

# 基于嵌入式的遥感目标实时检测方法

农元君, 王俊杰\*

中国海洋大学工程学院, 山东 青岛 266100

**摘要** 当前基于深度学习的遥感图像目标检测方法因模型复杂、计算量大,难以部署在计算资源受限的卫星上进行实时在轨检测。针对该问题,提出一种基于嵌入式的轻量化遥感目标实时检测方法。该方法以 YOLOv3-tiny 为基础网络,首先通过精简网络与改进多尺度预测对网络结构进行优化,其次引入空间注意力模块以增强遥感目标的特征。实验结果表明,在  $608 \times 608$  的输入尺寸下,所提方法的平均准确率均值、召回率、F1 值分别达到了 76.70%、75%、78%,较 YOLOv3-tiny 提升了 3.61%、8%、6%,同时计算量和模型体积较 YOLOv3-tiny 减少了 39.67% 和 71.26%,且在嵌入式平台 NVIDIA Jetson Xavier NX 上可达到 32.5 frame/s 的实时检测速度,可满足在嵌入端实时检测遥感目标的需求。

**关键词** 遥感; 目标检测; 实时检测; 嵌入式平台; 空间注意力

中图分类号 TP751

文献标志码 A

doi: 10.3788/AOS202141.1028001

## Real-Time Object Detection in Remote Sensing Images Based on Embedded System

Nong Yuanjun, Wang Junjie\*

School of Engineering, Ocean University of China, Qingdao, Shandong 266100, China

**Abstract** The current remote sensing images object detection methods based on deep learning are difficult to achieve real-time detection on satellite with limited computing resources due to its complexity and large amount of calculation. To solve this problem, a light-weight and embedded-based method is proposed. Based on YOLOv3-tiny, the network structure is optimized by simplifying the network and improving the multi-scale prediction. Then, the spatial attention module is introduced to enhance the characteristics of remote sensing objects. The experimental results show that under the input size of  $608 \times 608$ , the mean average precision, recall rate, and F1 value of the proposed method are 76.70%, 75%, and 78%, respectively, which are 3.61%, 8%, and 6% higher than that of YOLOv3-tiny. Meanwhile, its computation and model volume are reduced by 39.67% and 71.26%, respectively, compared with YOLOv3-tiny. In addition, the proposed method can achieve a real-time detection speed of 32.5 frame/s on the embedded platform NVIDIA Jetson Xavier NX, which can meet the requirement of real-time detection when run on the embedded platform.

**Key words** remote sensing; object detection; real-time detection; embedded platform; spatial attention module

**OCIS codes** 280.4788; 100.2000; 110.2960

## 1 引言

近年来,随着航天遥感技术的发展,高质量的遥感图像不断丰富,为遥感领域的应用奠定了基础。

遥感图像中通常有飞机、机场、船舶、桥梁等重要目标,在国防安全、城市建设规划、灾害监测等民用和军用领域具有十分重要的用途。因此,对遥感图像目标进行检测具有重要的意义。

收稿日期: 2020-10-22; 修回日期: 2020-11-30; 录用日期: 2020-12-30

基金项目: 山东省重点研发计划项目(2019GHY112081)

\* E-mail: wjj@ouc.edu.cn

传统的遥感图像目标检测方法主要为基于机器学习的方法。但由于遥感图像背景复杂、目标尺度较小,且受光照、云层<sup>[1]</sup>、大气中颗粒等因素影响较大,采用基于机器学习的传统检测方法效果不佳,存在严重依赖于数据结构和遥感专业知识、检测效率低、鲁棒性差等缺陷。近年来,随着深度学习的快速发展,基于卷积神经网络的目标检测方法凭借其学习能力强、检测精度高被广泛应用于各个领域。目前常用的目标检测方法主要分为两类:一类是以 Fast R-CNN<sup>[2]</sup>和 Faster R-CNN<sup>[3]</sup>等为代表的基于区域建议的目标检测算法,该类算法检测精度高但速度慢,难以满足实时检测的要求;另一类是以 SSD<sup>[4]</sup>和 YOLO<sup>[5-7]</sup>等为代表的基于回归的目标检测算法,该类算法检测速度快但精度较低。目前已有不少学者将目标检测方法应用于遥感图像目标检测中。史文旭等<sup>[8]</sup>提出特征增强 SSD 算法,实现了复杂场景下的遥感目标检测。戴媛等<sup>[9]</sup>提出一种基于 Faster R-CNN 改进的遥感图像目标检测方法。公明等<sup>[10]</sup>提出了一种基于改进 YOLOv3 的实时遥感舰船目标检测方法,取得了较高的精度。朱明明等<sup>[11]</sup>以区域卷积神经网络为基本框架,提出一种特征融合软判决的遥感图像飞机检测方法。姚群力等<sup>[12]</sup>提出一种多尺度遥感目标检测框架,实现了对多尺度遥感目标的稳健检测。王玺坤等<sup>[13]</sup>采用改进型 YOLO 对遥感图像舰船目标进行检测,取得了良好效果。李竺强等<sup>[14]</sup>提出一种基于残差网络的连续学习遥感影像机场目标检测方法。

