结构,以减少遮挡小目标检测网络的延迟和参数量,提高模型检测速率;此外,在颈部网络中引入基于点采样的 Dysample 上采样器,获得更多的局部细节和语义信息,增强模型对小目标的检测能力,同时降低计算开销;最后,使用基于多尺度特征提取 BSPPF 的空间金字塔池化方法,有效地解决尺度不变性及遮挡目标特征信息损失问题,从而更好地捕获关键信息,提高模型对遮挡小目标检测的稳定性以及鲁棒性。实验结果表明,与基线 YOLOv5 相比,FDB-YOLOv5 的 mAP@0.5% 达到了 91.5%;参数量和计算量分别减少了 19.07% 与 18.40%;模型的检测速度提高了 8.83%;与 Faster R-CNN、SSD、YOLOv5s、YOLOv8 相比,FDB-YOLOv5 表现出更优越的性能,可以为边境无人化目标检测技术提供参考。

关键词: 小目标检测;复杂环境;大面积遮挡;YOLOv5;无人边防

中图分类号: TP391;TN912.2 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Complex environment occlusion small target detection algorithm
for unmanned border defenseWang Huiyun¹ Zhao Junsheng¹ Wang Yu^{1,2} Li Xinyan¹ Wang Lin¹

(1. School of Mechanical Engineering, North University of China, Taiyuan 030051, China;

2. Department of State key Laboratory of Dynamic Measurement Technology, North University of China, Taiyuan 030051, China)

Abstract: In the face of the challenges and security risks posed by the complex environment at the border, the deployment of unmanned monitoring systems is crucial for our country's border defense. The existing unmanned border defense systems encounter challenges such as high rates of false positives and missed detections, as well as insufficient real-time capabilities, primarily due to significant variations in image scale caused by differences in distance between the cameras and the intrusion targets, along with the use of occlusion strategies by the monitored targets. A FDB-YOLOv5 occlusion small target detection algorithm with higher average accuracy, fewer parameters, and stronger universality is proposed to address this issue. Firstly, a dataset is constructed by collect a large number of personnel samples with different occlusion areas; secondly, a new structure called Faster_C3 has been introduced to reduce the delay and parameter count of the occlusion small target detection network, thereby improving the detection speed and universality of the model; in addition, a Dysample up-sampler based on point sampling is introduced into the neck network to obtain more local details and semantic information, enhance the detection capability of the model for small targets, while reducing the computational overhead. Finally, a spatial pyramid pooling method based on multi-scale feature extraction BSPPF is used to effectively solve the problems of scale invariance and loss of feature information of the occluded targets, so as to better capture key information and improve the stability and robustness of the model for detecting occluded small targets. The experimental results indicate that compared to the baseline YOLOv5, FDB-YOLOv5 mAP @0.5% reaching 91.5%; experimental outcomes demonstrate that compared to the baseline YOLOv5, FDB-YOLOv5 exhibited superior performance with an mAP@0.5 score reaching 91.5%. There was also a reduction in the number of parameters and computations by 19.07% and 18.41%, respectively, and an increase in model detection speed by 8.83%. When compared to Faster R-CNN, SSD, YOLOv5s and YOLOv8, FDB-YOLOv5 showcases outstanding capabilities, offering valuable insights for unmanned border target detection technologies.

Keywords: small object detection; complex environment; large area occlusion; YOLOv5; unmanned border defense

0 引言

边防巡检是打击相关违法犯罪的主要手段^[1],而我国

边防巡检环境复杂,犯罪人员多隐藏于各种遮挡下,对边防人员和无人边防系统检测造成影响^[2]。因此,如何在遮挡环境下,对小目标进行检测成为研究的难点问题。

收稿日期:2024-09-09

* 基金项目:山西省基础研究计划项目(202203021212158,20210302123039)、中北大学研究生科技立项课题(20231910)资助

基于深度学习的目标检测方法是实现无人边防的主要手段,一类基于候选区域的两阶段目标检测算法,如 Fast R-CNN^[3]、Faster R-CNN^[4]和 R-FCN^[5]等,另一类是基于回归思想的一阶段目标检测算法,其中 SSD^[6]和 YOLO 系列^[7-8]是极具代表性的一级检测器,YOLO 算法具有轻量级网络架构,平衡了速度和准确性的特点,使其广泛用于实时目标检测。在边防检测方面,Krišto 等^[9]利用 YOLOv3 检测模型对边境地区的异常行为进行检测,及时发现偷渡物体和非法越境的情况,但检测精度较低;Hu 等^[10]提出了一种基于特征融合和增强红外目标入侵检测算法,对目标进行了强化和屏蔽,有效地抑制了背景噪声并提高了目标信噪比,减少了误检率,但模型较大。为了实现模型轻量化,Yue 等^[11]使用轻量级模块对骨干网进行堆叠重建,同时使用 BP Sim 进一步优化了网络的特征提取能力,增强了模型对难以检测的边界巡逻图像的检测与特征信息挖掘能力,同时也减少了资源消耗。

考虑到边境入侵人员在图像中大都为小目标和遮挡目标,因此对小目标和遮挡目标检测方法的研究如下:

在小目标检测方面,考虑到基于深度学习的目标检测方法进行了连续的下采样操作,造成了小目标在网络前向传播过程中的信息丢失,为此,一些学者提出了基于特征金字塔网络(FPN)^[12]的不同多尺度特征融合结构,如宋晓茹等^[13]在特征融合网络部分使用双向特征金字塔网络(BiFPN),使得网络能够关注不同尺度的特征信息,从而提高不同尺度特征图的融合性能;然而,这些方法不同层之间的融合只是简单的求和,忽略了目标在场景中的相关性,对小目标检测的改进有限。为了增强小目标的特征表示,并抑制其他目标及环境的影响,一些注意力机制被提出,如卷积注意力模块(CBAM)^[14]、SE、CA^[15]、EMA^[16]等,Li 等^[17]利用跨层注意力网络获得小物体的更好特征。然而这些注意力机制忽略了不同卷积核对小目标检测的影响,冯哲等^[18]通过引入多头注意力机制,增强了模型获取全局上下文信息的能力,改善了卷积核大小对目标特征提取时的限制问题。翁俊辉等^[19]通过增加一个低级预测头(P2)来检测浅层特征图中的小物体,提高模型对小目标的捕捉能力,更有利于小目标检测。

