

文章编号 1004-924X(2023)22-3383-12

航天器部件的精细分割和稳定跟踪

邵亚东^{1,3,4}, 邵远斌^{2,3,4}, 武奥迪^{2,3,4}, 万雪^{3,4*}

(1. 中国科学院大学 计算机科学与技术学院, 北京 100049;

2. 中国科学院大学 航空宇航学院, 北京 100049;

3. 中国科学院空间应用工程与技术中心, 北京 100094;

4. 中国科学院太空应用重点实验室, 北京 100094)

摘要:为了实现在轨服务过程中对于没有靶标的部件进行操作,需要精细地分割出相关部件,并对其在时序上进行稳定地跟踪。对于部件的精细分割,本文首先基于航天器部件实例分割数据集对实例分割网络 Mask RCNN 进行了训练,然后在其掩膜分割分支上添加一个优化模块对部件分割结果进行优化。对于部件跟踪,本文首先在 Quilt-trihard 损失的基础上提出分层加权五元组损失,然后利用该损失在航天器部件重识别数据集上对有关重识别网络进行训练,最后将得到的重识别网络嵌入 Deep OC SORT 跟踪算法以实现航天器部件的稳定跟踪。实验结果表明:经过掩膜优化后,在部件实例分割测试集上相关实例分割算法的分割精度可提升至 84.90 mAP;使用改进后的损失进行部件重识别,在部件重识别测试集上的识别成功率提高至 76.86%,同时相关跟踪算法在部件跟踪测试集上的跟踪成功率升至 89.38%。因此,本文提出的方法基本可以满足航天器部件的精细分割和稳定跟踪。

关键词:航天器;部件分割;部件跟踪

中图分类号:V19;TP391.4 文献标识码:A doi:10.37188/OPE.20233122.3383

Fine segmentation and stable tracking of spacecraft components

SHAO Yadong^{1,3,4}, SHAO Yuanbin^{2,3,4}, WU Aodi^{2,3,4}, WAN Xue^{3,4*}

(1. School of Computer Science and Technology, University of Chinese Academy of Sciences, Beijing 100049, China;

2. School of Aeronautics and Astronautics, University of Chinese Academy of Sciences, Beijing 100049, China;

3. Technology and Engineering Center for Space Utilization, Chinese Academy of Sciences, Beijing 100094, China;

4. Key Laboratory of Space Utilization, Chinese Academy of Sciences, Beijing 100094, China)

* Corresponding author, E-mail: wanxue@csu.ac.cn

Abstract: In order to realize the operation of components without cooperation markers in on-orbit services, it is necessary to segment the area of the relevant components finely and then track them stably. For the refinement segmentation of components, firstly, the instance segmentation network, Mask RCNN, is trained on the spacecraft component instance segmentation dataset, and secondly a mask refinement mod-

收稿日期:2023-06-14;修订日期:2023-07-12.

基金项目:月面人机共融非合作环境感知理论与技术(No. T203211)

ule is added to its mask segmentation branch to optimize the component segmentation results. As to component tracking, a hierarchical weighted quintuple loss based on the Quit_trihard loss is proposed to train a re-identification network on the component re-identification dataset, and then the re-identification network trained before is embedded into the Deep OC SORT tracking algorithm for stable component tracking. The experimental results show that after mask optimization, the component segmentation accuracy of the relevant instance segmentation algorithm on the component segmentation test set can be improved to 84.90 mAP; by using the improved loss, the identification success rate on the component re-identification test set is improved to 76.86%, and the tracking success rate of the correlation tracking algorithm on the component tracking test set is improved to 89.38%. Therefore, the method proposed in this paper can basically satisfy the fine segmentation and stable tracking of spacecraft components.

Key words: spacecraft; component segmentation; component tracking

1 引 言

自从上世纪人类开启探索太空,开发太空,利用太空的征程后,近地空间的航天器数量不断增加。其中有些航天器由于设备老化,或者遭受严重毁损,失去原有作用。这类航天器本身造价不菲,并且占据着珍稀的不可再生的轨道资源。如果对其开展在轨服务^[1],通过更换部组件进行在轨延寿或者辅助离轨以释放占据的轨道资源,则将产生巨大的经济价值和战略价值。对于一些在轨任务,如对没有靶标的部件进行操作时,需要首先识别出目标部件的区域,然后跟踪该部件,以完成后续的操作。因此在相关的在轨服务中,精确并连续地识别出相关部件,是任务成功的关键和前提,这也是本文着眼要解决的主要问题。近些年来,基于深度学习的计算机视觉技术获得迅猛的发展,在相关任务上已远远领先传统方法。使用基于深度学习的方法解决本文关注的问题,首先需要有一个高精度的航天器部件检测器来获取包含相关部件的区域,然后需要一个稳定的跟踪器在时序帧上进行相关部件的关联。

