

基于密集连接与特征增强的遥感图像检测

王道累,杜文斌,刘易腾,张天宇,孙嘉珺,李明山

(上海电力大学 能源与机械工程学院,上海 200090)

摘要: 遥感技术的快速发展使得遥感图像检测技术广泛应用于军事、农业、交通、城市规划等多个领域。随着遥感分辨率和数据体量的不断提升,通过人工处理数据的方法已经无法满足实时性需求,因此,实现高效、精准的自动化数据处理方式成为该领域的研究热点。针对遥感图像分辨率高、背景复杂、目标尺度小等特点,提出一种改进的YOLOv3算法,用以提升遥感图像的检测效果。在原始YOLOv3算法的基础上,使用改进的密集连接网络替换原有的DarkNet53作为基础网络,以提升网络输入和预测结果的尺度多样性。通过阀杆模块降低输入损失,同时在浅层特征图中加入特征增强模块,从而丰富特征图的感受野,强化网络对浅层特征信息的提取,在保证整体检测性能的同时使网络对遥感图像中、小目标的检测精度和鲁棒性均有所提升。在遥感图像数据集上进行多组对比实验,结果表明,相比原始YOLOv3算法,该算法的平均准确率提高9.45个百分点,在小尺度目标上的检测准确率提升更显著,达到11.03个百分点,且模型参数量得到有效缩减。

关键词: 目标检测;深度学习;遥感图像;特征增强;密集连接

开放科学(资源服务)标志码(OSID):



中文引用格式:王道累,杜文斌,刘易腾,等.基于密集连接与特征增强的遥感图像检测[J].计算机工程,2022,48(6):251-256,262.

英文引用格式:WANG D L, DU W B, LIU Y T, et al.Remote sensing images detection based on dense connection and feature enhancement[J].Computer Engineering, 2022, 48(6): 251-256, 262.

Remote Sensing Images Detection Based on Dense Connection and Feature Enhancement

WANG Daolei, DU Wenbin, LIU Yiteng, ZHANG Tianyu, SUN Jiajun, LI Mingshan

(College of Energy and Mechanical Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

[Abstract] With the rapid development of remote sensing technology, remote sensing image detection is being widely used in military, agriculture, transportation, urban planning, and other fields. With the continuous improvements of the remote sensing resolution and data volume, a manual data processing method has been unable to meet the real-time requirements. Therefore, the realization of an efficient and accurate automatic data processing approach has become a research hotspot in this field. Aiming at the characteristics of a high resolution, complex background, and small target scale of a remote sensing image, this paper proposes an improved YOLOv3 algorithm to improve the detection effect of such an image. Based on the original YOLOv3 algorithm, the improved dense connection network replaces the original DarkNet53 as the basic network, thereby improving the scale diversity of network input and prediction results. This study reduces the input loss through the valve stem module, and adds a feature enhancement module to the shallow feature map, thereby enriching the receptive field of the feature map and strengthening the extraction of the shallow feature information of the network, while ensuring the overall detection performance, this study improves the detection accuracy and robustness of the network for medium and small targets in remote sensing images. This study also carried out several groups of comparative experiments on remote sensing image datasets. The results show that, compared with the original YOLOv3 algorithm, the average accuracy of the algorithm is improved by 9.45 percentage points, and the detection accuracy of small-scale targets is increased even more significantly, reaching 11.03 percentage points. In addition, the number of model parameters is effectively reduced.

[Key words] target detection; deep learning; remote sensing image; feature enhancement; dense connection

DOI: 10.19678/j.issn.1000-3428.0061482

基金项目:国家自然科学基金(61502297)。

作者简介:王道累(1981—),男,副教授、博士,主研方向为计算机视觉、图像处理;杜文斌、刘易腾、张天宇、孙嘉珺、李明山,硕士研究生。

收稿日期:2021-04-27 **修回日期:**2021-07-07 **E-mail:**alfredwdl@shiep.edu.cn

0 概述

随着遥感技术的快速发展,高分辨率光学遥感图像以其观察面积大、范围广、不受国界和地理条件限制等特点而受到国内外学者的广泛关注。在森林防护、交通监测、电力检修、资源勘探、城建规划等领域,遥感图像检测发挥着十分重要的作用,例如,通过检测车辆目标来进行交通秩序管理,通过检测建筑房屋等目标来为城市规划提供依据,通过检测受灾房屋、道路、桥梁等目标来评估受灾情况等^[1]。传统的遥感图像检测方法主要利用人工设计特征的方式提取特征信息然后训练分类器,通过滑动窗口获取图像区域,由分类器输出预测结果^[2]。这种检测方法不仅消耗较多资源,检测速度与准确性往往也无法达到要求。