针对复杂环境下的遮挡目标检测,现有的解决方案可以分为两类。第1类是充分利用全局信息生成鲁棒的特征表示法。如从多个位置或尺度^[20]中提取判别特征,然而,当遮挡严重时,很难区分目标人员和遮挡。第2类是使用附加线索增强某些部分的局部特征的方法。通过增强某些部分的局部特征^[21],从而有利于在遮挡场景中生成判别特征表示。因此,一些研究试图使用额外的线索来寻找没有被遮挡的关键部分,具体来说,傅荟瑾等^[22]通过引入卷积注意力机制,达到前景目标信息增强而其他背景弱化的效果。许迪等^[23]引用基于残差思想和并行空洞卷积的 DR-SPPF 模块,增加了特征表示能力,从而降低了天气情

况对目标检测精度的影响;孙备等^[24]提出多尺度交叉注意力模块,对不同尺度的卷积特征进行互交叉增强,从而提升了对伪装目标的边界提取能力。

由于边防入侵人员检测环境与一般场景不同,丛林、高山等复杂环境强调场景的可变性,包含了光照条件、四季变化、大面积遮挡等,加之远距离目标通常较小,目标的前景特征更容易被复杂的背景噪声所覆盖,进一步增加了目标检测的难度。目前的目标检测方法存在模型较大、实时性与准确性难以兼顾、小目标因背景干扰以及分辨率限制导致识别困难、大面积遮挡情况下特征提取困难等问题,使得其在边防场景下的适用性较低。针对上述问题,本文提出了面向无人边防的复杂环境遮挡小目标检测算法,本文算法主要工作如下:

1)针对大面积遮挡数据集缺失的问题,构建了数据集,有效验证了模型性能。

2)在特征提取网络中,设计一种 Faster_C3 新结构代替原有的 C3 模块,从而减少了遮挡小目标检测网络的延迟和参数量,使模型能够在资源及算力有限的设备上部署,提高了模型的普适性。

3)在颈部网络中引入上采样器 Dysample,从而获得更多的局部细节和语义信息,更好地区分遮挡目标和背景,增强模型对低分辨率图像和小目标的检测能力,提高模型在复杂场景下的检测性能,同时降低计算开销。

4)在主干网络中引入 BSPPF(Better SPPF)空间金字塔方法,有效解决尺度不变性及遮挡目标特征信息丢失问题,提高模型对遮挡小目标检测的稳定性以及检测速度。

1 YOLOv5 算法模型与设计与分析

边防检测环境多处于高山密林中,使得入侵人员像素占比较少,加之犯罪人员为了躲避追捕与检测,多隐藏于树木等各种遮挡下,因此,在边防安全检测中,检测目标与背景相比,存在检测目标小、大面积遮挡等问题。小目标的详细定义可以从不同方面进行说明。例如,文献[25]说明小目标边界框的长度和宽度像素应小于 32,文献[26]说明小目标的边界框应覆盖小于原始图像的 1%,本文对小目标的定义则采用文献[26]的方法,即目标边界框覆盖小于原始图像的 1%。同理,遮挡目标的定义也有多种方法,本文则以目标被遮挡的面积来定义遮挡目标,即目标被遮挡的面积超过目标自身的 50%则为遮挡目标。由于图像覆盖率较低、目标被遮挡以至于外观线索较少,且存在着背景干扰等问题,因此在边境等复杂环境下的遮挡小目标检测比一般的目标检测更加困难。

YOLOv5 是一种单阶段目标检测模型,其兼顾识别精度与识别速度,是单阶段识别算法中实时高效的目标识别算法,包括 YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x,表 1 为 YOLOv5 不同版本在 COCO 数据集上的预训练模型结果。由表 1 可知,随着模型从小到大,网络的大小、深度和

性能增加,而速度下降。通过对比发现,YOLOv5s 模型检测速度最快,可以更好地满足实时性的需求,且所需的计算资源更少,更容易在计算资源有限设备上部署。针对本文的特殊性,系统需要在较低的延迟(或较快的检测速度)内达到有效的目标检测,而 YOLOv5s 在处理复杂场景时展现出灵活性、较高的检测精度和较低的延迟,能够确保快速响应。考虑到实时性与精度的双重需求,本文选择 YOLOv5s 作为本文的基础模型,并对其进行优化以进一步提高精度。

表 1 不同 YOLOv5 模型性能对比

Table 1 Performance comparison of different YOLOv5 models

模型	AP ₅₀	Paras/M	FLOP/G	时间/ms
YOLOv5s	55.6	7.3	17.0	2.2
YOLOv5m	63.1	21.4	51.3	2.9
YOLOv5l	66.4	47.0	115.4	3.8
YOLOv5x	68.7	87.7	218.8	6.0

2 改进 YOLOv5 算法模型构建

为解决 YOLOv5 模型在边境等大面积遮挡的复杂开放环境下识别性能较低的问题,本文设计了用于边境复杂遮挡环境的 FDB-YOLOv5 目标检测模型,该模型具体网络结构如图 1 所示。首先,根据 Fasternet 网络,引入了 Faster_C3 新结构,以减少遮挡小目标检测网络的延迟和参数量,提高模型检测速率;此外,在颈部网络中引入了一种超轻量、高效的上采样器 Dysample,能够获得更多的局部细节和语义信息,更好地区分遮挡目标和背景,增强模型对低分辨率图像和小目标的检测能力,提高模型在复杂场景下的检测性能,同时降低计算开销,最后,使用 BSPPF 的空间金字塔方法,以有效解决尺度不变性及遮挡目标特征信息损失问题,提高模型对遮挡小目标检测的稳定性以及鲁棒性。

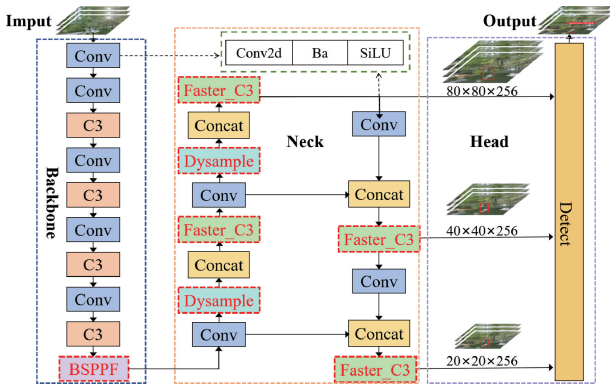


图 1 改进 YOLOv5 网络结构图

Fig. 1 Improvement of YOLOv5 network structure diagram

2.1 基于快速特征提取的 Faster_C3 模块

为了减少遮挡小目标检测网络的延迟和参数量,提高模型的检测速度,本文重新设计了骨干网络中的卷积结构,引入一种新的部分卷积(PCConv)技术,减少浮点运算数(FLOPs)及模型参数,以加快神经网络的速度。

