

基于改进 YOLOv5m 的弱小目标识别方法

杨文涛, 张维光

(西安工业大学 光电工程学院, 西安 710021)

摘要: 针对空对地观测弱小目标识别与跟踪技术需求, 提出了一种改进型 YOLOv5m 网络的多目标识别检测方法, 以提升对所占像素个数小于 10×10 弱小目标的识别能力; 分析了网络结构输入端 Mosaic 数据增强、Anchor 计算、Focus 模块及 SPP 模块对弱小目标的影响; 在深度学习网络 Prediction 层引入距离交并比非极大值抑制 (DIoU-NMS) 代替传统非极大值抑制 (NMS), 引入距离交并比损失函数 (DIoU_Loss) 代替广义化交并比损失函数 (GIoU_Loss), 加快边界框回归速率, 提高定位精度, 消除重叠检测, 并在网络中引入 4×4 以上像素的目标识别层, 提升对遮挡重叠弱小目标识别的准确率; 实验结果表明, 改进的深度学习网络算法与经典的 YOLOv5m 网络相比, 目标识别的均值平均精度 mAP 指标达到 89.7%, 对比原网络提高了 4.1%, 实现了对图像像素个数小于 10×10 的弱小目标高精度识别, 有效提升了深度学习网络对弱小目标的适应性和应用价值。

关键词: 多目标识别; yolov5m; 损失函数; 目标识别层; 深度学习

Method of Weak and Small Targets Recognition Based on Improved YOLOv5m

YANG Wentao, ZHANG Weiguang

(School of Optoelectronic Engineering, Xi'an Technological University, Xi'an 710021, China)

Abstract: Aiming at the needs of air-to-earth observation weak and small target recognition and tracking technology, a multi-target recognition and detection method of improved YOLOv5m network is proposed to improve the recognition ability of weak and small targets with less than 10×10 pixels; The influences of Mosaic data enhancement, Anchor calculation, Focus module and SPP module on weak and small targets at the input end of network structure are analyzed; In the prediction layer of deep learning network, the distance intersection over union non-maximum suppression (DIoU-NMS) is introduced to replace the traditional non-maximum suppression (NMS), and the distance intersection over union loss function (DIoU_Loss) is introduced to replace the generalized intersection over union loss function (GIoU_Loss), speed up the bounding box regression rate, improve the positioning accuracy, eliminate the overlapping detection, and introduce a target recognition layer with more than 4×4 pixels in the network to improve the accuracy of occlusion overlapping weak and small targets; The experimental results show that, compared with the classic YOLOv5m network, the improved deep learning network algorithm reaches 89.7% of average precision mAP index, which is 4.1% higher than that of the original network, and realizes the image pixel number less than 10×10 , which effectively improves the adaptability and application value of the deep learning network to weak and small targets.

Keywords: multi-target recognition; YOLOv5m; loss function; object recognition layer; deep learning

0 引言

基于机载平台的空对地观测目标识别技术是一种不断发展的军民两用技术。民用技术已成功应用于防灾减灾、农田管理、大区域工业监控等领域。军用技术已成功应用于大区域防务、敌对目标识别等领域。空对地观测由于被观察目标离机载平台较远, 目标在图像数据中所占像素点有限, 表现出弱小目标的特征。有的应用领域目标在图像数据中所占像素个数小于 10×10 , 目标的色彩、纹理及形状等特征在目标识别过程中难以提取。加之空对地观测以

大地为背景, 背景事物的随机性较大, 目标与背景之间相互关联关系不高, 目标识别的难度较大。国内外弱小目标识别技术根据是否使用神经网络可以分为非神经网络技术和神经网络技术两大类。非神经网络的弱小目标识别技术主要利用背景建模和目标在图像序列之间的关联特征关系实现目标识别。背景建模目标识别技术典型技术有基于高斯背景的目标识别技术, 应用高斯混合模型对其背景进行建模, 分辨出图像前景和背景来实现对弱小目标的识别^[1], 但该方法对弱小目标识别准确率较低。基于目标图像关联

