

5-22-2023

Fixed-Wing UAV Detection Based on Simulated Data Transfer Learning

Yu Fu

1.Engineering Research Center of Learning-Based Intelligent System, Ministry of Education, Tianjin 300384, China;2.School of Computer Science and Engineering, Tianjin University of Technology, Tianjin 300384, China; fuyucv@stud.tjut.edu.cn

Yao Zhang

1.Engineering Research Center of Learning-Based Intelligent System, Ministry of Education, Tianjin 300384, China;2.School of Computer Science and Engineering, Tianjin University of Technology, Tianjin 300384, China; zytju221@tju.edu.cn

Meng Zhao

1.Engineering Research Center of Learning-Based Intelligent System, Ministry of Education, Tianjin 300384, China;2.School of Computer Science and Engineering, Tianjin University of Technology, Tianjin 300384, China;

Mianzhao Wang

1.Engineering Research Center of Learning-Based Intelligent System, Ministry of Education, Tianjin 300384, China;2.School of Computer Science and Engineering, Tianjin University of Technology, Tianjin 300384, China;

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Fixed-Wing UAV Detection Based on Simulated Data Transfer Learning

Abstract

Abstract: Data play an important role in visual inspection tasks, but it is difficult to obtain a sufficient amount of real fixed-wing UAV data. Therefore, *a data set containing a large number of simulated fixed-wing UAV data and a small number of real fixed-wing UAV data is constructed, and the real fixed-wing UAV data are detected by training simulated fixed-wing UAV data based on the idea of weight transfer. On this basis, a two-stage learning strategy is proposed to further reduce the missed detection rate of UAVs by using multi-scale feature fusion.* The simulation results show that simulated data can be used to detect real fixed-wing UAVs, which has potential application prospects in future target detection research.

Keywords

visual inspection, fixed-wing UAV, weight transfer, multi-scale feature

Authors

Yu Fu, Yao Zhang, Meng Zhao, Mianzhao Wang, Jiangpeng Zheng, Chen Jia, and Shengyong Chen

Recommended Citation

Yu Fu, Yao Zhang, Meng Zhao, Mianzhao Wang, Jiangpeng Zheng, Chen Jia, Shengyong Chen. Fixed-Wing UAV Detection Based on Simulated Data Transfer Learning[J]. *Journal of System Simulation*, 2023, 35(5): 998-1007.

基于仿真数据迁移学习的固定翼无人机检测

付玉^{1,2}, 张垚^{1,2*}, 赵萌^{1,2}, 王绵沼^{1,2}, 郑江鹏^{1,2}, 贾晨^{1,2}, 陈胜勇^{1,2}

(1. 学习型智能系统教育部工程研究中心, 天津 300384; 2. 天津理工大学 计算机科学与工程学院, 天津 300384)

摘要: 数据在视觉检测任务中发挥重要作用, 针对足够数量的真实固定翼无人机数据难以获取的问题, 构建了一个包含大量仿真和少量真实的固定翼无人机数据集, 采用权重迁移的思想, 通过对仿真固定翼无人机数据的训练达到对真实固定翼无人机数据的检测。在此基础上又提出一个两阶段学习策略, 利用多尺度特征融合进一步降低无人机的漏检率。仿真实验结果表明, 利用仿真数据检测真实固定翼无人机在未来目标检测研究中有潜在应用前景。

关键词: 视觉检测; 固定翼无人机; 权重迁移; 多尺度特征

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2023)05-0998-10

DOI: 10.16182/j.issn1004731x.joss.22-0024

引用格式: 付玉, 张垚, 赵萌, 等. 基于仿真数据迁移学习的固定翼无人机检测[J]. 系统仿真学报, 2023, 35(5): 998-1007.

Reference format: Fu Yu, Zhang Yao, Zhao Meng, et al. Fixed-Wing UAV Detection Based on Simulated Data Transfer Learning[J]. Journal of System Simulation, 2023, 35(5): 998-1007.

Fixed-Wing UAV Detection Based on Simulated Data Transfer Learning

Fu Yu^{1,2}, Zhang Yao^{1,2*}, Zhao Meng^{1,2}, Wang Mianzhao^{1,2}, Zheng Jiangpeng^{1,2},
Jia Chen^{1,2}, Chen Shengyong^{1,2}

(1. Engineering Research Center of Learning-Based Intelligent System, Ministry of Education, Tianjin 300384, China;

2. School of Computer Science and Engineering, Tianjin University of Technology, Tianjin 300384, China)

Abstract: Data play an important role in visual inspection tasks, but it is difficult to obtain a sufficient amount of real fixed-wing UAV data. Therefore, a data set containing a large number of simulated fixed-wing UAV data and a small number of real fixed-wing UAV data is constructed, and the real fixed-wing UAV data are detected by training simulated fixed-wing UAV data based on the idea of weight transfer. On this basis, a two-stage learning strategy is proposed to further reduce the missed detection rate of UAVs by using multi-scale feature fusion. The simulation results show that simulated data can be used to detect real fixed-wing UAVs, which has potential application prospects in future target detection research.