PCConv 原理图如图 2 所示,该卷积对部分输入通道应用常规 Conv 进行空间特征提取,并保持其余通道不变。对于连续或规则的内存访问,将第一个或最后一个连续的通道 c_p 视为整个特征图的代表进行计算,通常认为输入和输出特征图具有相同数量的通道,因此,PCConv 的 FLOPs 与内存访问量(AMC)的计算表达式分别为式(1)、(2)所示。

$$FLOPs = h \times w \times k^2 \times c_p^2 \quad (1)$$

$$AMC = h \times w \times 2c_p + k^2 \times c_p^2 \approx h \times w \times 2c_p \quad (2)$$

$$r = c_p / c \quad (3)$$

式中: k 为卷积核的大小, h 、 w 分别为特征图的高度和宽度, c 为总通道数, c_p 为部分通道数。




图 2 PCConv 结构图

Fig. 2 PCConv structure diagram

对于典型的 $r=1/4$ 时,PCConv 的 FLOPs 只有 Conv 的 $1/16$,内存访问量仅为 Conv 的 $1/4$ 。故该卷积能够在有效提取空间特征的同时最大限度地减少了冗余计算和内存访问,不仅有利于实现目标检测的轻量化架构,提高模型的检测速度,而且提高了模型的普适性,使其能够在资源以及算力有限的设备上部署。

为了解决目标被大面积遮挡导致目标边缘模糊难以识别的问题,本文引入该模块对 C3 模块进行了重构,设计了计算速度更快、参数量更少的 Faster_C3 模块。

Faster_C3 模块结构如图 3 所示。当特征图输入到 Faster_C3 模块后,分别通过 Conv 标准卷积、FasterBottleneck 和上方的 Conv 标准卷积,最终将两者信息通过 Concat 连接层进行连接,并通过标准卷积 Conv 进行输出。在 FaterBottleneck 中,FaterBottleneck 通过残差结构将一个部分卷积(PCNov)和两个标准卷积(Conv)进行连接。其中,标准卷积的核大小为 1×1 ,在保持特征映射大小不变的情况下减少了通道数量,从而降低了网络总体计算成本,使其在资源及算力有限的设备上部署,提高模型的普适性;部分卷积 PCNov 的核大小为 3×3 ,可以部分操作大小为 3×3 的滑动窗口的输入特征图,捕获更大的感受域以改善特征表示,从而更好地理解遮挡目标的上下文特征信息,减少遮挡以及背景对目标特征提取的影响,同时增加非线性以提高模型的准确性和鲁棒性。

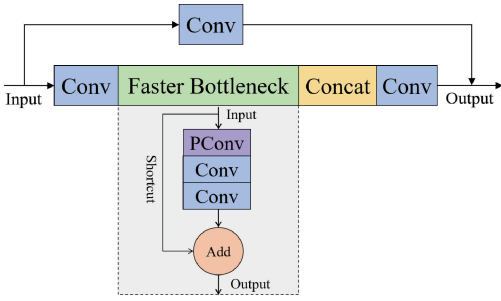


图 3 Faster_C3 模块结构图

Fig. 3 Faster_C3 module structure diagram

2.2 基于点采样的上采样 Dysample 模块

边防检测场景下,入侵人员像素占比小、存在大面积遮挡情况,导致小目标检测特征提取困难及特征图像细粒度丢失,不利于实现入侵目标的高精度检测及轻量化架构。本文引入基于点采样的动态上采样器(Dysample),旨在增强模型对小目标的检测和抗遮挡能力。Dysample 的设计原理如图 4 所示,公式如式(4)~(7)所示。


$$\chi' = grid_sample(\chi, S) \tag{4}$$

$$S = G + O \tag{5}$$

$$O = 0.25(linear(\chi)) \tag{6}$$

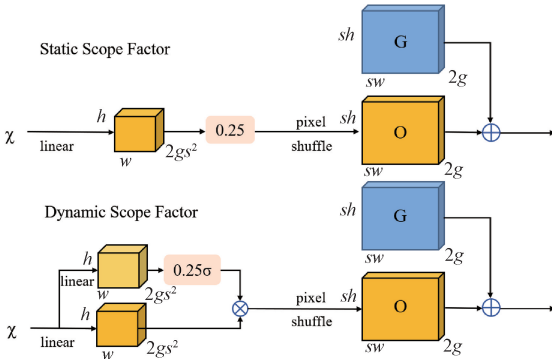
$$O = 0.25\sigma(linear_1(\chi)) * linear_2(\chi) \tag{7}$$

式中: χ 、 χ' 、 O 、 G 、 S 分别表示输入特征、上采样特征、生成偏移量、原始采样网格、采样集。



(a) 基于采样的动态上采样

(a) Dynamic upsampling based on sampling



(b) DySample 中采样点生成器

(b) Sampling point generator in DySample

图 4 Dysample 网络结构图

Fig. 4 Dysample network structure diagram

图 4(a)由采样点生成器生成采样集 S ,对输入特征 χ 使用网格样本(grid_sample)进行重采样,在采样点发生器图 4(b)中,其采样集(S)由原始采样网格(G)和生成的偏移量(O)组成,偏移量的生成采用“线性+像素随机播放”

的方法,其中偏移量的范围由静态和动态因素确定。具体来说,以静态因子采样方法为例,如图 4(b)上半部分所示,给定一个大小为 $c \times h \times w$ 的特征映射和一个上采样因子 s ,特征映射首先通过一个输入通道为 c 、输出通道为 $2s^2$ 的线性层,生成大小为 $2s^2 \times h \times w$ 的偏移量 O 。然后,使用像素随机方法将其重塑为 $2 \times sh \times sw$,其中 2 表示 x 和 y 坐标。最后生成大小为 $c \times sh \times sw$ 的上采样特征图。Dysample 通过近邻样本生成新样本,增加了样本的多样性,从而改善数据不平衡问题,减少假阳性和假阴性的情况,在边防遮挡目标检测过程中可以有效增加特征图的分辨率,使得小目标在遮挡情况下表示更加清晰,从而提高检测准确性,减少误检和漏检情况;同时,基于点的采样方法和学习采样的视角进行上采样,完全避免了耗时的动态卷积操作和额外的子网络,从而以最小的计算成本提高遮挡小目标检测模型的效率和性能。因此,该模块更加适用于部署在资源及算力有限的无人边防遮挡小目标检测系统中。