收稿日期: 2022-05-05; 修回日期: 2022-05-31。

基金项目: 航空科学基金(202000190U1002)。

作者简介: 杨文涛(1995-), 男, 陕西省宝鸡人, 硕士, 主要从事图像处理与模式识别、嵌入式图像处理技术方向的研究。

通讯作者: 张维光(1973-), 男, 陕西咸阳人, 博士, 副教授, 硕士生导师, 主要从事图像处理及模式识别、嵌入式图像处理技术、智能光电成像技术、光电信息处理技术等方向的研究。

引用格式: 杨文涛, 张维光. 基于改进 YOLOv5m 的弱小目标识别方法[J]. 计算机测量与控制, 2022, 30(12): 218-223, 231.

特征的目标识别技术, 钟小莉等人^[2]研究了利用离焦模糊图像序列对弱小目标进行自动检测, 采用了小波分解的方法对图像进行分解, 通过缩减小波系数, 滤除弱小目标复杂背景的噪声, 完成动态聚类的目标检测, 该方法的检测效率虽然较好, 但是对于相似背景下的弱小目标检测精度较低。张素等人采用时空域图像块模型求解图像目标, 最终实现弱小目标的识别^[3], 但该方法对于像素尺寸为 10×10 以下的弱小目标依然存在识别精度低的问题。基于神经网络的弱小目标识别方法可以分为分类回归神经网络技术和深度学习目标识别技术两大类。分类回归神经网络对于多目标识别与跟踪精度不高, 适用性不强, Z. Huang 等人^[4]提出了改进的分类回归深度卷积神经网络对小目标进行识别, 但该方法容易造成弱小目标分类识别率低、实时性低的问题。基于深度学习的目标识别方法可以为分双阶段和单阶段两种。双阶段深度学习网络可以实现目标的高精度识别与跟踪, 但因基运算量较大, 目标识别系统实时性较低, K. He 等人^[5]在提出的双阶段 R-CNN 算法基础上设计了一种空间金字塔池化层, 使得该网络不仅克服了多尺度提取、弱小目标特征表达能力的缺点, 并且解决了在卷积神经网络中只能限制输入固定大小的情况, 但是由于增加网络结构存在着检测目标速度慢的问题。单阶段深度学习目标识别方法的典型代表是系列 You Only Look Once (YOLO)^[6]及其衍生模型, 可以实现目标的快速识别。对于实时性要求较高的应用领域 yolo 方法, 通过开发提升网络目标识别准确率的新型模块与单元, 可以实现对多目标的高精度高速检测与识别。

针对机载平台计算资源有限条件下空对地观高精度高速目标识别与跟踪技术需求, 本文选用 YOLOv5m 网络模型为研究对象, 通过增加小目标检测层, 提高对弱小目标的检测能力; 在原始的特征融合网络 (FPN, feature pyramid network) + (PAN, pyramid attention network) 结构的结合下, 使用 4 个降采样特征图作为该网络的输入, 减小下采样后特征图的感受野; 在后处理端选用 DIoU-NMS 代替传统非极大值抑制 NMS, 选用 DIoU_Loss 代替 YOLOv5m 的 GIoU_Loss, 加快边界框回归速率, 提高定位精度, 以提升网络对所占图像像素个数小于 10×10 弱小目标的识别能力, 并完成了对比实验分析。

1 YOLOv5m 网络模型结构分析

YOLO 算法是一种单阶段 (One-stage) 算法典型的代表之一, 该算法可以直接从图片生成位置和类别, Yolov5 算法是在 YOLOv4 的基础上进行了改进, 是一系列在 Common Objects in Context (COCO) 数据集预训练的对象检测架构和模型。YOLOv5 到目前截至一共发布了 4 种版本的目标检测网络模型, 分别是 YOLOv5 的 s、m、l 和 x 模型网络, 网络深度的大小决定了提取和融合特征的能力, 而网络的宽度的大小则决定了特征提取的学习能力, 其中 YOLOv5s 的深度最浅、宽度更窄, 网络的速度更快, 但是它的精度最低, 后面 3 种模上不断加深、加宽^[7], 在随着深