近年来,随着计算机硬件与人工智能技术的不断发展,基于深度学习的目标检测算法因其适用性强、检测效率高等优点而得到广泛应用。基于深度学习的目标检测算法主要分为两类:第一类为双阶段目标检测算法,以Faster R-CNN^[3]、Mask R-CNN^[4]等为代表;第二类为单阶段目标检测算法,以SSD^[5]、YOLO^[6]、YOLO9000^[7]、YOLOv3^[8]等为代表。目前,深度学习在遥感图像检测应用^[9]中主要存在以下问题:遥感图像分辨率较高,被检目标信息少,背景噪声影响较大,使得一般的目标检测算法无法准确提取原始图像的特征信息,造成分类和定位

困难;遥感图像中的目标普遍小而密集,尺寸较小的目标在网络学习过程中极易被忽略,导致网络对小目标的学习不足,降低了检测的准确率。

为解决上述问题,本文对YOLOv3算法进行改进,建立一种基于密集连接与特征增强的目标检测模型。该模型使用改进的密集连接网络作为主干网络,同时基于Inception^[10]与RFB(Receptive Field Block)^[11]扩大卷积感受野,并引入特征增强模块和新型特征金字塔结构,从而增强浅层特征图语义并改善模型对小目标的检测性能。

1 基于密集连接与特征增强的检测算法

1.1 YOLOv3算法

YOLOv3是REDMON等在2018年提出的一种单阶段目标检测算法,是目前应用最广泛的目标检测算法之一^[8]。YOLOv3的检测框架如图1所示,其主要包括2个部分:第一部分为基础网络,采用DarkNet53,网络包含5个残差块(ResBlock),每个残差块由多个残差结构(Residual Structure)组成;第二部分为借鉴FPN(Feature Pyramid Networks)^[12]设置的特征金字塔网络结构,其通过卷积和上采样产生3个具有丰富语义信息的特征图,大小分别为 13×13 、 26×26 、 52×52 。在训练阶段,网络将图像划分为 $N \times N$ 个网格单元,每个网格单元输出预测框的信息以及分类置信度从而完成检测。

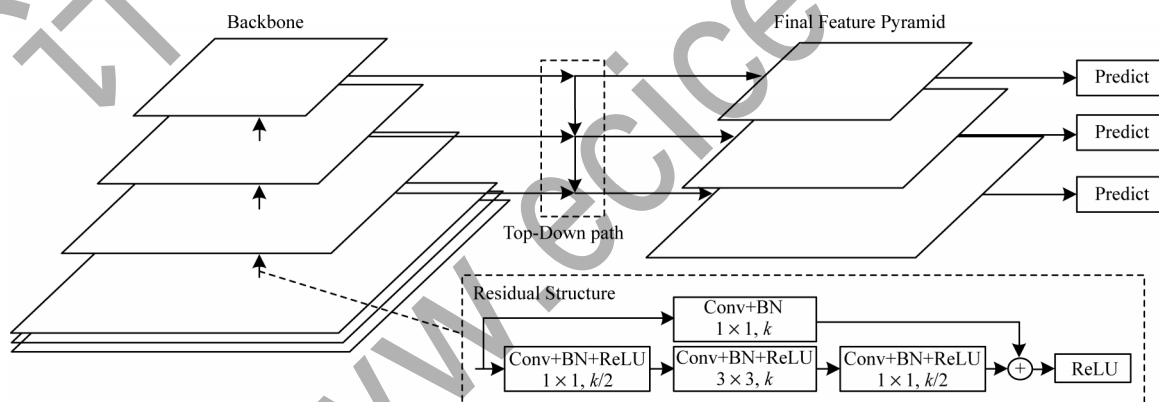


图1 原始YOLOv3框架

Fig.1 Original YOLOv3 framework

现有一些研究人员将YOLOv3应用于遥感图像检测领域。李昕等^[13]将空间变换网络(Spatial Transformer Networks, STN)融入YOLOv3算法中,以提升遥感图像中油罐的检测精度。郑海生等^[14]通过替换主干结构和激活函数将YOLOv3的参数量缩小为原始的1/15,实现了轻量级的遥感图像检测。沈丰毅^[15]在原始YOLOv3算法中引入压缩激励结构,通过权重差异提升模型对遥感图像特征的敏感度。上述研究通过不同方法改进YOLOv3模型,使其具有更好的表现,但是都未能很好地解决遥感图像中特征提取困难以及目标尺度小的问题,这是由于YOLOv3对小尺度目标的检测主要依赖于浅层