Keywords: visual inspection; fixed-wing UAV; weight transfer; multi-scale feature

0 引言

目标检测主要面向自然场景图像, 包含边缘检测^[1]、姿态检测^[2]、场景文本检测^[3]、人脸检测^[4]、行人检测^[5]等任务。同时, 在安全^[6]、军事^[7]、交通^[8]、医疗^[9]和生活^[10]等领域有广泛的应

用价值。迁移学习的应用场景有医疗^[11]、海洋^[12]、生活^[13]等领域。

文献 [14] 提出的多尺度形变部件模型 (deformable part model, DPM) 应用十分广泛, 但这种算法不具有普适性, 工作量大。当卷积神经

收稿日期: 2022-01-11

修回日期: 2022-02-22

基金项目: 国家自然科学基金(61906133, 62020106004, 61903275, 61902078)

第一作者: 付玉(1998-), 女, 硕士, 研究方向为计算机视觉。E-mail: fuyucv@stud.tjut.edu.cn

通讯作者: 张垚(1987-), 男, 讲师, 博士, 研究方向为非线性控制理论、计算机视觉。E-mail: zytju221@tju.edu.cn

网络一系列模型如 ResNet^[15]、GoogleNet^[16] 以及 AlexNet^[17] 等被提出后, 图片中的特征能够很好地提取出来, 检测精度得到极大的提高。文献[18]提出一种基于深度学习的两阶段目标检测算法 Faster R-CNN (faster region-based convolutional network), 该算法使用区域建议进行检测, 通过简单的交替优化, 可以训练 RPN(region proposal network) 和 Fast R-CNN(region-based convolutional network)^[19] 共享卷积特征。文献[20]提出 YOLOv4 (you only look once) 算法, 首先在头部使用 Mosaic 数据增强等方法, 然后使用 BottleneckCSP^[21] 等模块并使用 FPN(feature pyramid network)^[22] + PAN (pyramid attention network)^[23], 最后使用 GIOU_Loss (generalized intersection over union loss)^[24] 损失函数提升模型精度。对于无人机目标检测的应用主要是无人机航拍用于实时目标检测^[25]。DeepBlueAI 团队在 ICCV 挑战赛中提出了一种思想, 将 Faster R-CNN、DCN(deep & cross network)^[26]、FPN 作为基本模块, 该思想将原有的 head 改为 Double head, 采用级联检测将多个阈值越来越高的检测器串联。文献[27]提出了 SlimYOLOv3 算法, 其主要思想是 YOLOv3^[28] 剪枝得到的模型在数据集上微调, 剪枝过程不断地重复训练, 一直到模型剪枝率达到一定的条件。文献[29]提出了 FFRCNN 算法, 采用多尺度融合的方式, 将 FPN 与 Faster R-CNN 模型相结合, 该算法提升了对小目标的关注度, 增强了模型的鲁棒性。

近几年, 结合深度学习检测无人机图像有很大优势且有十分重要的意义, 但由于面临很多挑战, 无人机的检测方法很少用于在军事勘察工作中检测真实固定翼无人机图像。它的主要问题是固定翼无人机目前没有大规模普及, 真实数据很难获取, 获取足够数据需要大量经济资源和人力资源。另一方面, 固定翼无人机需要专业人员操作, 提高了数据获取的风险, 增加了实验数据采集的复杂性。

针对以上问题, 本文构建了一个固定翼无人

机数据集, 将检测固定翼无人机图像与深度学习算法结合, 提出了一个基于仿真数据迁移学习的固定翼无人机检测方法。该方法提出了一个两阶段学习策略, 第一阶段网络模型通过基础网络模型检测所有样本, 为基础检测网络; 第二阶段网络模型改进网络, 重新检测第一阶段网络模型的漏检样本, 为漏检检测网络。第一阶段网络模型利用端到端的单阶段网络对高层信息进行提取。为了实现不同尺度的无人机检测, 提出第二阶段网络模型, 第二阶段利用多层特征金字塔提取特征获取更多低层信息, 进一步提高无人机在复杂变化场景下的检测精度。此外, 本文构建的数据集包括大量仿真固定翼无人机数据和少量真实固定翼无人机数据, 通过对大量仿真固定翼无人机数据的训练迁移权重, 实现对真实固定翼无人机数据的检测, 仿真固定翼无人机样本作为源域, 真实固定翼无人机样本作为目标域。实验结果表明, 该方法初步解决在真实固定翼无人机数据资源匮乏条件下的目标检测, 进一步推动无人机在信息交互领域的发展, 在军事勘察工作中具有广阔的应用前景。

1 固定翼无人机检测方法

1.1 数据集

固定翼无人机一般用于军事场景, 由于军事保护绝大多数固定翼无人机图像不对外公布, 因此, 其图像获取的最大难度是资源有限性。除此之外, 无论在时间成本还是人工成本上, 也需付出巨大代价。本文构建了一个包含大量仿真和少量真实固定翼无人机的数据集, 旨在模拟固定翼无人机飞行过程中的各种行为和尺度, 能够充分覆盖固定翼无人机的动作和外观语义信息。

本文创建了一个新的固定翼无人机数据集, 数据集主要包括两部分: 大量仿真固定翼无人机图像和少量真实固定翼无人机图像。其中, 大量仿真固定翼无人机样本有两种模型: 3D 数字模型