通过其原理和小目标检测过程进行结合,进而能够获得更多的局部细节和语义信息,更好地区分遮挡目标和背景,增强模型对低分辨率图像和小目标的检测能力,提高模型对遮挡小目标的检测精度,同时降低计算开销。

2.3 基于多尺度特征提取的 BSPPF 特征金字塔池化方法

在边防场景下进行遮挡小目标检测时,入侵目标距离的远会导致感受野的不同。大的感受野能捕获全局和高级语义特征,但可能忽略小目标。相反,小的感受野收集了过多的局部细节,会错过全局上下文,影响目标识别。考虑到入侵目标的尺度特性及模型的轻量化设计,本文引入了一种基于多尺度特征提取的 BSPPF 特征金字塔池化方法。

BSPPF 的网络结构如图 5 所示,与原有 SPPF 结构不同之处在于:1)用 GSConv 代替 SPPF 的 CBS 模块,在保持速度的同时减少了参数和计算量,提高了模型的检测性能。2)在 SPPF 的 Concat 模块之后插入 CS 模块,该模块通过在每个群体中分配来自不同感受野的子群体,并确保在各个群体间的通道分配是均匀的,增强了群体间的跨组通信,丰富了目标特征,从而能够有效地捕捉到不同感受野之间的相互依赖关系,提升模型的理解能力及准确性。




图 5 BSPPF 网络结构图

Fig. 5 BSPPF network structure diagram

BSPPF 方法可以捕获遮挡目标在不同尺度下的上下文信息,使模型更好地理解遮挡目标的局部特征和全局特征。在边防遮挡小目标检测过程中,即使目标被大面积遮挡,该方法通过整合不同尺度特征,使模型能够利用周围环境和上下文信息提取到更关键的目标特征,有效解决不同尺度的遮挡目标特征信息损失问题,提高模型对遮挡小目标检测的检测速度和精度。

3 实验及结果分析

为了验证 FDB-YOLOv5 模型在边境复杂遮挡环境中的有效性,制作了基于不同遮挡面积以及伪装人员的数据集,并在数据集上进行了以下两个实验:

1) FDB-YOLOv5 消融实验:本文所提 FDB-YOLOv5 模型进行了许多改进措施。为了验证每种改进策略对模型检测性能的贡献,在本文构建的训练数据集中进行了消融实验。

2) FDB-YOLOv5 与其他检测算法的对比实验以及不同遮挡面积的对比实验:为了进一步验证 FDB-YOLOv5 在本数据集上的检测效果,选择了 Faster-RCNN、SSD、YOLOv5s、YOLOv5s 四种主流的目标检测算法进行检测实验,并比较了该模型在不同遮挡面积下的检测性能。

3.1 数据集构建

在真实的环境中,边防巡逻环境多处于高山密林中,犯罪人员为了躲避追捕,多隐藏于各种遮挡下,对边防人员的搜查检测以及无人边防系统的检测造成了严重影响,大大降低了被各种探测手段发现的概率。由于训练样本属于敏感安防资源,没有可以直接使用的公开数据集,制作了训练 YOLOv5 的数据集,使数据集更贴合实际的工作环境。数据集部分示例图如图 6 所示。



图 6 部分数据集示例图

Fig. 6 Partial dataset example diagram

针对上述复杂遮挡环境下的入侵人员检测任务,本研究以深山老林为背景,考虑到前景遮挡、目标大小、伪装目标、成像角度、光照、天气以及四季变化等因素的影响,采用毅廉锐长焦摄像头进行数据集的采集,其最大分辨率为 1 920×1 080,帧率为 30 fps。共拍摄图像 3 023 张,其中雨

雪雾天气以及昏暗光线条件下的图像占 30.0%,使用图像标注软件 LabelImg 对数据集中的样本数据进行标注,数据集标注格式与 PASCAL VOC 数据集一致,并将其按照 7:2:1 的比例随机划分训练集、验证集和测试集。

3.2 评价指标

本文的实验使用平均精度均值 mAP@0.5% 来评价检测模型的准确性,参数量(Parameters)和浮点运算数(FLOPs)来评价模型的复杂度,检测时间(Time)来评价模型的实时性,其定义分别如式(8)~(11)所示。

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

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

$$AP = \int_0^1 p(r) dr \quad (10)$$

$$mAP = \frac{1}{m} \sum_{i=1}^m AP_i \quad (11)$$

式中:TP 为预测为正类的正样本个数;FP 为预测为正类的负样本数;FN 是预测为负类的正样本数。

3.3 实验环境与参数设置

实验操作系统为 Windows 系统,实验配置如表 2 所示。训练网络时,batch size 设置为 16,输入网络训练的图像分辨率设置为 640×640,在 GPU 上进行训练,训练轮数为 100 轮,在训练过程中,采用随机梯度下降法对网络模型的参数进行优化。初始学习率、动量(momentum)、权重衰减等参数均使用 YOLOv5s 模型中的原始参数。

表 2 实验配置及其参数

Table 2 Experimental configuration and parameter

配置	参数
开发环境	Anaconda+Pycharm
CPU	Intel(R) Core(TM) i7-12700 2.10 GHz
GPU	Nvidia GeForce RTX 3060 Ti(8 G)
操作系统	Windows10
运行环境	CUDA11.1+torch1.9.0
编程语言	Python3.8

3.4 消融实验

1) 不同版本的 YOLOv5 对比

通过比较不同版本的 YOLOv5 性能发现,随着模型参数的增加,模型的检测性能显著提高。与 YOLOv5m 和 YOLOv5l 相比,YOLOv5s 以较少的参数和计算量实现了较好的精度,参数量为 7.3 M,因此,选择 YOLOv5s 作为基线。