的特征图,浅层特征图的分辨率较高,空间位置信息丰富,但由于其处于网络的浅层位置,没有经过足够的处理,因此语义信息较少,特征表达能力不足。此外,YOLOv3的主干网络DarkNet53在遥感图像中无法取得较好的表现,特征提取能力不足,导致检测效果较差。

1.2 改进的YOLOv3算法

1.2.1 主干网络改进

本文依据DenseNet121^[16]提出一种新型的密集连接主干网络,网络由阀杆模块(Stem Block)和4个密集连接块(Dense Block)组成。阀杆模块借鉴Inception v4和DSOD(Deeply Supervised Object Detectors)^[17]的思

想,结构如图2所示,该模块可以有效提升特征表达能力,同时不会增加过多的计算成本,与DenseNet121中的原始设计(首先是大小为7、步长为2的卷积层,然后是大小为3、步长为2的最大池化层)相比,多分支的处理可以大幅减少输入图像在下采样过程中的信息损失。




图2 阀杆模块结构

Fig.2 Stem block structure

密集连接块的基本组成为密集连接结构(Dense Structure),其最显著的特点是跨通道的特征连接方式,通过每一层与前面所有层建立连接,使误差信号快速传播到较浅层,加强整个网络对特征信息的传播,在提升特征提取能力的同时大幅降低网络参数量。密集连接块的计算可表示为:

$$\mathbf{x}_l = H_l(\delta[\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_{l-1}]) \quad (1)$$




图3 3种网络的结构对比

Fig.3 Structure comparison of three networks

1.2.2 特征增强模块

在本文主干网络中,由于预测所用的特征图分辨率较大,浅层特征图没有经过充分处理可能会导致特征中的语义信息不足,因此,本文提出一种特征增强模块,针对浅层特征图语义信息少、感受野不足的问题,使用多分支处理和空洞卷积来提高浅层特征图的语义

其中: \mathbf{x}_l 表示第 l 层的输出; $H_l(\cdot)$ 表示非线性操作组合,包括BN层、ReLU和卷积层; $\delta[\cdot]$ 表示Concatenation特征融合操作。

网络的输入大小为 448×448 像素,在训练阶段,输入图像首先经过阀杆模块处理,通过大尺度卷积与多分支处理以缓解图像下采样时尺度变化所带来的损失,之后经过密集连接块得到4个不同尺度的特征图,其下采样倍数分别为4、8、16、32。图3所示为DarkNet、原始DenseNet与本文改进主干网络的结构对比,其中,原始DarkNet53输入大小为 416×416 像素,使用下采样倍数为8、16、32的特征图预测,原始DenseNet121作为主干网络,输入大小为 224×224 像素,使用下采样倍数为8、16、32的特征图预测,改进的密集连接网络输入大小为 448×448 像素,使用下采样倍数为4、8、16、32的特征图预测。从图3可以看出,相较原始的DenseNet121,本文改进的主干网络的输入分辨率与预测特征图分辨率更高,并通过阀杆模块缓解了原始网络输入时信息损失过大的问题。同时,本文采用4种预测尺度,最大尺度为 112×112 ,最小尺度为 14×14 ,在保证小目标检测精度的同时提升了对大尺度目标的检测效果。

信息,从而改善网络对小尺度目标的适应能力。本文模型结构如图4所示,提取出下采样倍数分别为4、8、16、32的特征图用于预测,对浅层特征图(下采样倍数为4和8)进行特征增强处理,对深层特征图(下采样倍数为16和32)使用SPP(Spatial Pyramid Pooling)^[18]进行处理,SPP结构如图5所示。