和2D图片模型。3D数字模型从各种不同的像素、角度构建无人机数据集模型，但获取每一个无人机模型都需要手工构建，耗费了大量资源。考虑到构建数据集的复杂性，2D图片模型则使其更容易获取无人机模型，弥补了3D数字模型的缺陷，同时进一步利于无人机图像的检测。第一部分是大量仿真固定翼无人机样本作为源域，共有2100张仿真固定翼无人机图像，主要思路是把固定翼无人机模型融合到真实背景图像中，如图1所示。



图1 仿真固定翼无人机数据
Fig. 1 Simulated fixed-wing UAV data

这些背景图像覆盖了不同分辨率的各种真实环境，包含城市、森林、草原、戈壁、平原、天空等。前600张图像的无人机模型是3D数字模型，通过对3D无人机模型在不同平面下的二维映射来构建多尺度多角度目标模型，无人机3D模型到2D平面的映射包含像素尺度、垂直观察角度、水平观察角度、自身动作4种设置：①在像素尺度设置上，有40, 50, ..., 100像素共7种类型；②在垂直观察角度设置上，有俯视25°、30°、35°共3种类型；③在水平观察角度设置上，以15°为间隔分为7组，最小为左视角45°，最大为右视角45°，共有7种类型；④在自身动作设置上，一个完整动作是连续左旋转15°~5°，再直接旋转到0°，从0°直接旋转到5°，再连续右旋转5°~15°，即：

-15°, -14°, ..., -5°, 0°, 5°, 6°, ..., 15°共23种类型。以上4种设置分别组合，共有3381种无人机模型。随机选取600个模型分别融合到600张不同的背景图像中，作为前600张仿真无人机图像。后1500张图像的无人机模型是2d图片模型，2d平面模型包含像素尺度、无人机模型两种设置：①在像素尺度设置上，共有从40, 50, ..., 100像素7种类型；②在无人机模型设置上，共有20种无人机模型。以上2种设置分别组合，共有140种无人机模型。重复融合到1500张不同的背景图像中，作为后1500张仿真无人机图像。

第二部分是少量真实固定翼无人机样本作为目标域，随机选取110张不同环境、不同角度、不同尺度的真实固定翼无人机图像，如图2所示。

对于仿真前景目标和真实背景图像的融合，通过随机位置选取的方法将无人机模型添加在背景图像上。首先，从多角度多尺度的无人机模型中随机选取一个模型，并在2100张背景图像中随机选取一张图像。其次，随机选取背景图像上的一个点作为无人机模型的左上角坐标，将模型坐标转化为图像坐标，判断无人机的模型坐标是否重叠或超出背景图像边界。最后，将没有重叠和超出边界的区域转换成无人机模型像素。此外，由于给定无人机背景图像坐标，标注信息无需人工手动标注。



(a) 真实固定翼无人机数据1



(b) 真实固定翼无人机数据2



(c) 真实固定翼无人机数据3



(d) 真实固定翼无人机数据4

图2 真实固定翼无人机数据
Fig. 2 Real fixed-wing UAV data

固定翼无人机相较于其他飞行物有一定区别。例如, 固定翼无人机和飞鸟。在特征上, 固定翼无人机是刚体, 飞鸟是非刚体。在数据集上, 固定翼无人机数据难获取, 飞鸟数据容易获取。再

例如, 固定翼无人机和多旋翼无人机。在特征上, 固定翼无人机的特征相对清晰, 多旋翼无人机机型的特征较复杂。在数据集上, 多旋翼无人机通过深度学习提取特征的方法有很多, 固定翼无人机通过深度学习提取特征的方法较少。

1.2 整体网络模型

本文提出一种基于仿真数据迁移学习的方法, 极大的提高了效率。这种方法对大量仿真固定翼无人机数据进行训练, 通过迁移学习迁移训练好的权重模型, 仿真固定翼无人机样本作为源域, 真实固定翼无人机样本作为目标域, 实现对真实固定翼无人机数据的测试。

本文还提出一个两阶段学习策略, 既能利用单阶段检测提取目标中大感受野的特征, 又能利用多尺度融合尽量保留特征中的位置和细节信息。该方法的网络架构如图3所示。第一阶段是基础检测模型, 第二阶段是漏检检测模型。基础检测模型主要利用单阶段端到端的检测算法提取高层特征, 主要思路是通过训练仿真固定翼无人机图像迁移权重达到对真实固定翼无人机图像的检测, 仿真固定翼无人机样本作为源域, 真实固定翼无人机样本作为目标域。具体的, 把仿真无人机图像输入到单阶段网络模型, 利用训练得到的权重文件进行权重迁移, 检测大尺度目标。通过实验发现, 基础检测模型漏检率较高。高层特征具有很强的语义信息, 但分辨率较低且对细节的感知能力较差, 导致模型出现假阴性样本。漏检检测模型利用多层特征金字塔网络提取低层特征, 低层特征分辨率更高, 同时包含更多位置和细节信息, 可以改进基础检测模型的缺陷, 进一步检测小尺度目标。漏检检测模型同样采用权重迁移, 仿真固定翼无人机样本作为源域, 真实固定翼无人机样本作为目标域, 训练数据与基础检测模型相同, 测试样本为基础检测模型的假阴性样本。