尽管采用基于深度学习的目标检测方法可实现对遥感目标的自动检测,且准确率较高,但已有研究均采用 GPU 工作站作为实验平台,缺乏在嵌入端对遥感目标进行检测的考虑。方青云等<sup>[15]</sup>提出了一种遥感目标快速检测方法,但其只在 GPU 工作站上进行实验。相比而言,基于嵌入端的遥感目标检测方法将原有在服务器端的检测任务迁移到嵌入式设备上,具有实时数据处理、低延迟、可扩展性强等优势,可搭载在卫星上对遥感目标进行实时在轨检测,提高处理效率。

针对上述问题,本文以 YOLOv3-tiny<sup>[7]</sup>为基础网络,通过优化网络结构、引入空间注意力模块,提出一种基于嵌入式的轻量化遥感图像目标实时检测方法。实验结果表明,所提方法具有较高的检测精度,且模型计算量少、体积小,同时在嵌入式平台 NVIDIA Jetson Xavier NX 上可达到实时的检测速度,可满足在嵌入端实时检测遥感目标的需求。

## 2 YOLOv3-tiny 原理

YOLOv3 是由 Redmon 等<sup>[7]</sup>于 2018 年提出的基于回归的目标检测网络,YOLOv3-tiny 作为其轻量化版本,网络结构精简,检测速度快。以  $416 \times 416$  尺度的输入图像为例,YOLOv3-tiny 的网络结构如图 1 所示。与 YOLOv3 的特征提取网络多次使用残差模块不同,YOLOv3-tiny 采用只由 7 层卷积层和 6 层最大池化层组成的特征提取网络对输入图像进行特征提取,以达到网络结构精简的目的。特征提取完成后借鉴特征金字塔<sup>[16]</sup>的思想在  $13 \times 13$ 、 $26 \times 26$  两个尺度上进行多尺度预测,最后采用非极大值抑制机制剔除冗余的检测框,使每个目标只保留唯一的检测框,提高目标检测的精准性。YOLOv3-tiny 的检测流程如图 2 所示。

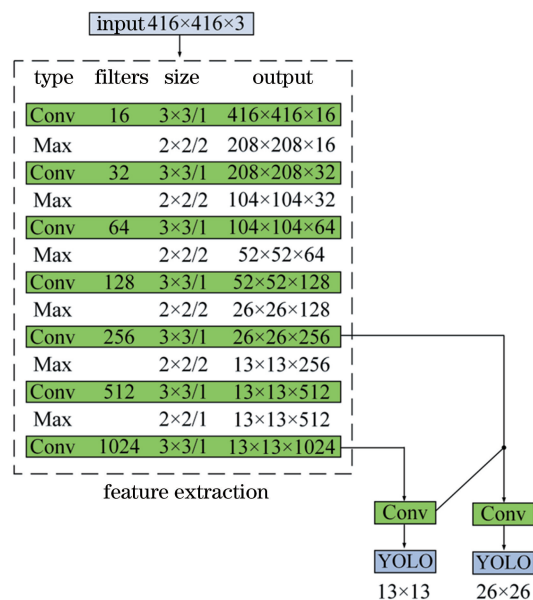


图 1 YOLOv3-tiny 网络结构

Fig. 1 Network structure of YOLOv3-tiny

## 3 改进 YOLOv3-tiny

YOLOv3-tiny 结构精简、计算量少、检测速度快,可在嵌入式平台上实现实时检测,但其检测精度不高,无法满足遥感图像中存在小尺度目标以及云层遮挡等复杂情况下的高精度检测,基于上述考虑,本文对其做出如下改进:1)通过精简网络与改进多尺度预测结构对网络进行优化,降低网络的冗余及提高对小尺度遥感目标的检测精度;2)引入空间注意力模块,增强遥感目标的特征,降低其他无关背景、云层等噪声信息的影响,提升检测精度。