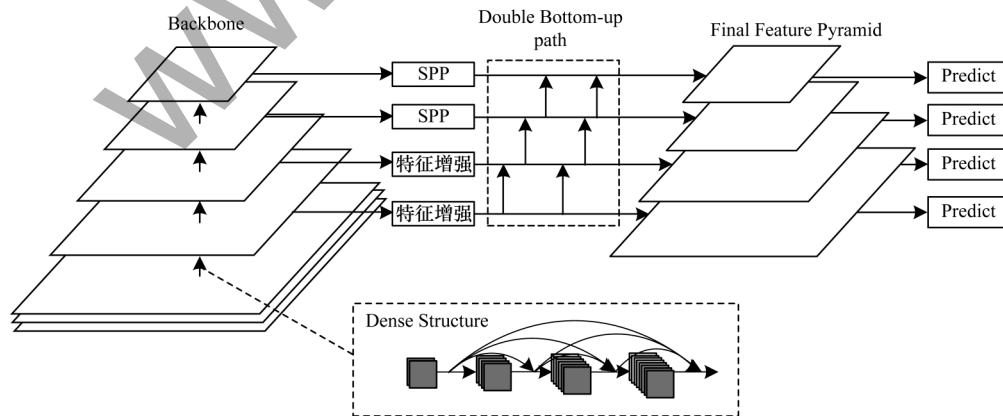


图4 改进的YOLOv3框架

Fig.4 Improved YOLOv3 framework

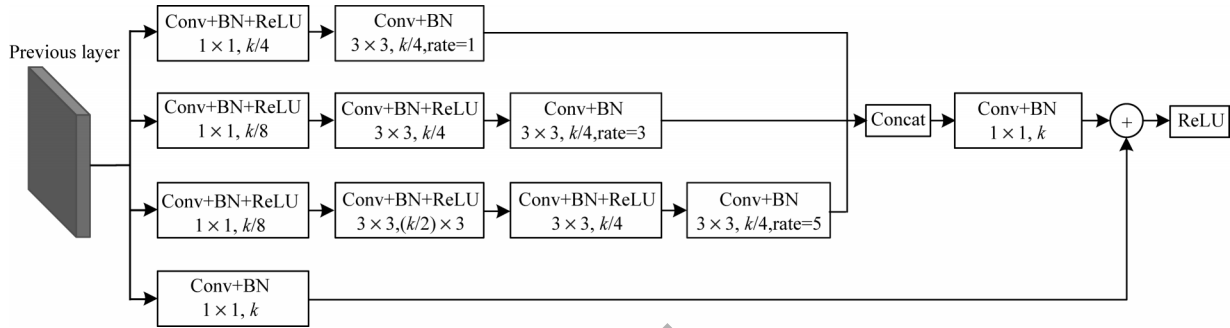


图5 SPP结构

Fig.5 SPP structure

特征增强模块借鉴RFB感受野原理,通过增加网络的宽度与感受野来提高模型的特征提取能力,增加特征图的语义信息,其结构如图6所示,共有4条支路,其中1条支路为残差网络结构中的残差支路(Shortcut Connection),只进行 1×1 的卷积操作,另外3条支路由 1×1 与 3×3 的卷积级联而成,并在 3×3 的卷积后加入不同膨胀率的空洞卷积层。多个 3×3 的卷积级联在扩大感受野的同时也减少了参数量,使网络的训练与推理速度更快,网络中的每个卷积层后都加入了BN层,旨在通过数据的归一化处理来加快模型收敛。

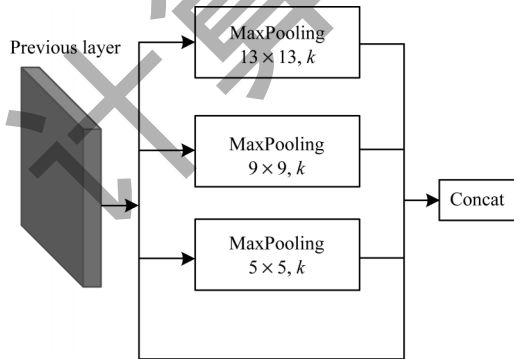


图6 特征增强模块结构

Fig.6 Structure of feature enhancement module

特征增强模块的计算可表示为:

$$\mathbf{Q}_i = H_i[P(\mathbf{X}_j)], i = 1, 2, 3 \quad (2)$$

$$\mathbf{W}_i = R_i(\mathbf{Q}_i) \quad (3)$$

$$\mathbf{Z}_j = \delta_i[\mathbf{W}_1, \mathbf{W}_2, \mathbf{W}_3] + P(\mathbf{X}_j) \quad (4)$$