模型的一些细节模块如图4所示。

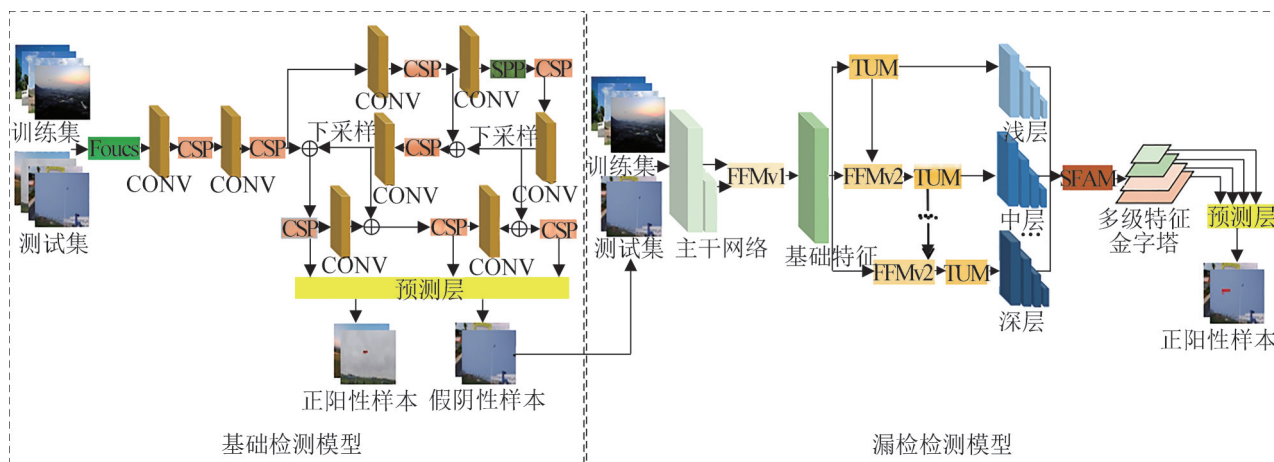


图3 两阶段网络模型结构
Fig. 3 Two-stage network model structure

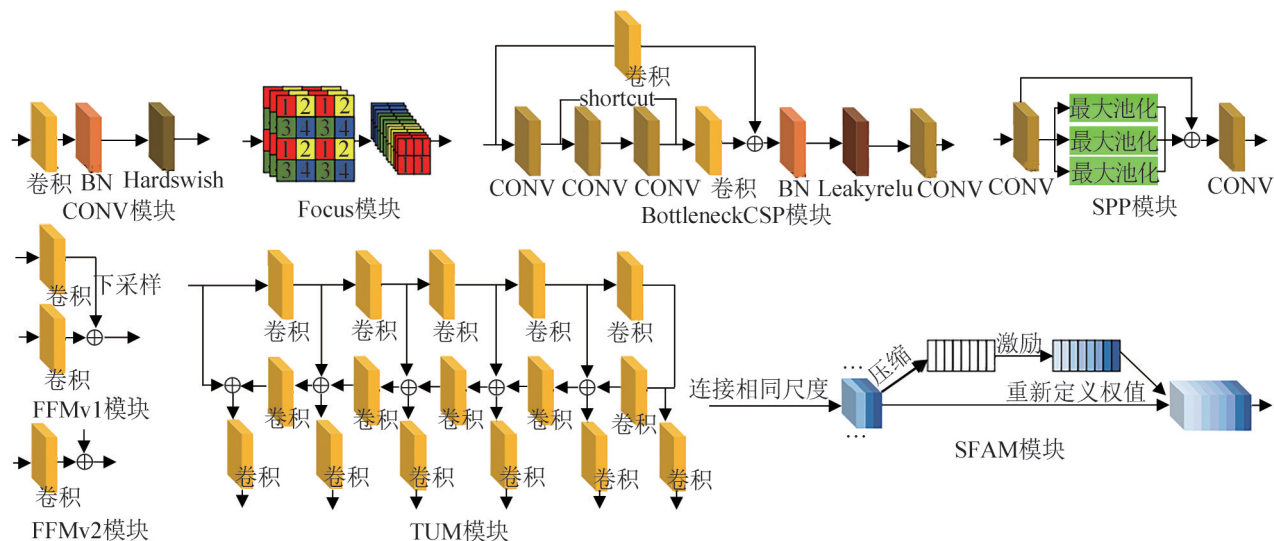


图4 两阶段网络模型结构的模块细节
Fig. 4 Module details of two-stage network model structure

对于基础检测模型，CONV 模块依次进行 1×1 卷积、批量归一化 (batch normalization, BN)、HardSwish 激活函数操作；Focus 模块先进行切片操作，即对每个图像间隔像素获取特征值，将特征值进行拼接，拼接后图像相较于原图像扩充 4 倍通道，然后进行一次 1×1 卷积操作得到特征图像，保证图像像素不丢失；BottleneckCSP 模块是 Bottleneck 模块的堆叠加卷积操作，即先对特征图降维降低通道数，然后进行卷积操作，最后对特征图升维恢复通道数；SPP 模块以 3×3 ， 5×5 ， 7×7 最大池化