图 2 YOLOv3-tiny 检测流程

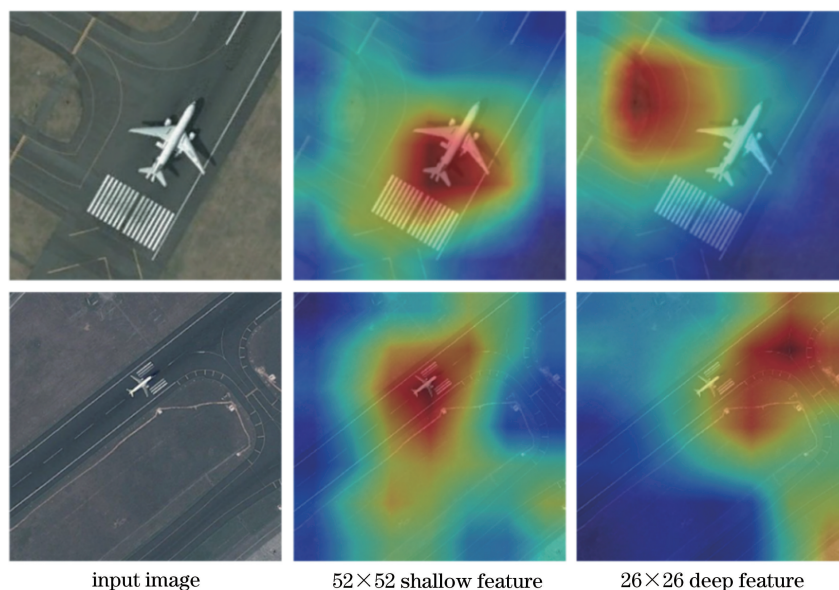
Fig. 2 Detection flow of YOLOv3-tiny

### 3.1 优化网络结构

YOLOv3-tiny 的特征提取网络由 7 层卷积层和 6 层最大池化层组成,每一卷积层所消耗的浮点计算量由该层的通道数决定。在 YOLOv3-tiny 的特征提取网络中,第 7 层卷积层的通道数最大(为 1024),在  $416 \times 416$  的输入尺寸下,该卷积层所消耗的浮点计算量远远大于其他卷积层的浮点计算量,不利于网络在嵌入式设备上对遥感目标的实时检测。遥感目标的快速实时检测有利于地面监测人员做出快速反应。为了提高 YOLOv3-tiny 在嵌入式设备上的检测速度,移除 YOLOv3-tiny 特征提取网络中通道数为 1024 的第 7 层卷积层,同时将第 7 层

卷积层前的最大池化层也移除。

YOLOv3-tiny 对输入图像进行特征提取后,在  $13 \times 13$ 、 $26 \times 26$  两个尺度的特征图上进行输出预测,未能充分利用浅层的特征图信息。相较于深层特征,浅层特征包含丰富的细节信息和位置信息,对目标定位较准确。同时浅层特征感受野包含的背景噪声小,对小目标有更好的表征能力。如图 3 所示,与  $26 \times 26$  尺度的深层特征相比较, $52 \times 52$  尺度的浅层特征对遥感目标的敏感度更高,包含更多的遥感目标细节信息,对其定位更准确,同时对小尺度的遥感目标有更好的表征能力。

图 3  $52 \times 52$  尺度的浅层特征与  $26 \times 26$  尺度的深层特征Fig. 3  $52 \times 52$  scale shallow features and  $26 \times 26$  scale deep features