其中: \mathbf{X}_j 表示输入特征图; P 表示由 1×1 卷积层、BN层和ReLU层组成的非线性操作组合; H_i 表示进行 i 次由 3×3 卷积层、BN层和ReLU层组成的非线性操作组合; \mathbf{Q}_i 表示 i 次卷积操作后的特征图; R_i 表示空洞卷积, $i = 1, 2, 3$ 时空洞卷积的膨胀率分别为1, 3, 5; \mathbf{Z}_j 表示融合后的新特征图。

经过特征增强模块的处理,网络对小目标的敏感度更高,在复杂背景下依然可以准确提取小目标的特征信息,从而提升网络的检测精度。

1.2.3 特征金字塔结构

本文使用重复的自浅而深(Double Bottom-up path)的特征金字塔结构,如图4所示,使用经特征增

强模块和SPP处理的特征图作为特征金字塔结构的输入,输入的特征图被分为2个分支:一支在进行下采样与卷积操作后与下一层特征图相累加;另一支同样进行下采样操作并与累加后的特征相结合,使网络中的信息由浅层向深层传输。通常在网络训练过程中,目标的像素不断减小,若小目标的信息在主干网络的最后一层已经消失,则在上采样操作后无法恢复小目标的信息,在浅层特征与深层特征相结合时便会出现混淆,降低了网络的检测精度。通过本文的特征金字塔结构处理,网络不会因上采样操作而丢失小目标信息,避免了网络因小目标信息丢失所造成的精度损失。

2 实验结果与分析

2.1 实验平台与数据集

本文实验平台设置:使用Ubuntu16.04操作系统,NVIDIA Tesla T4(16 GB显存),Python编程语言,深度学习框架为Tensorflow。

本文实验所用数据来自RSOD和NWPU NHR-10^[19]数据集,针对原始图像进行筛选,剔除质量较差的图片,并核验标注信息,对错标、漏标的样本进行重新标注,最终得到包括不同场景的图片共计1 620张,检测目标包括飞机、船舶、储油罐、棒球场、网球场、篮球场、田径场、海港、桥梁和车辆,图片分辨率为 $(600 \sim 1\,000) \times (600 \sim 1\,000)$ 像素。

图7所示为本文数据集中目标真实框的尺寸分布情况,目标真实框总共11 296个,主要集中于小尺度范围,绝大多数目标分布在 100×100 像素点以内,其中, 16×16 像素大小的目标占比为41.79%,低于 32×32 像素的目标占比达到约92%。




图7 目标尺度分布

Fig.7 Target scale distribution

2.2 模型训练及评价指标

数据增强采用随机裁剪、随机旋转、缩放等操作,初始学习率设置为 0.01,采用随机梯度下降法对总损失函数进行优化训练,训练批次设置为 4。

本文使用的评价指标为平均准确率(mAP)。通过衡量预测标签框与真实标签框的交并比(IOU)得到每个类别的精确度(Precision, *P*)和召回率(Recall, *R*),由精确度和召回率所绘制的曲线面积即为准确率均值(AP),多个类别的 AP 平均值即为平均准确率,其计算可表示为:

$$M_{\text{mAP}} = \frac{\sum_i^n \int_0^1 P(R) dR}{n} \tag{5}$$

2.3 对比实验结果分析

利用所整理的数据集对本文算法性能进行验

证,将其与原始 YOLOv3 算法、SSD 算法、EfficientDet 算法^[20]、CenterNet 算法^[21]、YOLOv4 算法^[22]、Faster R-CNN 算法得到的结果进行客观比较,结果如表 1 所示,其中, $\text{mAP}^{\text{large}}$ 、 $\text{mAP}^{\text{medium}}$ 、 $\text{mAP}^{\text{small}}$ 分别代表大目标、中目标、小目标的平均准确率。从表 1 可以看出,本文改进 YOLOv3 算法的平均准确率高出其他算法,达到 74.56%,相比原始 YOLOv3 算法提高了 9.45 个百分点,尤其在小尺度目标检测上,比原始算法提高了 11.03 个百分点,并且参数量也低于原始 YOLOv3 算法。与 YOLOv4 算法相比,本文算法的大目标检测精度与其相差 0.69 个百分点,但在中、小目标的检测精度上均高于 YOLOv4 算法,与双阶段目标检测算法 Faster R-CNN 相比,本文算法也取得了更优的检测效果。