的方式进行尺度融合，即分别提取每个最大池化操作中的特征图进而连接，用于参数固定。对于漏检检测模型，FFMv1 模块融合通过主干网络 VGG-16 和 ResNet-101 提取到的浅层特征和深层特征得到基础特征；FFMv2 模块融合基础特征和上一个 TUM(thinned U-shape module) 模块的输出得到 TUM 模块的输入；TUM 模块先进行上采样和相加操作，然后进行 1×1 卷积操作，默认设置中共有 8 个 TUM 模块；SFAM(scale-wise feature aggregation module) 模块先按通道维度拼接尺度相同的特征使每

个尺度相同的特征包含多级信息, 然后加入通道级注意力, 即引入 SENet 结构, 通过压缩操作和激励操作分离之前的连接操作, 最后重新定义权值。

基础检测模型采用 yolov5 网络模型, 漏检测模型采用 M2Det^[30] 网络模型, 下面分别对基础检测模型和漏检测模型进行简单介绍。

1.3 基础检测模型

基础检测模型是端到端的单阶段检测算法。网络先对输入图像进行预处理操作, 对大量仿真无人机图像采用随机裁剪、随机缩放、随机排布等方式进行 Mosaic 数据增强。每个样本会有一个初始锚框, 在初始锚框的基础上得到预测框, 网络模型会自适应计算训练数据中的最佳锚框。此外, 数据自适应添加最少黑边来提升模型的检测速度。图像经过预处理后进入模型的主干网络, 主干网络包括 Focus、CONV、BottleneckCSP、SPP^[31] 等模块。为了进一步提升模型特征多样性同时强化特征融合能力, 主干网络还引入 FPN+PAN 模块。FPN 模块首先通过自下而上结构前向传播神经网络, 然后通过自上而下结构将强语义的高层特征进行最近邻二倍上采样操作, 此外横向连接结构通过 1*1 卷积连接自上而下结构生成的上采样特征图和自下而上结构生成的与上采样特征图尺度相同的特征图。PAN 模块首先通过主干网络 ResNet18 提取步长分别为 4、8、16、32 的卷积作为高层特征和底层特征, 然后通过一个较轻量的 FPN 模型增强特征, 最后将相同尺度特征图中的对应元素相加, 加入上采样操作后进行连接。由于测试时没有真实边界框, 但损失函数会产生与真实框相关的信息, 所以采用加权非极大抑制算法进行非极大抑制操作。加权非极大值抑制操作是指在筛选预测框时, 根据模型给出的置信度评分进行加权操作后生成最终预测框, 同时去除低于置信度评分的预测框。损失函数

GIoU_Loss 定义为

$$GIoU = IoU - \frac{|C \setminus (A \cup B)|}{|C|} \quad (1)$$

式中: $A, B, C \subseteq S \in \mathbb{R}^n$ 。A 为真实框; B 为预测框; C 为 A、B 两个区域平行于坐标轴的最小矩形。其中, IoU 定义为

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (2)$$

1.4 漏检测模型

漏检测模型是多尺度融合检测算法。网络先通过主干网络对大量仿真无人机图像提取特征生成浅层和深层特征, 主干网络采用 VGG-16^[32]、ResNet-101^[33] 等网络模型。模型还包括 FFM、TUM、SFAM 等几个模块, FFM 模块包括 FFMv1 和 FFMv2 两个子模块。浅层特征和深层特征送入 FFMv1 子模块, 得到基础特征。根据 FFMv1 子模块的输入为不同尺度的特征图, 浅层特征和深层特征进行连接之前会加入上采样操作。FFMv2 子模块融合 FFMv1 子模块的输出和上一个 TUM 模块的输出后进入下一个 TUM 模块。TUM 模块通过跨步卷积操作提取不同尺度特征, 此外加入 1*1 卷积进行上采样, 最后输出 6 个不同尺度的特征图。SFAM 模块将底层 TUM 模块解码器和高层 TUM 模块解码器生成的多级多尺度特征聚合成一个多级特征金字塔。SFAM 模块分为两部分, 第一部分连接相同尺度特征, 第二部分引入 SENet 结构, 即首先通过对特征图的压缩生成通道级特征, 然后加入激励操作, 生成不同通道的权重大小, 最后与原特征做相乘操作重新定义权值。最后进入预测层进行后处理操作, 通过非极大抑制 soft-NMS^[34] 来抑制得分低于阈值的预测框。最终输出特征为

$$\tilde{X}_i^c = F_{\text{scale}}(X_i^c, s_c) = s_c \cdot X_i^c \quad (3)$$

式中: $\tilde{X}_i = [\tilde{X}_i^1, \tilde{X}_i^2, \dots, \tilde{X}_i^C]$; s 定义为

$$s = F_{\text{ex}}(z, W) = \sigma(W_2 \delta(W_1 z)) \quad (4)$$

式中: $z \in \mathbb{R}^C$ 为通道级的统计数据; σ 为 ReLU 函

数； δ 为sigmoid函数； $W_1 \in \mathbb{R}^{C \times \frac{C}{r}}$ ； $W_2 \in \mathbb{R}^{C \times \frac{C}{r}}$ (r 为缩小比例)。