因遥感卫星距离地面较远,遥感图像中的目标大多为小目标,给遥感目标的检测及其位置的确定带来了极大的困难和挑战。对此,本文对多尺度预测结构进行优化,增加一个  $52 \times 52$  的检测尺度,在  $13 \times 13$ 、 $26 \times 26$ 、 $52 \times 52$  三个尺度上进行输出预测,以充分利用网络的浅层特征,提高对小尺度遥感目标的检测效果。优化前后的多尺度预测结构如图 4

所示。

### 3.2 引入空间注意力模块

空间注意力(SA)<sup>[17]</sup>作为常用的一种注意力机制,通过加权目标的空间特征来选择性及有目的地聚合每个空间的特征,增强各个尺度特征之间的信息传播,使网络有效捕捉图像的全局上下文信息,提升网络预测目标及确定目标空间位置信息的准确




图 4 多尺度预测结构。(a)优化前的多尺度预测结构;(b)优化后的多尺度预测结构

Fig. 4 Multi-scale prediction structure. (a) Multi-scale prediction before modified; (b) multi-scale prediction after modified

性。遥感图像因背景复杂、目标较小,同时受云层、大气颗粒及雾等的影响,给遥感目标的检测及其位置的确定带来了不小的困难。引入空间注意力模块可对特征图中各个位置的特征值进行筛选,突出和增强遥感目标的特征,忽略其他无关背景的特征以及降低云层等噪声的影响,以提高遥感目标的检测准确率。如图 5(a)所示,空间注意力模块首先对输入的特征图进行最大池化与全局平均池化操作以获

取新的特征图,然后通过  $7 \times 7$  的卷积操作对新的特征图进行降维,再通过 Sigmoid 函数生成空间注意力矩阵,最后将原始的特征图与生成的空间注意力矩阵进行特征加权,以增强遥感目标的特征信息。由于平均池化、最大池化、 $7 \times 7$  卷积操作需要较大的计算量,增加推断时间,本文遵循文献[18]的做法,采用  $1 \times 1$  的卷积操作生成空间注意力矩阵,以降低计算量,减少推断时间,如图 5(b)所示。

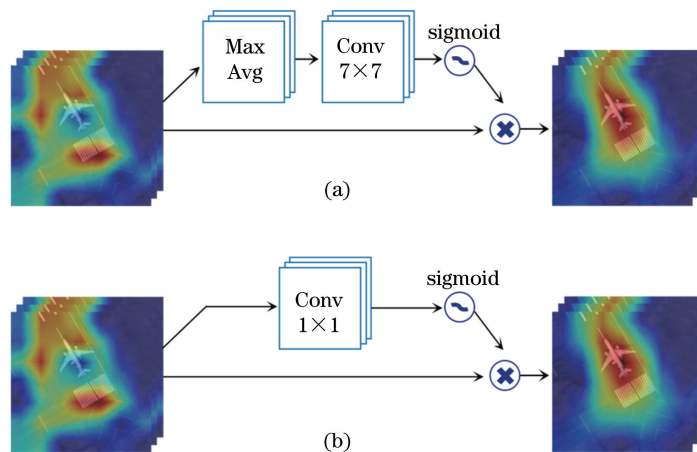


图 5 空间注意力模块。(a)原始空间注意力模块;(b)改进后的空间注意力模块

Fig. 5 Spatial attention module. (a) Original spatial attention module; (b) modified spatial attention module

将改进后的模型命名为 YOLO-RS,其结构如图 6 所示。与 YOLOv3-tiny 相比较,YOLO-RS 精简了网络、优化了多尺度预测结构、引入了空间注意力模块(SAM)。

## 4 实验与结果

### 4.1 实验数据与平台

NWPU-VHR-10 公开数据集<sup>[19]</sup>作为常用的遥感目标检测数据集,包含 650 张图像,标注有飞机、船只、油罐、棒球场、网球场、篮球场、田径场、港口、桥梁、车辆 10 类目标。考虑到该数据集图像数量较少,本文通过网上收集遥感图像将数据集扩充到 1242 张图像,目标类别保持不变。随机选取数据集中 60% 的图像作为训练集,其余的 40% 作为测试集。