度和宽度的增加, 多目标识别的精度就会越高, 识别的速度也会随之降低。在机载平台上, 由于计算资源有限, 目标检测速度低, 所以为了达到速度和精度综合的情况下, 选择了 YOLOv5m 模型。

YOLOv5m 模型网络的改进网络结构总体来说主要有 4 部分^[8], 如图 1 所示。

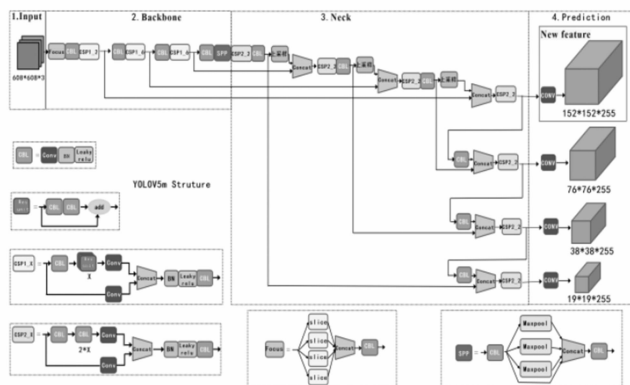


图 1 改进 YOLOv5m 网络结构图

其中这 4 部分的功能结构如下:

输入端 (Input): 马赛克图像数据增强、自适应图像缩小放大和自适应锚框计算。

主干网络 (BackBone): Focus 结构、CSP (Cross stage partial) 结构和 SPP (Spatial Pyramid Pooling) 模块。

网络的颈部 (Neck): FPN+PAN 结构。

预测输出端 (Prediction): DIoU_Loss、DIoU_NMS。

1) 马赛克数据增强 (Mosaic)。YOLOV5 一般在输入端对图片有 3 种增强数据的方式: 图片的缩小放大、图片的颜色空间调整和马赛克数据增强。其中马赛克数据增强 (Mosaic) 是通过将 4 张训练图像进行随机方式的缩放、裁剪和分布等方法进行组合成为一张图像, 这样会提升对弱小目标的检测效果^[9], 结合这 4 种图像彼此不同的上下文信息, 丰富了图像检测目标的背景, 这使得网络检测弱小目标范围增大, 加快收敛速度, 增强算法模型的鲁棒性^[10], 其原理如图 2 所示。

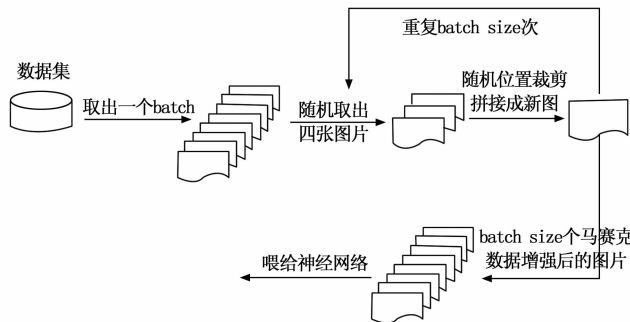


图 2 Mosaic 数据增强

2) 自适应锚框计算。预定义边框, 就是在训练之前提前设置的一些边框, 在训练过程中, 用真实的边框与预定

义边框之间的偏移来形成（也就是我们打下的标签）训练样本，在 YOLO 系列中，可以针对数据集设置初始的锚框（Anchor）。在对网络进行训练的过程中，网络首先输出预测锚框，接着将预测锚框和 GroundTruth 锚框进行比较，计算 loss，然后通过反向更新，迭代网络优化参数。在 YOLOv3 和 YOLOv4 版本中，设置初始 Anchor 的大小都是通过程序使用 K-means 算法得到，而在 YOLOv5 整体代码中，将此功能的算法放入到了代码中，经过每次训练数据集的时候，算法会自动计算该数据集得到最合适的 Anchor 尺寸，即最佳锚框值^[11]，该功能也可以在相应代码中设置超参数进行关闭。