2) C3 与 Faster_C3 对比

为了验证改进不同位置的 C3 模块在遮挡小目标检测方面的性能,探索最优的检测效果,将 Faster_C3 分别替换 YOLOv5 模型中不同位置的 C3 模块,进行了对比实验,实

验结果如表3所示。其中,模型C3表示未引入Faster_C3模块;Faster_C3模型表示将所有的C3模块替换为Faster_C3;Faster_C3a模型表示将backbone中的C3模块替换为Faster_C3;Faster_C3b模型表示将head中的C3模块替换为Faster_C3。

表3 C3与Faster_C3检测结果比较

Table 3 Comparison of C3 and Faster-C3 detection results

模型	mAP@0.5%	Paras/M	FLOP/G	时间/ms
C3	87.6	7.05	16.3	31.7
Faster_C3	86.9	5.78	12.6	29.7
Faster_C3a	88.1	6.34	13.8	29.7
Faster_C3b	87.5	6.46	14.6	29.7

由实验结果可知,在引入Faster_C3模块后,参数数量和浮点运算次数都有所降低,参数数量的减少主要原因是去掉了核大小为3的标准卷积模块。虽然PConv中的卷积核也为3,但它只对部分输入通道应用规则卷积(Conv),而对其他输入通道保持不变,既保持了遮挡目标特征的完整性及表示能力,更好地理解遮挡目标的上下文特征信息,又减少了参数数量,而引入Faster_C3a后,在提升精度的情况下,很大程度上降低了遮挡目标检测的计算开销,更适合在硬件配置较低的环境下部署。因此,本文将Faster_C3a模块为基础进行下一步的优化。

3) 不同特征金字塔池化结构比较

为了验证不同特征金字塔池化结构对遮挡小目标检测方面的性能,寻找最优的检测结果。比较了不同SPPF结构对整个网络性能的影响,在不同SPPF结构的网络上进行了实验。实验结果如表4所示。

表4 不同特征金字塔池化结构比较结果

Table 4 Comparison results of pyramid pooling structures with different features

模型	mAP@0.5%	Paras/M	FLOP/G	时间/ms
SPPF	87.7	7.05	16.3	31.7
SPPF_LSKA	88.9	8.08	16.6	32.4
BSPPF	89.1	6.37	15.2	30.0

由实验结果可知,与其他模型相比,在引入BSPPF结构后,在参数量和浮点运算数都减少的同时精度得到了提升,这是由于BSPPF能够在不同尺度上捕捉到遮挡目标更加精细的特征,使得模型能够更好地理解遮挡目标的局部特征和全局特征,有效地解决尺度不变性及遮挡目标特征信息损失问题,从而提高了模型对遮挡小目标检测的准确性以及鲁棒性;由于BSPPF采用GConv压缩卷积,故而在更好地捕获遮挡目标在不同尺度下的上下文信息的同时,减少了参数量,降低了计算开销。而引入SPPF_SLKA时,在SPPF的基础上融合了大可分离核的注意力机制(SLKA),通过捕捉空间域和通道域之间的依赖关系,使得模型更加关注遮挡目标的特征,增加了模型对遮挡目标特征提取的敏感度,进而提高了模型的检测精度,但引入了过多的参数量,检测速度变慢,因此,本文将BSPPF结构为基础进行下一步的优化。

4) 消融实验

为了验证所提模型在复杂环境下对遮挡小目标检测的有效性,在相同的实验环境下以YOLOv5s原模型为基础进行了一系列的消融实验。分别验证了Faster_C3a模块、Dysample上采样和BSPPF这3种改进策略给模型带来的性能增益,消融实验结果如表5所示。

表5 消融实验

Table 5 Ablation experiment

序号	模型	mAP@0.5%	Paras/M	FLOPs/G	时间/ms
A	YOLOv5s	87.6	7.05	16.3	31.7
B	A+Faster_C3a	88.1	6.34	13.8	29.7
C	A+Dysample	91.3	7.03	15.8	31.1
D	A+BSPPF	89.1	6.37	15.2	30.0
E	A+Faster_C3a+Dysample	90.9	6.35	13.8	29.2
F	A+Faster_C3a+Dysample+BSPPF	91.5	5.71	13.3	28.9

分析表5结果可知,在引入Faster_C3a后,如模型B与基础模型相比,在保证模型检测精度的情况下,参数量以及浮点运算数分别减少了10.13%和15.34%,检测速度也得到了提升,出现这一结果的原因是PConv在保持特征映射大小不变的情况下减少了通道数量,从而提高了模型的处理效率。

为了进一步提高模型的检测精度,而不增加模型的计

算开销与推理时间,在YOLOv5s模型的基础上,引入Dysample上采样方法,如模型C,与原模型相比,mAP@0.5提升了3.7%,主要得益于在边防检测场景下,入侵人员在图像中的像素占比通常较小,且存在着大面积遮挡等情况,会导致识别任务中特征学习困难以及特征图像细粒度丢失等问题,而Dysample上采样方法能够有效避免这一问题。

为了在降低模型的计算开销并提升检测速度的同时提升检测精度,引入 BSPPF 结构,如模型 D,在参数量和浮点运算量分别降低 9.70% 和 6.75% 的同时,mAP@0.5 提升了 1.5%,此外检测速度提高了 5.36%,证明了 BSPPF 结构在遮挡小目标检测方面的有效性。当同时引用 Faster_C3a、Dysample 和 BSPPF 后,如模型 F,与其他模型相比,mAP@0.5 提高了 3.9%,参数量和浮点运算量分别减少 19.07% 和 18.40%,检测速度提高了 8.83%,在一定程度上平衡了目标的检测精度、计算开销与检测速度之间的问题。由实验结果可知,本文的改进算法在提升精度的同时,很大程度上降低了复杂环境下遮挡小目标检测模型的参数量与浮点运算量,此外,检测速度也得到提升。因此,改进后的模型对边防复杂环境下的入侵人员检测实用性更强,消耗的内存资源更少,更适合在硬件配置较低的环境下部署。

5) 典型场景对比

为了更直观地说明检测效果的提升,图 7 所示为几个典型场景示例的检测结果。由图可知,YOLOv5 模型虽然可以检测到不同尺度的目标,但是在不同场景下对遮挡目标以及伪装小目标检测出现了漏检、误检现象。如场景 1