本文选择在 GPU 工作站上对模型进行训练及

性能评价,再将训练好的模型部署到嵌入式平台 NVIDIA Jetson Xavier NX 上检验其运行速度。工作站的实验配置为 GPU 型号 GeForce RTX 2060  $\times$  1, Ubuntu 16.04; 嵌入式平台的配置为 GPU 型号 NVIDIA Tegra Xavier  $\times$  1, Ubuntu 18.04。

### 4.2 评价指标

本文采用平均准确率均值(mAP)、召回率、F1 值作为衡量模型精度的指标。同时还采用模型体积、浮点运算量(BFLOPS)和每秒帧率作为衡量模型大小、计算量、运行速度的指标。

### 4.3 训练过程可视化

实验选择在 Darknet 深度学习框架中进行。训练时采用 Mosaic<sup>[14]</sup> 数据增强方式,以提高模型的泛化性。训练过程的损失变化如图 7 所示。从图 7 可以看出,网络前 2000 次迭代期间的损失值较大,随着

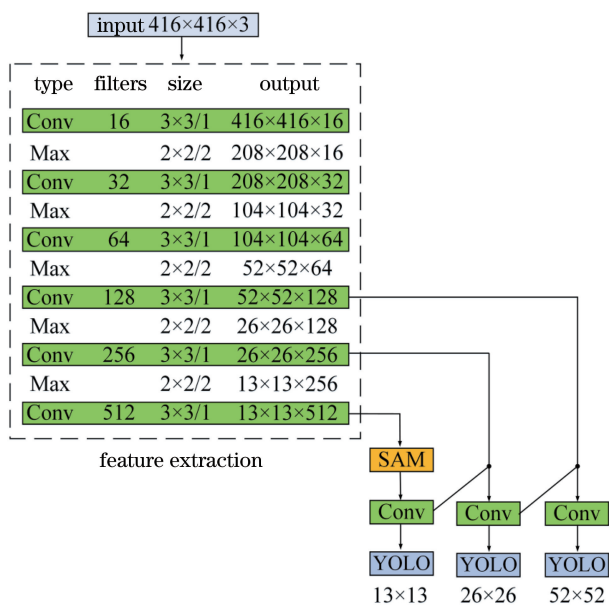


图 6 YOLO-RS 网络结构

Fig. 6 Network structure of YOLO-RS

迭代次数的增加, 损失值不断减小, 当迭代到 12000 次后损失值基本稳定在 1.5 左右, 表示模型收敛。




图 7 训练过程损失值变化曲线

Fig. 7 Loss curve during training process

#### 4.4 实验结果

表 1 对比了本文方法与其他方法在遥感测试集上的性能。性能评估在三种输入尺寸下进行, 当输入尺寸为  $608 \times 608$  时, 网络在  $19 \times 19$ 、 $38 \times 38$ 、 $76 \times 76$  三个尺度上进行输出预测; 当输入尺寸为  $512 \times 512$  时, 网络在  $16 \times 16$ 、 $32 \times 32$ 、 $64 \times 64$  三个尺度上进行输出预测; 当输入尺寸为  $416 \times 416$  时, 网络在  $13 \times 13$ 、 $26 \times 26$ 、 $52 \times 52$  三个尺度上进行输出预测。在输入尺寸越大的情况下, 图像能保留更加丰富的信息, 模型的检测精度也越高, 但其浮点运算量也越大。由表 1 可知, 本文提出的 YOLO-RS 在  $608 \times 608$  的输入尺寸下取得了最佳的检测精度, 其中 mAP 达 76.70%, 召回率达 75%, F1 值达 78%, 较 YOLOv3-tiny 提升了 3.61%、8%、6%, 究其原因, 本文优化了原始 YOLOv3-tiny 的多尺度预测结构, 充分利用了网络的浅层特征, 同时引入了空间注意力模块, 增强了遥感目标的特征, 使模型的检测精度得到了提升。

此外, YOLO-RS 的计算量和模型体积也较小, 其浮点计算量最大仅为 7.04, 模型体积为 10.0 MB, 较 YOLOv3-tiny 分别减少了 39.67% 和 71.26%。究其原因, 本文对 YOLOv3-tiny 进行了精简, 降低了模型的计算量和体积。尽管 YOLO-RS 在精度上逊色于 YOLOv3, 但其计算量和模型体积远远小于 YOLOv3, 更适合在嵌入式平台上部署。实验结果表明, 相较于 YOLOv3-tiny, 改进后的 YOLO-RS 在精度上有明显提升, 同时计算量和模型体积还得到了减小。