3) Focus 模块。Focus 模块在图像进入到主干网络之前，先对图像进行切片操作^[12]如图 3 所示，在每张图像中间隔一个像素提取一个值，从左到右，从上到下遍布完整张图片，操作后结果获得 4 个图像，这 4 张图像相互间互补，切片操作后使得信息完全没有缺失，通道空间包含了信息的宽和高，因此通道扩大了 4 倍，这样，拼接出来得到的图片将原来图片的 RGB 三个通道经过扩充增加到了 12 个通道，再进行卷积操作后，最终结果获得了二倍下采样的特征图像。Focus 结构的优点在于虽然它的计算量和参数量降低，但是经过下采样后信息没有缺失，在保持精度不变的同时，提高了弱小目标的检测速率。




图 3 切片操作原理

4) SPP 模块。SPP 模块应用于主干网络后，在使用类似 1×1、5×5、9×9、13×13 的最大池化的方法后，最后结合起这些不同的特征图，此模块既可以使主干特征的接受范围增加，扩大了感受野范围，而且将最重要的上下文信息特征进行了显著的分开^[13]，提高复杂背景下弱小目标的识别率。

2 YOLOv5m 算法改进

2.1 特征融合网络改进

Neck 层网络的作用是为了提高提取融合图像的特征的能力，FPN+PAN 结构使得特征提取的能力增加，起着承上启下的关键环节，其中 FPN^[14]特征金字塔结构是经过 top-down 的顺序结构，利用最高层的强语义将信息特征传递下来，再通过上采样将高、低层特征信息进行信息特征融合，从而产生即将预测的特征图像。PAN 结构是设计在 FPN 结构后面的金字塔中，经过了 down-top 的路径增强，PAN 所在的特征金字塔采用了下采样的方法，对准确定位信息进行传递。

在原始的特征融合网络 FPN+PAN 结构的结合下，将 76×76、38×38、19×19 共 3 个不同的特征图进行融合，输出 3 种不同的结果，如图 4，现在在此基础上使用 4 个降采样特征图作为该网络的输入，使得下采样后的特征图感受野减小，FPN 层通过自顶向下的结构表达了强语义信息特征的功能，而 PAN 结构所在的特征金字塔通过自底向上的结构表达了强定位信息特征的功能，两者结合提高了特征融合提取的能力，让模型学习到更多的学习特征，提高对弱小目标的识别精度，改进的 neck 层特征融合网络如图 5 所示。




图 4 FPN+PAN 结构图




图 5 改进的特征融合网络

2.2 网络后处理端改进

2.2.1 改进的 Bounding box 损失函数

目标检测算法的损失函数总体是由两部分分类损失函数和边界框回归损失函数组成，一般常用的回归损失函数有 IoU_Loss、GIoU_Loss、DIoU_Loss、CIoU_Loss 这 4 种，IoU 表示目标真实框与预测框的交集与两者并集之比，IoU 的损失函数表示为：

$$IoU_Loss = 1 - IoU = 1 - \frac{A}{B} \quad (1)$$

式中，A 为真实框与预测框的交集，B 为真实框与预测框的并集，IoU 损失函数虽然得到的预测框受真实边界框尺寸影响小，鲁棒性较好，但是也存在缺点，当预测框与真实框不相交的时候，这时 IoU=0 时，预测效果最差，该损失函数就不可行了。

GIoU 的损失函数表示为：

$$GIoU_Loss = 1 - GIoU = 1 - \frac{C - B}{C} \quad (2)$$

式中，C 为目标预测框与实际框的最小外接矩形，GIoU 损失函数是在 IoU 损失函数上的基础上多考虑了一个因素，

GIoU 不仅考虑到了检测框和目标框之间的重叠面积, 并且还关注了其他区域的非重合部分, 因此可以更好的反映预测框与目标框的重合度, 而且增加了两者相交尺度的衡量方式。但是也存在缺点, 如果预测框存在于真实框的内部, 并且几种预测框的大小一致, 即 C-B 值相同, 就出现了无法区分预测框相对位置的情况, 这时该损失函数就失去了效果。