所示,由于环境背景与目标人员相似度较高,使得 YOLOv5 模型出现了误检现象,引入 Faster_C3a 模块后,模型能更好地理解特征信息,避免梯度消失,部分误检现象消失,模型的检测性能相对提高;随着 Dysample 上采样方法以及 BSPPF 结构的引入,进一步提高了对困难目标特征的提取能力,误检现象彻底消失,从而提高了模型的检测精度;如场景 2 和场景 4 所示,受到雾、雪天气以及大面积遮挡的影响,使得原始模型出现了误检、漏检现象,随着 Faster_C3a 模块的引入,模型能够更好地理解遮挡目标的上下文特征信息,减少遮挡以及背景对目标特征提取的影响,误检现象消失,引入 Dysample 上采样方法后,增强了模型对低分辨率图像和小目标的检测能力,从而提高了模型的检测精度,在此基础上,引入 BSPPF 结构,由于解决了遮挡目标特征信息损失问题,漏检现象消失,进一步提高了模型的检测性能;如场景 3 所示,由于目标较小且存在大面积遮挡的情况,基线 YOLOv5 模型出现了漏检现象,当同时引入 Faster_C3a 模块、Dysample 上采样方法和 BSPPF 结构后,模型能够完整、高精度地检测到所有目标。改进后的模型比初始模型达到了更好的检测效果,检测精度相对提高。

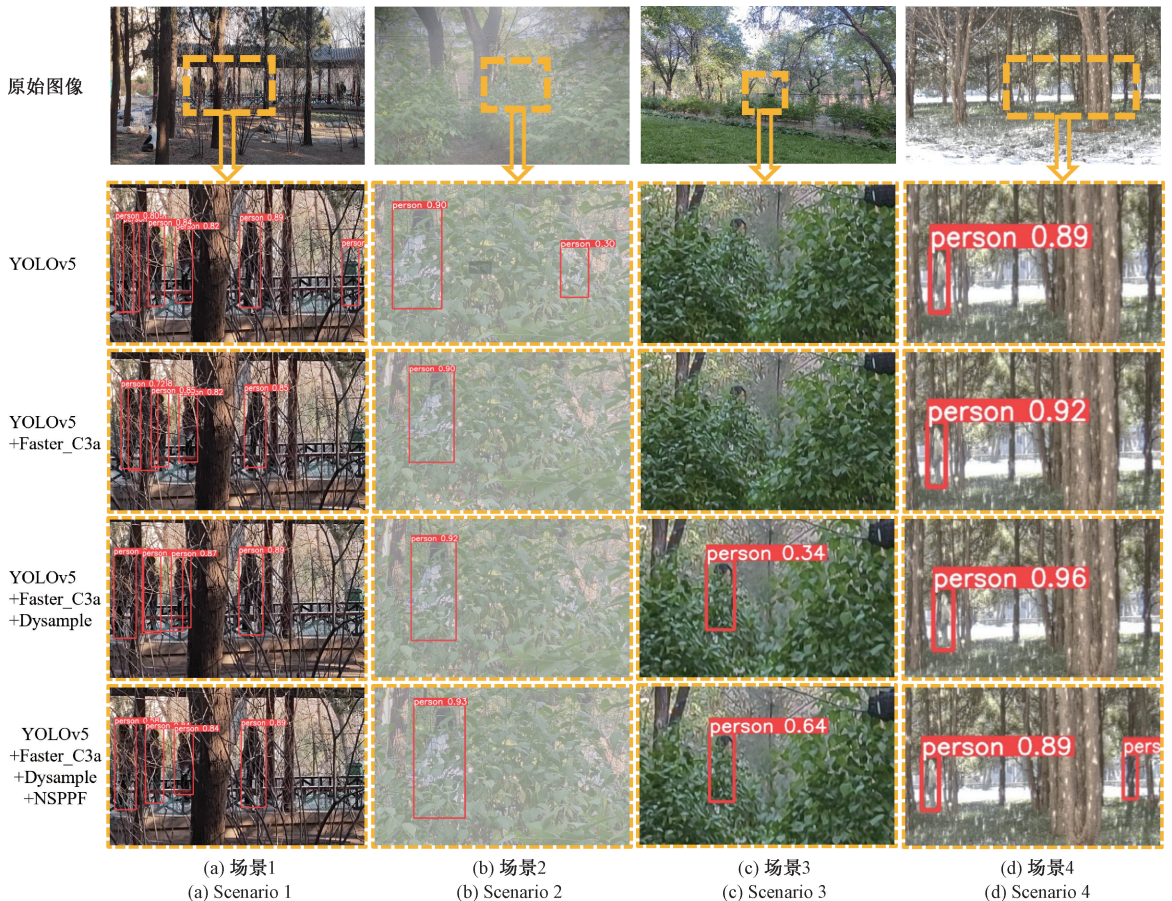


图 7 目标检测示例图

Fig. 7 Example image of object detection

3.5 对比试验

1) 不同主流算法对比试验

为了验证所提算法的优越性,本模型与 Faster R-CNN、SSD、YOLOv5s、YOLOv8s 等一系列目标检测算法在相同的数据集和实验条件下进行了对比实验,模型均已收敛,实验结果如表 6 所示。

表 6 不同算法对比实验

Table 6 Comparison experiment of different algorithms

模型	mAP@0.5%	Paras/M	FLOP/G	时间/ms
Faster R-CNN	35.2	—	—	70.4
SSD	54.1	—	—	7.0
YOLOv5s	87.6	7.05	16.3	31.7
YOLOv8s	84.9	11.13	28.4	31.4
FDB-YOLOv5	91.5	5.71	13.3	28.9

由实验结果可知,该算法的 mAP@0.5 比 Faster R-CNN、SSD 和 YOLOv8s 分别高出 56.3%、37.4% 和 6.6%,参数量比 YOLOv8s 降低 94.92%,浮点运算量比 YOLOv8s 降低 113.53%,推理速度比 YOLOv8 快 7.96%。实验结果表明,优化后的 YOLOv5 模型在降低内存开销和计算量的同时,保持了较高的检测率和准确率。与原有的 YOLOv5 模型和主流目标检测算法相比,它消耗的内存资源更少,更适合在硬件配置较低的环境下部署。

2) 不同遮挡效果对比试验

为了更直观地验证所提 FDB-YOLOv5 检测算法对复杂环境下遮挡小目标检测的优越性,针对不同遮挡面积的小目标检测结果进行了验证,典型结果如图 8 所示。图中目标占比为 0.12%,遮挡面积为 82.63%,满足小目标以