2 两阶段网络模型实验与结果分析

2.1 实验配置

本文所提算法基于PyTorch和Tensorflow深度学习框架实现，在GPU单张显卡上进行实验。软件版本为PyTorch 1.9.1，Tensorflow-gpu 1.15.0，CUDA 11.2，Python 3.7和Numpy 1.21.4；硬件平台配置两张NVIDIA TITAN V显卡，每张显卡内存为12 066 MiB，显卡驱动版本为460.84。此外，无论是本文方法还是消融实验、对比实验，所用实验环境均一致。

2.2 实验数据

文本数据集共有2 210张固定翼无人机图像，其中2 100张仿真图像用于训练，30张真实图像用于验证，80张真实图像用于第一阶段网络模型的测试，第一阶段的假阴性样本作为第二阶段网络模型的测试集。仿真固定翼无人机图像分辨率为780×380，真实固定翼无人机图像分辨率为1 980×1 020。

2.3 训练设置

训练时第一阶段网络模型的图像分辨率为640×640，迭代次数设置为100，每个训练批次大小为16张图像，初始学习率为0.000 05，训练时使用单张显卡，即每次输入16张图像。第二阶段网络模型的图像分辨率为320×320，迭代次数设置为100。前50次迭代冻结网络模型的主干，所有参数将会被冻结，特征提取网络不发生改变，冻结阶段每个训练批次大小为16张图像，初始学习率为0.005；后50次迭代解冻网络模型的主干，所有参数发生改变，特征提取网络也会发生改变，解冻阶段每个训练批次大小为8张图像，初始学

习率为0.001。测试时第一阶段iou为0.5，置信度阈值为0.25。第二阶段iou和置信度阈值都为0.11。

2.4 评估标准

本文采用准确率(Precision)、召回率(Recall)、mAP(mean average precision)、漏检率(miss rate, MR)和每秒传输帧数(frames per second, FPS)作为评价指标，其中最主要且常用的实验指标是MR。Precision是指正阳性样本的个数除以被预测为正样本的所有样本个数；Recall是指正阳性样本的个数除以所有样本个数；MR是指假阴性样本的个数除以所有样本个数。Precision、Recall、mAP和FPS越大代表检测效果越好，MR越小代表检测效果越好。

2.5 实验设计

网络模型的对比实验结果如表1所示。本文方法和YOLOF^[35]、YOLO Nano^[36]、PP-YOLO^[37]、DETR^[38]、YOLOX^[39]这5种算法进行比较，检测结果：Precision为94.05%，Recall为98.75%，mAP为91.67%，MR为1.25%，FPS为25.72。具体的，在80张真实无人机图像中，检测到79张无人机图像，只有1张无人机图像漏检。在Recall、mAP和MR这3个指标上，本文实验结果均优于其他算法，在Precision上，略低于YOLOF、PP-YOLO、DETR算法。Precision不是最优的原因可能是无人机存在误检情况，和YOLOF算法相比相差5.95%，但相较于误检情况，YOLOF、PP-YOLO、DETR算法MR过高。在FPS上，低于YOLO Nano、PP-YOLO算法，但基本满足实时性。同时相较于处理速度，YOLO Nano、PP-YOLO算法MR过高。对比最新算法YOLOX，本文算法在Precision、Recall、mAP、MR和FPS上分别提升1.74%、8.75%、5.77%、8.75%和2.74，证明了网络模型的优越性。

表1 对比实验结果

方法	Precision/%	Recall/%	mAP/%	MR/%	FPS
YOLOF ^[35]	100	53.75	77.50	46.25	20.30
YOLO Nano ^[36]	40.18	56.25	9.12	43.75	30.08
PP-YOLO ^[37]	95.77	85.00	78.20	15.00	72.90
DETR ^[38]	98.41	77.5	45.60	22.50	0.52
YOLOX ^[39]	92.31	90.00	85.90	10.00	22.98
本文方法	94.05	98.75	91.67	1.25	25.72

本文将实验模型分别和第一阶段网络模型, 第二阶段网络模型进行比较, 消融实验结果如表2所示。可以看出, 本文实验结果在 Precision、Recall、mAP 和 MR 这4个指标上均优于第一阶段、第二阶段模型方法, 证明了网络模型的可行性。在FPS上, 低于第一阶段网络模型的处理速度, 但基本满足实时性。在消融实验中, 第一阶段网络模型的MR为15%: 在80张真实无人机图像中, 检测到68张无人机图像, 实验结果示例见图5, 漏检12张无人机图像, 实验结果示例如图6所示; 在第二阶段, 又重新检测到11张无人机图像, 实验结果示例见图7。

表2 消融实验结果
Table 2 Ablation results

方法	Precision/%	Recall/%	mAP/%	MR/%	FPS
YOLOv5	90.67	85.00	72.30	15.00	80.65
M2Det ^[30]	74.47	87.50	70.20	12.50	4.65
本文方法	94.05	98.75	91.67	1.25	25.72