DIoU 的损失函数表示为:

$$DIoU_Loss = 1 - \left(IoU - \frac{D^2}{E^2} \right) \quad (3)$$

式中, D 为目标预测框与实际框内部最小外接矩形 C 之间的对角线距离值, E 为目标预测框的中心点与实际框内部中心点间的距离值, 而 DIoU 损失函数则是在 GIoU 损失函数的基础上再次进行了优化, DIoU 不但考虑了两者的重叠面积还同时考虑了两者间的中心点距离, 当出现了预测框在真实框内部, 两者有交集的情况下, 考虑了中心点距离后, 就加快边界框的回归速率, 使得 DIoU_Loss 收敛的速度加快。但是如果预测框和实际框没有交集, 而预测框的大小不相等, 预测框的中心点位置即使一样, 也会出现 E 值相等, 这时根据 DIoU_Loss 公式, 损失函数相等, 损失函数就失去了效果。

CIoU 的损失函数表示为:

$$CIoU_Loss = 1 - \left(IoU - \frac{D^2}{E^2} - \frac{v^2}{(1 - IoU) + v} \right) \quad (4)$$

式中, v 为一个影响因子, 在 DIoU 损失函数的基础上多增加了一个因素, 即预测框与实际框长宽的比值。这样综合下来 CIoU 损失函数总共有 3 种因素, 分别为预测框与实际框的交集区域、两者中心点距离和两者长宽比, 但是由于 CIoU 损失函数多添加了一个影响因子, 所以就会影响收敛速度^[15]。

综上所述, 考虑到预测框回归的速度和精度综合的情况下, 该实验在输出层选择用 DIoU_Loss 代替 GIoU_Loss 作为边界框回归损失函数, 加快边界框回归的速率以及提高定位精度, 加快对弱小目标的检测速率。

2.2.2 NMS 非极大值抑制改进

非极大值抑制中, 一般用 IoU 指标来表示抑制重复多余的检测框^[16], 在众多影响因素当中, 重叠面积的影响最大, 在弱小目标部分被遮挡的情况下, 经常会造成错误的抑制。在目标检测完成后, 对于很多目标框, 要进行筛选, 留下一个框, 所以通常需要进行 NMS 非极大值抑制操作。非极大值抑制的原理就是通过分类器首先得到多个边界框以供选择, 并且得到关于边界框中属于类别的概率值, 将得到的概率值进行排序, 选择出最高的概率所在的框, 用别的框与此框做比较, 最终将无用框删掉, 留下一个类别可能性最高的框^[17]。在目标检测的时候, 有的目标相互遮挡或被其他物体遮挡, 不同目标的检测框距离太近, 经过 NMS 非极大值抑制操作后, 检测框也会被去除, 就会导致识别失败。选择 DIoU-NMS 操作, 将 DIoU 作为传统 NMS

抑制的准则, 在此抑制准则中不仅考虑了真实框与预测框的交集区域还考虑了两者内部的中心点距离, 这样可以使得过滤的准确度更加提高, DIoU_NMS 操作对于一些互相遮挡的小目标, 会有很好的识别效果, 所以选用 DIoU_NMS 代替传统的 NMS, 提高对于弱小目标互相之间的遮挡或者被其它物体遮挡的识别率。

2.3 增加小目标检测层

空对地观测情况下检测目标像素尺寸基本都在 10×10 以下, 而 YOLOv5 的下采样倍数比较大, 在深层次的特征图很难学习到小目标的特征信息。所以该算法对于小目标检测效果不好, 在原始 YOLOv5 模型中只有 3 种不同的检测层, 输入图像尺寸为 608×608 时, 大的检测层为 76×76 的特征图可以检测 8×8 以上像素的目标, 中等检测层为 38×38 的特征图可以检测 16×16 以上像素的目标, 小的检测层为 19×19 的特征图可以检测 32×32 以上像素的目标, 所以在本次改进中提出增加小目标检测层, 增加了更大的检测层为 152×152 的特征图可以对 4×4 以上像素的目标进行检测, 对浅层特征图和深层特征图拼接后进行检测, 使得空对地观测下 10×10 以下像素的弱小目标有着很好的检测效果, 提出的多尺度检测结构如图 6 所示。