表 1 对比实验结果

Table 1 Results of comparative experiment

算法	主干网络	输入大小/像素	mAP/%	$\text{mAP}^{\text{large}}/\%$	$\text{mAP}^{\text{medium}}/\%$	$\text{mAP}^{\text{small}}/\%$	参数量/ 10^6
YOLOv3	DarkNet53	416×416	65.11	81.42	57.49	64.69	235.0
SSD	VGG16	300×300	55.99	83.36	45.01	56.25	95.8
EfficientDet	EfficientNet-B0	512×512	70.19	81.94	62.34	66.09	16.0
CenterNet	ResNet50	512×512	69.15	87.13	46.43	73.89	125.0
YOLOv4	CSPDarkNet53	416×416	71.39	87.62	58.60	67.95	245.0
Faster R-CNN	ResNet50	600×600	66.37	75.37	56.26	67.48	108.0
本文算法	改进 DenseNet121	448×448	74.56	86.93	61.10	75.72	229.0

图 8 所示为 2 种算法的检测效果对比,第 1 行为原始 YOLOv3 算法的检测结果,第 2 行为本文算法的检测结果。第 1 列、第 2 列背景为机场与港口,是典型的遥感图像场景,从中可以看出,原始 YOLOv3 算法在这种具有复杂背景的图片下存在漏检现象,部分目标如飞机、油罐等无法检出,而本文算法漏检现象则大幅减

少;第 3 列、第 4 列为道路背景图片,待检目标的尺寸较小,原始 YOLOv3 算法无法有效检出目标车辆,而本文算法在高分辨率下对小目标仍有较好的检测效果;第 5 列~第 7 列为森林、海域背景图片,可以明显看出,当待检目标距离较近时,原始 YOLOv3 算法会出现漏检现象,而本文算法的检测效果得到有效提升。




图 8 2 种算法的检测效果对比

Fig.8 Comparison of detection effects of two algorithms

2.4 消融实验结果分析

本节通过消融实验以探究各部分改进对模型的性能影响。

第 1 组对比实验分析替换主干网络对模型精度的影响,本次实验设置 3 组模型进行对比,分别为原始 YOLOv3 模型,对比模型 1(使用原始 DenseNet121 的 YOLOv3 模型)以及对比模型 2(使用本文主干网络的 YOLOv3 模型),3 组实验分别使用不同的主干网络,其他参数相同,实验结果如表 2

所示。从表 2 可以看出,使用原始 DenseNet121 作为主干网络时 mAP 的提升并不明显,这是由于较低的分辨率输入以及原始 DenseNet121 在下采样时损失过多特征信息所导致,而使用本文改进的主干网络时, mAP 提高了 6.76 个百分点,在大、中目标上的检测精度均高于原始模型,且在小目标上的检测精度提升最为显著。由于遥感图像中的目标尺度集中分布在小尺寸范围内,因此本文所提主干网络更适用于遥感图像检测。

表2 主干网络消融实验结果

Table 2 Experimental results of backbone network ablation

模型	mAP	mAP ^{large}	mAP ^{medium}	mAP ^{small}
YOLOv3	65.11	81.42	57.49	64.69
对比模型1	65.58	72.18	50.63	74.90
对比模型2	71.87	83.27	59.70	75.68

第2组对比实验分析特征增强模块与特征金字塔结构对模型的影响,设置4组模型进行对比,实验结果如表3所示。从表3可以看出,使用特征增强模块的模型mAP提升显著,而单独使用改进特征金字塔结构时则效果不明显,这是由于原始YOLOv3模型中特征未经强化处理,语义信息过少,使改进后的特征金字塔效果较差,而当2项改进共同使用时,检测精度达到最高。

表3 特征增强模块与特征金字塔消融实验结果

Table 3 Experimental results of feature enhancement module and feature pyramid ablation