及遮挡目标的定义,检测精度为 85%,表现出较好的检测性能。




图 8 遮挡效果示例图

Fig. 8 Example image of occlusion effect

图 9 所示为在不同遮挡条件下的检测结果。由图可知,得益于改进后的模型能够更好地学习到目标的有效特征,解决遮挡目标特征信息损失问题,因此随着遮挡面积的增加,该模型保持着较高的检测精度,并未受到环境的干扰而出现漏检、误检现象,表明改进后的算法对遮挡小目标检测的准确性以及鲁棒性。而当目标几乎被相似背景完全遮挡时,如图 9(f) 所示,该模型依然保持着优异的检测性能,并未受到相似背景的干扰;当目标处于雨、雾、雪等恶劣天气环境下时,如图 9(c)、(b)、(e) 所示,改进后的模型并未受到环境的影响,完整地检测出了被遮挡的小目标但在整个验证集中,对于部分遮挡小目标的检测,出现了误检现象,误检率为 5.97%,主要原因是模型在提取遮挡目标特征时,由于目标在图像中的像素占比过小且受到外界环境的影响,出现了过拟合现象,错误地将与背景相似很低的物体检测为目标。综上所述,可以认为本文所提出的改进 FDB-YOLOv5 模型对遮挡小目标的检测的有着更优异的抗遮挡效果以及稳定性,可以较好地服务于无人边防的目标检测当中。



(a) 目标占比: 0.86%, 遮挡面积: 57.54%
(a) Target proportion: 0.86%, covering area: 57.54%



(b) 目标占比: 0.15%, 遮挡面积: 85.93%
(b) Target proportion: 0.15%, covering area: 85.93%



(c) 目标占比: 0.19%, 遮挡面积: 89.44%
(c) Target proportion: 0.19%, covering area: 89.44%



(d) 目标占比: 0.26%, 遮挡面积: 90.12%
(d) Target proportion: 0.26%, covering area: 90.12%

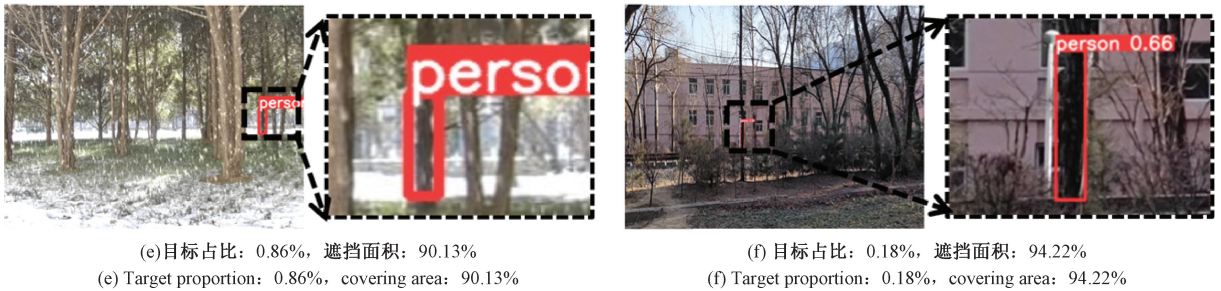


图 9 不同遮挡效果对比结果图

Fig. 9 Comparison results of different occlusion effects

3) 不同遮挡目标检测算法对比分析

遮挡目标检测算法根据所采集数据形式的不同,主要分为可见光目标检测和红外目标检测。在红外目标检测方面,由于其独特的物理特性,红外技术能够有效探测到环境温度的变化,进而识别出隐蔽或部分遮挡的目标。这种能力使得红外监测在复杂环境中具有显著优势。然而,红外目标监测也面临一些挑战。在复杂背景下,热噪声和伪影可能降低检测精度。可见光摄像头分辨率高,纹理信息丰富,成本通常较低,且易于维护和升级,但大面积的遮挡可能导致小目标的整体轮廓缺失,从而影响检测算法的效果。因此,图像融合技术的应用对于提高遮挡目标检测的准确性显得尤为重要,通过结合红外数据与可见光图像,可以有效提升检测效果。因此,本文重在提升可见光遮挡小目标检测算法的性能,为下一步开展可见光和红外图像的融合奠定基础。

4 结 论

本文以 YOLOv5s 模型为基线,提出了一种名为 FDB-YOLOv5 模型的边境复杂环境遮挡小目标检测算法,一定程度上解决了边境复杂环境下的遮挡目标检测误检测以及漏检率高、实时性差的问题。该算法能够在计算资源有限设备上对复杂环境下的遮挡小目标进行检测。首先,根据 Fasternet 网络,在算法的颈部网络中引入了 Faster_C3 新结构,降低了模型的参数量和计算复杂度;其次,在模型中引入基于点采样的动态上采样器 Dysample,以最小的计算开销增强了模型对低分辨率目标和小目标的检测能力;最后,引入 BSPPF 结构,能够在不同尺度上捕捉到更加精细的目标特征,以有效地解决尺度不变性问题,提高系统稳定性目标检测模型的性能。

实验结果表明,与两阶段算法 Faster R-CNN 相比,本文设计的模型在检测精度方面具有显著的竞争力。与同一系列的其他 YOLO 算法相比,FDB-YOLOv5 模型在减少计算开销及内存占用的同时,保持了较高的检测率和准确性,还提升了检测速度,在一定程度上平衡了目标检测精度、速度与计算资源及内存占用的问题。此外,不同遮挡面积的小目标进检测结果表明,该模型对复杂环境下遮

挡小目标检测的优越性,为边境复杂遮挡环境下的目标检测提供了参考。然而,目前边境复杂环境下的数据集还不够充足,入侵人员的动作类型也较为单一,后续可以考虑对其进行扩充以增加样本的丰富性;在未来的工作中,将进一步探索如何在降低复杂环境下遮挡目标检测算法的计算开销及内存占用的同时更大程度上提高检测精度,使其在资源及算力有限的设备上部署的同时,提高模型检测的准确性,以满足实际边境场景需求。