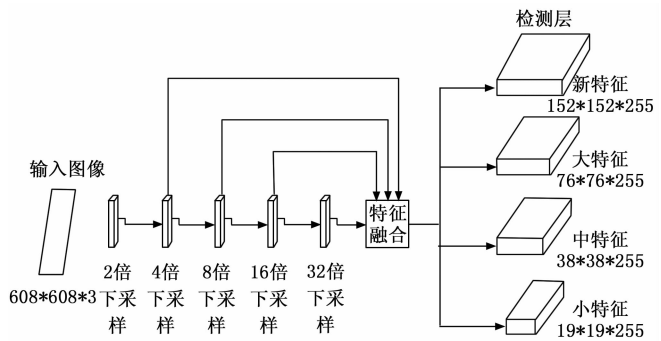


图 6 多尺度检测结构

3 实验结果及分析

3.1 数据集预处理

该实验的数据集是利用建模的方法得到空对地观测下的弱小目标视频, 然后编写程序对视频进行指定大小、指定帧数间隔的方式获得大量的数据集图像, 数据集准备好之后, 选择 Labelimg 标注图像软件工具对原始图像数据集进行打标签操作, 首先将设置数据集标注为 voc 标签格式, 保存为 xml 文件, 数据集中包含了目标的名字、大小以及存放的位置, 统一图片格式, 制作图像标注, 最后将标签封装到样本中后, 将其序列化。由于 YOLOv5 模型需要的数据集标签格式为 txt 文件, 通过转化代码脚本, 将 xml 文件转换为 YOLOv5 所需要的 txt 文件。在标注数据集的时候, 要将数据集和打好的标签对应起来, 在目标检测图像分类的数据集中, 只需要标注图片中所含目标以及目标的类别即可。

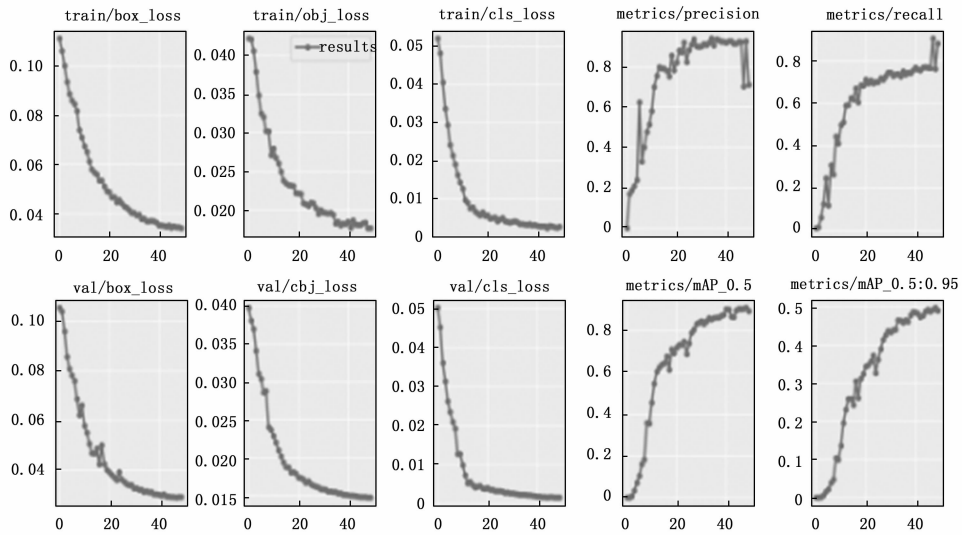


图 7 训练参数变化图

3.2 模型训练

数据集标注好之后，对模型进行初始设置，修改数据配置文件和模型配置文件，搭建好 YOLOv5m 模型环境，根据自己的电脑性能，设置好训练适应的参数，本文选择迁移学习的方法对该数据集进行训练，迁移学习是一种深度学习策略，将已经在大量数据集上训练好的模型迁移到我们的规模针对新型目标的数据集，然后对数据集进行新模型的预训练^[18-20]，使得最终训练好的神经网络对新型目标有着很好的检测效果，因此使用 yolov5m_pt 这个预训练权重作为初始网络权重对数据集进行训练，由于该预训练权重之前在超大的数据集上训练得到的权重文件，基于此，用此预训练权重直接训练该数据集即车以及飞机等，可以提高网络的学习和优化，增加泛化能力，使得改进的 YOLOv5m 模型具有很好的鲁棒性，训练结果如图 7 所示，训练完成后，各项数值变化基本趋于平稳状态。