表 1 不同方法在遥感测试集上的检测性能

Table 1 Detection performance of different methods on remote sensing test set

Method	Input size	mAP / %	Recall / %	F1 / %	BFLOPS	Volume / MB
YOLOv3	$608 \times 608$	80.07	81	81	139.64	246.5
YOLOv3-tiny	$608 \times 608$	73.09	67	72	11.67	34.8
YOLO-RS	$608 \times 608$	76.70	75	78	7.04	10.0
YOLOv3	$512 \times 512$	79.61	76	80	99.02	246.5
YOLOv3-tiny	$512 \times 512$	71.60	63	70	8.27	34.8
YOLO-RS	$512 \times 512$	75.56	73	77	4.99	10.0
YOLOv3	$416 \times 416$	77.04	70	77	65.37	246.5
YOLOv3-tiny	$416 \times 416$	65.15	54	64	5.46	34.8
YOLO-RS	$416 \times 416$	72.86	65	72	3.30	10.0

#### 4.5 检测结果可视化

图 8 展示了所提出的 YOLO-RS 在遥感测试集上的部分检测结果。从图 8 可以看出, 在密集分

布、小尺度目标、有云层遮挡等复杂情况下, YOLO-RS 均精准地检测出了遥感目标, 表明该方法具有良好的检测性能。



图 8 YOLO-RS 的检测结果  
Fig. 8 Test results of YOLO-RS

#### 4.6 嵌入式平台实验结果

如图 9 所示,将训练好的 YOLO-RS 部署到嵌入式平台 Jetson Xavier NX 上,以检验其检测速度。

Jetson Xavier NX 外形小巧、性能强大,适合搭载在卫星上作为检测遥感目标的计算平台。



图 9 在嵌入式平台 Jetson Xavier NX 上进行实验  
Fig. 9 Experiments on the embedded platform Jetson Xavier NX

表 2 对比了不同方法在 Jetson Xavier NX 上的检测速度。

表 2 不同方法在 Jetson Xavier NX 上的检测速度

Table 2 Detection speed of different methods on Jetson Xavier NX

Method	Speed / (frame · s <sup>-1</sup> )		
	416 × 416	512 × 512	608 × 608
YOLOv3	8.1	6.3	4.6
YOLOv3-tiny	54.6	40.8	31.5
YOLO-RS	56.7	43.5	32.5

由表 2 可知,精度较高的 YOLOv3 因结构复杂在 Jetson Xavier NX 上只达到了最快 8.1 frame/s 的检测速度,无法满足实时检测的需求。而 YOLO-RS 在三种输入尺寸下分别实现了 56.7 frame/s、43.5 frame/s、32.5 frame/s 的实时

检测速度,均高于 YOLOv3-tiny 和 YOLOv3,满足了实时检测的需求。图 10 对比了不同模型的检测精度和检测速度。从图 10 可以看出,YOLOv3 检

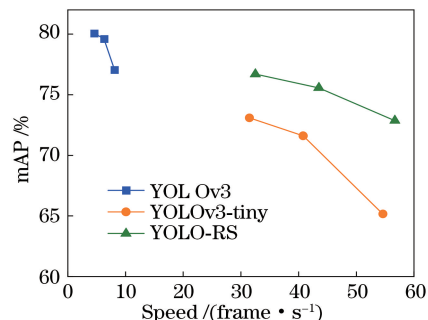


图 10 不同模型的检测精度和检测速度对比  
Fig. 10 Comparison of detection accuracy and speed of different models

测精度高但无法实现实时检测,而 YOLO-RS 较 YOLOv3-tiny 精度高且检测速度快,更适合在嵌入式平台上部署。

## 5 结 论

为了实现在计算资源受限的卫星上对遥感目标进行实时在轨检测,本文以 YOLOv3-tiny 检测方法为基础,通过优化原始网络结构、引入空间注意力模块,提出一种基于嵌入式的轻量化遥感图像目标实时检测方法。实验结果表明,所提方法在遥感图像数据集上取得了较高的检测精度,同时计算量少、模型体积小,在嵌入式平台 NVIDIA Jetson Xavier NX 上可达到实时检测。所提方法适合部署在嵌入式设备上,并搭载在卫星上对遥感目标进行实时在轨检测。