参考文献

- [1] 亓玉昆. 全国共侦破妨害国(边)境管理犯罪刑事案件 1.8 万余起[N]. 人民日报, 2022-01-14(6).
QI Y K. More than 18000 criminal cases of obstructing national(border) management have been solved nationwide [N]. People's Daily, 2022-01-14(6).
- [2] 张希文, 张渊, 王龙. 边境地区武装巡逻反袭击行动探要[J]. 中国人民警察大学学报, 2017, 33(1): 23-26.
ZHANG X W, ZHANG Y, WANG L. Exploration of armed patrol anti attack operations in border areas[J]. Journal of China People's Police University, 2017, 33(1): 23-26.
- [3] GIRSHICK R. Fast R-CNN[C]. IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [4] 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.
- [5] DAI J F, LI Y, HE K M, et al. R-FCN: Object detection via region-based fully convolutional networks [J]. Advances in Neural Information Processing Systems, 2016: 379-387, DOI:10.48550/arXiv.1605.06409.
- [6] LIU W, ANGELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. 14th European Conference on Computer Vision, 2016: 21-37.
- [7] VARGHESE R, SAMBATH M. YOLOv8: A novel object detection algorithm with enhanced performance and robustness[C]. 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS), 2024: 1-6.

- [8] 卢嫚, 朱世博. 基于 OpenCV 和 YOLOv5 的车道线检测与识别[J]. 国外电子测量技术, 2024, 43(6): 134-142.
LU M, ZHU SH B. Lane detection and recognition based on OpenCV and YOLOv5 [J]. Foreign Electronic Measurement Technology, 2024, 43(6): 134-142.
- [9] KRIŠTO M, KOS I M, POBAR M. Thermal object detection in difficult weather conditions using YOLO[C]. IEEE Access, 2020: 125459-125476.
- [10] HU X D, WANG X Q, YANG X, et al. An infrared target intrusion detection method based on feature fusion and enhancement [J]. Defence Technology, 2020, 16(3): 737-746.
- [11] YUE L, LING H F, YUAN J H, et al. A lightweight border patrol object detection network for edge devices[J]. Electronics, 2022, 11(22): 3828.
- [12] LI X H, XIE Z Y, LAI T T, et al. NAS-WFPN: Neural architecture search weighted feature pyramid networks for object detection[C]. Lecture Notes in Computer Science, 2021: 384-394.
- [13] 宋晓茹, 刘康, 高嵩, 等. 复杂战场环境下改进 YOLOv5 军事目标识别算法研究[J]. 兵工学报, 2024, 45(3): 934-947.
SONG X R, LIU K, GAO S, et al. Research on improved YOLOv5-based military target recognition algorithm used in complex battlefield environment[J]. Acta Armamentarii, 2024, 45(3): 934-947.
- [14] WOO S, PARK J, LEE J, et al. CBAM: Convolutional block attention module[C]. European Conference on Computer Vision(ECCV), 2018: 3-19.
- [15] 侯艳丽, 唐博华. 基于改进 YOLOv5 的 PCB 缺陷检测算法[J]. 国外电子测量技术, 2023, 42(11): 24-32.
HOU Y L, TANG B H. PCB defect detection algorithm based on improved YOLOv5 [J]. Foreign Electronic Measurement Technology, 2023, 42(11): 24-32.
- [16] OUYANG D, HE S, ZHANG G ZH, et al. Efficient multi-scale attention module with cross-spatial learning[C]. ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing, 2023: 1-5.
- [17] LI Y Y, HUANG Q, PEI X, et al. Cross-layer attention network for small object detection in remote sensing imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 2148-2161.
- [18] 冯哲, 王彬, 黄鹏程, 等. 小天体表面着陆区岩石目标检测算法[J]. 仪器仪表学报, 2024, 45(4): 194-205.
FENG ZH, WANG B, HUANG P CH, et al. Algorithm of detection rock object in landing zone of small celestial body surface [J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 194-205.
- [19] 翁俊辉, 成乐, 黄曼莉, 等. 基于 CS-YOLOv5s 的无人机航拍图像小目标检测[J]. 电子测量技术, 2024, 47(7): 157-162.
WENG J H, CHENG L, HUANG M L, et al. Small target detection for UAV aerial images based on CS-YOLOv5s[J]. Electronic Measurement Technology, 2024, 47(7): 157-162.
- [20] HE SH T, LUO H, WANG P CH, et al. TransReID: transformer-based object re-identification[C]. IEEE/CVF International Conference on Computer Vision, 2021: 15013-15022.
- [21] ZHANG ZH ZH, LAN C L, ZENG W J, et al. Relation-aware global attention for person re-identification[C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020: 3183-3192.
- [22] 傅荟瑾, 史天运, 王瑞, 等. 基于改进 ByteTrack 的高铁周界入侵监测方法研究[J]. 仪器仪表学报, 2023, 44(4): 61-71.
FU H J, SHI T Y, WANG R, et al. Research on intrusion detection of high speed railway perimeter based on the improved ByteTrack[J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 61-71.
- [23] 许迪, 张淑卿, 葛超. 面向复杂环境的 YOLOv8 安全装备检测[J]. 电子测量技术, 2024, 47(7): 121-129.
XU D, ZHANG SH Q, GE CH. YOLOv8 security equipment inspection for complex environments [J]. Electronic Measurement Technology, 2024, 47(7): 121-129.
- [24] 孙备, 党昭洋, 吴鹏, 等. 多尺度交互交叉注意力改进的单无人机对地伪装目标检测定位方法[J]. 仪器仪表学报, 2023, 44(6): 54-65.
SUN B, DANG ZH Y, WU P, et al. Multi scale cross attention improved method of single unmanned aerial vehicle for ground camouflage target detection and localization [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 54-65.
- [25] LIN T, MAIRE M, BELONGIE J S, et al. Microsoft COCO: Common objects in context [C]. European Conference on Computer Vision, Springer International Publishing, 2014.
- [26] KRISHNA H, JAWAHAR C V. Improving small object detection[C]. 2017 4th IAPR Asian Conference on Pattern Recognition(ACPR), 2017: 340-345.

作者简介

王慧云, 硕士研究生, 主要研究方向为计算机视觉、目标检测。

E-mail: 2508147155@qq.com

赵俊生, 博士, 硕士生导师, 教授, 主要研究方向为机器视觉、图像处理。

E-mail: zjsnuc@163.com

王禹(通信作者), 博士, 讲师, 主要研究方向为机器学习、目标检测。

E-mail: wysummer@nuc.edu.cn