3.3 实验测试结果

训练结束后，在 runs/train 文件夹下会自动生成训练结果，其中包括模型权重、混淆矩阵、PR 曲线等。将权重文件路径修改为训练好的 best 权重文件路径，改进前后的模型对弱小多目标检测结果如图 8 所示，可以看到图 (a) 使用原 YOLOv5m 算法进行检测，出现了漏检和错检的结果，将旁边的建筑物错检测成了飞机，并且将图中的飞机没有检测出来，而图 (b) 使用改进的算法进行检测，成功将图中的弱小目标飞机和车全部检测出来，保证改进算法后稳定并且准确的检测效果。

对于遮挡后的目标检测结果分别如图 9 所示，可以看到图 (a) 使用原 YOLOv5m 算法进行检测，依然出现了漏检的情况，被低空飞行的飞机遮挡下的车没有检测出来，而图 (b) 使用改进算法进行检测，可以将飞机遮挡下的车成功准确的识别出来，图 (c) 使用原 YOLOv5m 算法进行检测，看到图 (d) 中被树遮挡后的车没有检测出来，而图



(a) YOLOv5m 算法检测结果



(b) 改进算法检测结果

图 8 目标检测结果图

(d) 使用改进算法进行检测，可以将树木遮挡下的车成功的检测出来。

3.4 实验性能评估指标

均值平均精度 (mAP, mean average precision) 经常作为目标检测中衡量检测精度的指标。将正样本正确的划分为正例的数量为 TP (true positives)，将负样本正确地划分为负例的数量为 TN (true negatives)，将正样本错误的划分为负例的数量为 FN (false negatives)，将负样本错误的划分为正例的数量为 FP (false positives)，精确率 (precision) 为 P ，反映了所有检测出的目标中检测正确的概率，精确率 (P) 的公式为：

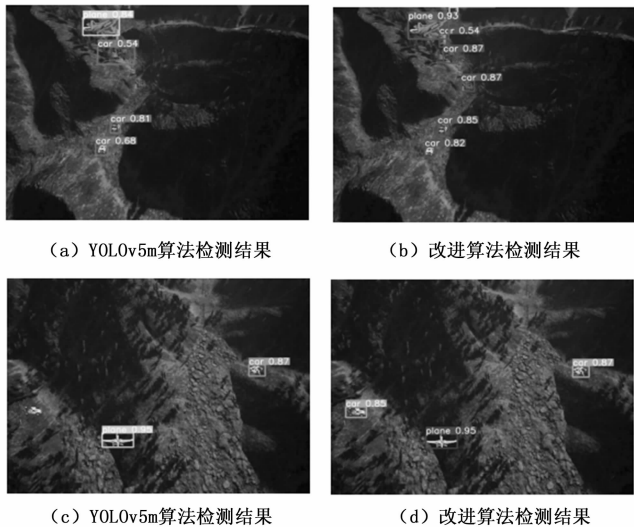


图 9 遮挡后的目标检测结果图

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

召回率 (recall) 为 R , 表示所有正样本中正确识别的概率, 召回率 (R) 的公式为:

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

一般用精确率 (P) 为纵坐标、召回率 (R) 为横坐标, 在坐标轴上绘制曲线图, 单类目标检测的平均精度 (AP , average precision) 即为该曲线图与坐标轴围成的面积, 全部类别目标 AP 的平均值即为均值平均精度 (mAP)。

3.5 实验结果分析

实验结果表明, 通过对比 3 种算法实验后得到该数据集中每个类别的平均精度 (AP) 如表 1 所示, 本文改进的算法得到的每个类别的平均精度 (AP) 均高于另外两种算法。