## 参 考 文 献

- [1] Li X H, Wang L Y, Cheng Q, et al. Cloud removal in remote sensing images using nonnegative matrix factorization and error correction[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 148: 103-113.
- [2] Girshick R. Fast R-CNN [C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1440-1448.
- [3] 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 and Machine Intelligence, 2017, 39(6): 1137-1149.
- [4] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector [M]. Cham: Springer International Publishing, 2016: 21-37.
- [5] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection [J]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 779-788.
- [6] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [7] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08) [2020-10-08]. <https://arxiv.org/abs/1804.02767>.
- [8] Shi W X, Tan D L, Bao S L. Feature enhancement SSD algorithm and its application in remote sensing images target detection[J]. Acta Photonica Sinica, 2020, 49(1): 0128002.
- 史文旭, 谭代伦, 鲍胜利. 特征增强 SSD 算法及其在遥感目标检测中的应用[J]. 光子学报, 2020, 49(1): 0128002.
- [9] Dai Y, Yi B S, Xiao J S, et al. Object detection of remote sensing image based on improved rotation region proposal network [J]. Acta Optica Sinica, 2020, 40(1): 0111020.
- 戴媛, 易本顺, 肖进胜, 等. 基于改进旋转区域生成网络的遥感图像目标检测[J]. 光学学报, 2020, 40(1): 0111020.
- [10] Gong M, Liu Y Y, Li G N. A ship detection method for remote-sensing images based on improved YOLO-v3[J]. Electronics Optics & Control, 2020, 27(5): 102-107.
- 公明, 刘妍妍, 李国宁. 改进 YOLO-v3 的遥感图像舰船检测方法[J]. 电光与控制, 2020, 27(5): 102-107.
- [11] Zhu M M, Xu Y L, Ma S P, et al. Airplane detection based on feature fusion and soft decision in remote sensing images[J]. Acta Optica Sinica, 2019, 39(2): 0210001.
- 朱明明, 许悦雷, 马时平, 等. 基于特征融合与软判决的遥感图像飞机检测[J]. 光学学报, 2019, 39(2): 0210001.
- [12] Yao Q L, Hu X, Lei H. Object detection in remote sensing images using multiscale convolutional neural networks[J]. Acta Optica Sinica, 2019, 39(11): 1128002.
- 姚群力, 胡显, 雷宏. 基于多尺度卷积神经网络的遥感目标检测研究[J]. 光学学报, 2019, 39(11): 1128002.
- [13] Wang X K, Jiang H X, Lin K Y. Remote sensing image ship detection based on modified YOLO algorithm [J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(6): 1184-1191.
- 王玺坤, 姜宏旭, 林珂玉. 基于改进型 YOLO 算法的遥感图像舰船检测[J]. 北京航空航天大学学报, 2020, 46(6): 1184-1191.
- [14] Li Z Q, Zhu R F, Ma J Y, et al. Airport detection method combined with continuous learning of residual-based network on remote sensing image[J]. Acta Optica Sinica, 2020, 40(16): 1628005.
- 李竺强, 朱瑞飞, 马经宇, 等. 联合连续学习的残差网络遥感影像机场目标检测方法[J]. 光学学报, 2020, 40(16): 1628005.
- [15] Fang Q Y, Wang Z K. Efficient object detection method based on improved YOLOv3 network for remote sensing images [J]. Aerospace Shanghai,

- 2019, 36(5): 21-27, 34.
- 方青云, 王兆魁. 基于改进 YOLOv3 网络的遥感目标快速检测方法[J]. 上海航天, 2019, 36(5): 21-27, 34.
- [16] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 936-944.
- [17] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module [M]. Cham: Springer International Publishing, 2018: 3-19.
- [18] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection [EB/OL]. (2020-04-23)[2020-10-08]. <https://arxiv.org/abs/2004.10934>.
- [19] Cheng G, Zhou P C, Han J W. Learning rotation-invariant convolutional neural networks for object detection in VHR optical remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(12): 7405-7415.