图5 第一阶段检测到的样本
Fig. 5 Detected samples in first stage图6 第一阶段漏检样本
Fig. 6 Undetected samples in first stage图7 第二阶段重新检测到的样本
Fig. 7 Redetected samples in second stage

3 结论

本文提出一种基于仿真数据迁移学习的固定翼无人机检测方法。该方法构建了一个包括大量仿真和少量真实固定翼无人机的数据集, 通过仿真训练数据的权重迁移实现检测真实固定翼无人机数据, 仿真固定翼无人机样本作为源域, 真实固定翼无人机样本作为目标域。除此之外, 还提出一个两阶段学习策略, 第一阶段基础检测模型利用单阶段检测算法提取图像高层特征, 第二阶段漏检检测模型通过多层特征金字塔网络进一步提高模型对不同尺度目标的检测能力。未来将构想一个更合理的多尺度融合方式, 进一步学习无人机的轮廓特征, 降低误检率, 更好地检测固定

翼无人机图像。

参考文献:

- [1] 刘丹, 王运宏. 限制型自适应SUSAN边缘检测算法[J]. 计算机辅助设计与图形学学报, 2020, 32(6): 971-978.
Liu Dan, Wang Yunhong. Constraint Self-Adaptive SUSAN Algorithm for Edge Detection[J]. Journal of Computer-Aided Design and Computer Graphics, 2020, 32(6): 971-978.
- [2] 何炜婷, 曾碧, 陈文轩. 基于轻量级人体姿态估计和图卷积的摔倒实时检测方法[J]. 计算机科学与应用, 2021, 11(4): 783-794.
He Weiting, Zeng Bi, Chen Wenxuan. Real-Time Fall Detection Based on Light-Weight Human Pose Estimation and Graph Convolution Network[J]. Computer Science and Applications, 2021, 11(4): 783-794.
- [3] 陈淼妙, 续晋华. 基于高分辨率卷积神经网络的场景文本检测模型[J]. 计算机应用与软件, 2020, 37(10): 138-144.
Chen Miaomiao, Xu Jinhua. Scene Text Detection Model Based on High Resolution Convolutional Neural Networks[J]. Computer Applications and Software, 2020, 37(10): 138-144.
- [4] 邓珍荣, 白善今, 马富欣, 等. 改进YOLO的密集小尺度人脸检测方法[J]. 计算机工程与设计, 2020, 41(3): 874-879.
Deng Zhenrong, Bai Shanjin, Ma Fuxin, et al. Improved YOLO Dense Small-Scale Face Detection Method [J]. Computer Engineering and Design, 2020, 41(3): 874-879.
- [5] 陈勇, 谢文阳, 刘焕淋, 等. 结合头部和整体信息的多特征融合行人检测[J]. 电子与信息学报, 2022, 44(4): 1453-1460.
Chen Yong, Xie Wenyang, Liu Huanlin, et al. Multi-feature Fusion Pedestrian Detection Combining Head and Overall Information[J]. Journal of Electronics and Information Technology, 2021, 44(4): 1453-1460.
- [6] 骆子铭, 许书彬, 王杰勋. 一种基于机器学习的TLS恶意流量检测方案[J]. 网络空间安全, 2019, 10(7): 89-94.
Luo Ziming, Xu Shubin, Wang Jiexun. A Scheme for Identifying Malware Traffic with TLS Data Based on Machine Learning[J]. Cyberspace Security, 2019, 10(7): 89-94.
- [7] 宋羿铭, 解文彬, 周末. 基于机器学习的军事目标检测系统开发研究[J]. 现代计算机, 2020(22): 54-58.
Song Yiming, Xie Wenbin, Zhou Wei. Development and Research of Military Target Detection System Based on Machine Learning[J]. Modern Computer, 2020(22): 54-58.
- [8] 张富凯, 杨峰, 李策. 基于改进YOLOv3的快速车辆检测方法[J]. 计算机工程与应用, 2019, 55(2): 12-20.
Zhang Fukai, Yang Feng, Li Ce. Fast Vehicle Detection Method Based on Improved YOLOv3[J]. Computer Engineering and Applications, 2019, 55(2): 12-20.
- [9] 席孝倩, 刘威. 基于目标检测算法的肺结节辅助诊断系统[J]. 计算机与现代化, 2020(11): 1-7.
Xi Xiaoqian, Liu Wei. Pulmonary Nodule Aided Diagnosis System Based on Target Detection Algorithm [J]. Computer and Modernization, 2020(11): 1-7.
- [10] Cheng X, Shi F, Liu X, et al. A Novel Deep Class-Imbalanced Semisupervised Model for Wind Turbine Blade Icing Detection[J]. IEEE Transactions on Neural Networks and Learning Systems (S2162-237X), 2022, 33(6): 2258-2570.
- [11] Ahuja S, Panigrahi B K, Dey N, et al. Deep Transfer Learning-Based Automated Detection of COVID-19 from Lung CT Scan Slices[J]. Applied Intelligence (S0924-669X), 2021, 51(1): 571-585.
- [12] Cheng X, Li G, Han P, et al. Data-Driven Modeling for Transferable Sea State Estimation Between Marine Systems[J]. IEEE Transactions on Intelligent Transportation Systems (S1524-9050), 2022, 23(3): 2561-2571.
- [13] Behera S K, Rath A K, Sethy P K. Maturity Status Classification of Papaya Fruits Based on Machine Learning and Transfer Learning Approach[J]. Information Processing in Agriculture (S2214-3173), 2021, 8(2): 244-250.
- [14] Felzenszwalb P F, Girshick R B, McAllester D, et al. Object Detection with Discriminatively Trained Part-Based Models[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S0162-8828), 2009, 32(9): 1627-1645.
- [15] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[C]// IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [16] Szegedy C, Liu W, Jia Y, et al. Going Deeper with Convolutions[C]// IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA: IEEE, 2015: 1-9.
- [17] Krizhevsky A, Sutskever I, Hinton G E. Imagenet Classification with Deep Convolutional Neural Networks [J]. Advances in Neural Information Processing Systems (S1049-5258), 2012, 25: 1097-1105.
- [18] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[J]. Advances in Neural Information Processing