表 1 平均精度指标对比结果

类别	AP/%		
	SSD 算法	YOLOv5m 算法	本文算法
雷达	75.0	70.2	74.5
坦克	65.1	96.0	97.9
车	62.9	87.2	98.8
船	91.6	93.7	95.5
飞机	45.5	80.9	81.8

对比 3 种算法对该数据集的均值平均精度 (mAP), 证明实验改进算法的有效性, 在交并比阈值为 0.5 的情况下, 经改进算法检测, mAP 达到了 89.7%, 算法性能指标对比如表 2 所示。

表 2 算法性能结果对比

算法	Precision/%	mAP/%	Time/s
SSD	67.2	68.0	0.026
YOLOv5m	87.2	85.6	0.037
本文算法	90.5	89.7	0.045

从 3 种算法的结果性能对比可知, 本文研究的改进算法精确率均高于另外两种算法, 改进算法精确率比原 YOLOv5m 算法提升了 3.3%, 使用原始 SSD 算法在该数据集检测得到均值平均精度 (mAP) 值为 68.0%, 使用原始 YOLOv5m 算法检测 mAP 为 85.6%, 本文改进算法检测后 mAP 值为 89.7%, 与原始 YOLOv5m 算法相比, 均值平均精度 (mAP) 值提高了 4.1%, 其中在对车的检测平均精度 (AP) 上, 改进算法相对原始 YOLOv5m 算法提高了 11.6%, 这是因为对地观测情况下, 车的目标像素很小, 增加的小目标检测层对弱小目标有着很好的检测效果, 但是由于网络改进后网络结构变得复杂, 使得检测图片时间相对于原始 YOLOv5m 算法增加了 8 ms, 但是仍然可以达到实时的效果。

由实验结果可知, 使用本文改进算法可显著提升识别准确率, 对一些漏检和错检的目标依然可以检测出来, 并且对于空对地观测下被叶簇遮挡的弱小目标和目标之间的遮挡有着更准确的识别, 目标检测算法的 mAP 指标达到 89.7%, 实现对地观测下像素小于 10×10 弱小目标的识别任务, 使得该算法对多目标识别有着更好的鲁棒性。

4 结束语

针对空对地观测环境下弱小目标和遮挡目标识别效果差等问题, 本文研究了 YOLOv5m 算法, 并对其进行改进, 在原 YOLOv5m 网络中增加一个新的小目标检测层实现了 4 个检测结构对不同大小尺寸目标的识别, 提高对弱小目标的检测能力, 其次在后处理端部分, 使用 DIoU_Loss 代替 GIoU_Loss 作为边界框回归损失函数、DIOU_NMS 代替传统的 nms, 加快边界框回归的速率以及提高定位精度, 提高对于遮挡目标的识别率。在实验中利用建模的方式建立了对地观测下的弱小目标数据集, 通过实验结果性能表明, 本文研究改进算法得到目标检测的均值平均精度 mAP 达到 89.7%, 实现了网络对所占图像像素个数小于 10×10 弱小目标的高精度识别, 证明了本文所研究方法的有效性, 但是由于改进的算法使得网络结构更加复杂, 降低了检测速率, 在之后的研究中将考虑对网络模型进行剪枝处理, 轻量化网络结构, 提升检测目标的速率。

参考文献:

- [1] 董宏辉, 孙智源, 葛大伟, 等. 基于高斯混合模型的铁路入侵物体目标识别方法 [J]. 中国铁道科学, 2011, 32 (2): 131-135.
- [2] 钟小莉, 樊吉亮. 离焦模糊图像序列微弱运动目标自动检测仿真 [J]. 计算机仿真, 2019, 36 (7): 419-422.
- [3] 张素, 安博文, 潘胜达. 基于时空非局部相似性的海上红外弱小目标检测 [J]. 光子学报, 2018, 47 (11): 1110001.
- [4] GU Y, WANG C, LIU B, et al. A kernel-based nonparametric regression method for clutter removal in infrared small-target detection applications [J]. IEEE Geoscience and Remote Sensing Letters, 2010, 7 (3): 469-473.

(下转第 231 页)