模型	特征增强	特征金字塔	mAP/%
YOLOv3			65.11
对比模型1	√		69.47
对比模型2		√	67.14
对比模型3	√	√	70.12

3 结束语

本文针对遥感图像背景干扰大、目标尺度小等问题,提出一种基于改进YOLOv3的遥感图像目标检测算法。将密集连接网络与YOLOv3相结合,通过由多分支结构与空洞卷积所组成的特征增强模块来加强特征的语义信息,使用新型的特征金字塔结构减少对小目标的检测精度损失。在遥感图像数据集上的实验结果验证了该算法在目标检测任务中的有效性,尤其在小目标检测上优势明显。后续将结合本文算法进一步探究密集连接网络与感受野原理对遥感图像检测的影响,以实现更高的检测精度。

参考文献

[1] WU Y R, HU H, ZHANG Y. Multi-resolution object detection and data fusion for large-scale remote sensing images based on deep learning method[C]//Proceedings of IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference. Washington D. C. , USA; IEEE Press, 2019: 933-937.

[2] 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, 2010, 32(9) : 1627-1645.

[3] REN S 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.

[4] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]//Proceedings of IEEE International Conference on Computer Vision. Washington D. C. , USA; IEEE Press, 2017: 2980-2988.

[5] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single Shot MultiBox Detector[M]. Berlin, Germany; Springer, 2016.

[6] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press , 2016: 779-788.

[7] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2017: 6517-6525.

[8] REDMON J, FARHADI A. YOLOv3: an incremental improvement[EB/OL]. [2021-03-05]. <https://arxiv.org/pdf/1804.02767.pdf>.

[9] ZHENG Z, LEI L, SUN H, et al. A review of remote sensing image object detection algorithms based on deep learning[C]//Proceedings of IEEE International Conference on Image, Vision and Computing. Washington D. C. , USA; IEEE Press, 2020: 34-43.

[10] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-ResNet and the impact of residual connections on learning [EB/OL]. [2021-03-05]. <https://arxiv.org/pdf/1602.07261.pdf>.

[11] LIU S, HUANG D. Receptive field block net for accurate and fast object detection [C]//Proceedings of European Conference on Computer Vision. Berlin, Germany; Springer, 2018: 385-400.

[12] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2017: 936-944.

[13] 李昕,赵猛,董修武,等. 基于改进YOLOV3算法的遥感图像油罐检测[J]. 中国科技论文, 2020, 15(3) : 267-273.

LI X, ZHAO M, DONG X W, et al. Oil tank detection in remote sensing images based on improved YOLOV3 algorithm[J]. China Sciencepaper, 2020, 15(3) : 267-273. (in Chinese)

[14] 郑海生,王雪纯. 面向遥感图像实时目标检测任务的轻量级神经网络设计与实现[J]. 电脑与电信, 2020(3) : 18-22.

ZHENG H S, WANG X C. Design and implementation of lightweight neural network for real-time target detection tasks in remote-sensing images[J]. Computer & Telecommunication, 2020(3) : 18-22. (in Chinese)

[15] 沈丰毅,王琴,蒋剑飞. 基于改进卷积神经网络舰船的实时目标检测算法[J]. 计算机应用研究, 2020, 37(S1) : 316-319.

SHEN F Y, WANG Q, JIANG J F. Real-time automatic ship detection based on modified convolutional neural networks[J]. Application Research of Computers, 2020, 37(S1) : 316-319. (in Chinese)

[16] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA; IEEE Press, 2017: 2261-2269.

(上接第 256 页)

- [17] SHEN Z Q, LIU Z, LI J G, et al. DSOD: learning deeply supervised object detectors from scratch[C]//Proceedings of IEEE International Conference on Computer Vision. Washington D. C. , USA: IEEE Press, 2017: 1937-1945.
- [18] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[EB/OL]. [2021-03-05]. <https://ieeexplore.ieee.org/document/7005506/>.
- [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.
- [20] TAN M X, PANG R M, LE Q V. EfficientDet: scalable and efficient object detection[C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. Washington D. C. , USA: IEEE Press, 2020: 10778-10787.
- [21] DUAN K W, BAI S, XIE L X, et al. CenterNet: keypoint triplets for object detection[C]//Proceedings of IEEE/CVF International Conference on Computer Vision . Washington D. C. , USA: IEEE Press, 2019: 6568-6577.
- [22] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. [2021-03-05]. <https://arxiv.org/pdf/2004.10934.pdf>.

编辑 吴云芳