- Systems (S1049-5258), 2015, 28: 91-99.
- [19] Girshick R. Fast R-CNN[C]// IEEE International Conference on Computer Vision. Santiago, Chile: IEEE, 2015: 1440-1448.
- [20] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: Optimal Speed and Accuracy of Object Detection[J]. arXiv preprint, arXiv: 2004.10934, 2020.
- [21] Wang C Y, Liao H Y M, Wu Y H, et al. CSPNet: A New Backbone that can Enhance Learning Capability of CNN [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle, WA, USA: IEEE, 2020: 390-391.
- [22] Lin T Y, Dollár P, Girshick R, et al. Feature Pyramid Networks for Object Detection[C]// IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017: 2117-2125.
- [23] Liu S, Qi L, Qin H, et al. Path Aggregation Network for Instance Segmentation[C]// IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, Utah, USA: IEEE, 2018: 8759-8768.
- [24] Rezafighi H, Tsoi N, Gwak J Y, et al. Generalized Intersection Over Union: A Metric and a Loss for Bounding Box Regression[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. Savanese, Silvio. Long Beach, CA, USA: IEEE, 2019: 658-666.
- [25] 宋闯, 赵佳佳, 王康, 等. 面向智能感知的小样本学习研究综述[J]. 航空学报, 2020, 41(增1): 15-28.
Song Chuang, Zhao Jiajia, Wang Kang, et al. A Survey of Few Shot Learning Based on Intelligent Perception[J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(S1): 15-28.
- [26] Dai J, Qi H, Xiong Y, et al. Deformable Convolutional Networks[C]// IEEE International Conference on Computer Vision. Washington, USA: IEEE, 2017: 764-773.
- [27] Zhang P, Zhong Y, Li X. SlimYOLOv3: Narrower, Faster and Better for Real-Time UAV Applications[C]// IEEE/CVF International Conference on Computer Vision Workshops. Seoul, Korea: IEEE, 2019: 37-45.
- [28] Redmon J, Farhadi A. YOLOv3: An Incremental Improvement[J]. arXiv preprint, arXiv: 1804.02767, 2018.
- [29] 饶威. 基于深度学习的无人机地面小目标算法研究[D]. 沈阳: 沈阳理工大学, 2020.
Rao Wei. Research on UAV Ground Small Target Algorithm Based on Deep Learning[D]. Shenyang: Shenyang Ligong University, 2020.
- [30] Zhao Q, Sheng T, Wang Y, et al. M2Det: A Single-Shot Object Detector Based on Multi-Level Feature Pyramid Network[J]. Proceedings of the AAAI Conference on Artificial Intelligence (S2159-5399), 2019, 33: 9259-9266.
- [31] He K, Zhang X, Ren S, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S0162-8828), 2015, 37(9): 1904-1916.
- [32] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. arXiv preprint, arXiv: 1409.1556, 2014.
- [33] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[C]// IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [34] Bodla N, Singh B, Chellappa R, et al. Soft-NMS-- Improving Object Detection with One Line of Code[C]// IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017: 5561-5569.
- [35] Chen Q, Wang Y, Yang T, et al. You Only Look One-level Feature[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE, 2021: 13039-13048.
- [36] Wong A, Famouri M, Shafiee M J, et al. YOLO Nano: A Highly Compact You Only Look Once Convolutional Neural Network for Object Detection[J]. arXiv preprint, arXiv: 1910.01271, 2019.
- [37] Long X, Deng K, Wang G, et al. PP-YOLO: An Effective and Efficient Implementation of Object Detector[J]. arXiv preprint, arXiv: 2007.12099, 2020.
- [38] Carion N, Massa F, Synnaeve G, et al. End-to-End Object Detection with Transformers[C]// 16th European Conference on Computer Vision. Glasgow, UK: Springer, Cham, 2020: 213-229.
- [39] Ge Z, Liu S, Wang F, et al. YOLOX: Exceeding YOLO Series in 2021[J]. arXiv preprint, arXiv: 2107.08430, 2021.