针对目标检测器,目前的研究主要分为基于目标检测的方法,和基于实例分割的方法。基于目标检测的方法,主要形式是在图像中以一个最小矩形包络标识出相关目标;这种方法对于部件的精细操作,显得较为粗糙。基于实例分割的方法,主要形式是在图像中用不同的实例级像素掩膜表示不同的目标;这种方法和基于目标检测的方法相比精细化程度更高。实例分割方法基本上可以看做是目标检测和语义分割两个任务的

合并^[2],由于该方法是两个任务的合并,那么根据两个任务的先后顺序便可以将实例分割分为先检测后分割的方法(也称为自上向下的方法),先分割后检测的方法(也称为自下向上的方法),以及同时完成两个任务的方法(也称为直接法)。对于自上向下的方法,主要做法是在检测到的目标区域添加语义分割分支来预测目标的像素掩膜;代表方法有在YOLOv3^[3]的基础上发展出来的Poly-YOLO^[4],在Faster-RCNN^[5]的基础上发展来的Mask RCNN^[6]和Cascade Mask RCNN^[7]等。自下向上的方法主要采用像素编码然后通过相似度聚类得到实例的思路,比如SGN^[8]和SSAP^[9]等。直接法目前的技术范式并不统一,有一类方法将图像划分成若干栅格,对落在其中的物体进行类别和掩膜预测,代表方法有在目标检测网络YOLOv1^[10]的基础上发展出来的SOLOv1^[11]和SOLOv2^[12]。根据目前的发展现状,自上向下的方法在精度上基本优于自下向上的方法和直接法,但其依赖于精确的目标检测结果,掩膜分割的细节相对不够精确,速度相对较慢;自下向上的方法容易产生不连续的掩膜,精度较低,往往需要复杂的后处理。为了满足在轨操作的安全性和精确性,仍需对部件实例分割的精度进行提升。

针对目标跟踪器,主要有单目标跟踪和多目标跟踪方法,在研究领域上两者关注的重点不同,比如前者更关注不基于检测的跟踪,主要形式是提前给定一个目标,然后在后续图像上进行跟踪;后者则更多关注基于检测的跟踪,主要是通过检测器给定多个目标,在后续图像上进行跟

踪。为了区分航天器上的多个相似部件(比如双翼帆板),本文采用多目标跟踪方法。多目标跟踪算法目前主要存在两类方法,一是基于运动的方法,二是基于形貌的方法。卡尔曼滤波器是大多数基于运动的方法的基础;这类方法中有代表性的 SORT^[13] 算法,其根据线性运动假说对于目标矩形包络建立预测方程进行预测,通过预测结果和检测结果之间的交并比完成目标指派,并将检测结果作为观测信息来更新运动模型,最后迭代预测完成目标跟踪。当帧率较低且存在遮挡时该方法直接使用预测结果来更新运动模型,这会导致累计误差和跟踪失败。相对于 SORT 以预测为中心的跟踪思路, OC-SORT^[14] 提出以观测为中心的跟踪思路,其更依赖高精度的检测结果来进行运动建模,对于遮挡等非线性运动情况更加鲁棒。基于形貌的方法和基于运动的方法相比,主要是在目标指派时,考虑了目标形貌之间的相似性。具有代表性的 Deep-SORT^[15], Deep-OC-SORT^[16], 都是在原有方法的基础上添加了对目标区域进行特征编码的重识别网络,借助编码特征的相似性来辅助目标指派。由于目标的形貌具有较强的稳定性,因此通过存储重识别网络对跟踪目标的编码特征,可以有效处理目标跟踪短暂失败或者目标在视野中消失后又出现的情况,减少已有目标被指派为新目标的概率,所以在一定程度上重识别可以保证长时序的稳定跟踪。截止到目前, Deep-OC-SORT 在各个跟踪数据集均取得了领先成绩。不过在轨服务过程中,由于复杂的运动和在轨环境,观测到的待服务航天器会发生明显的形貌变化,这对于依赖形貌信息的算法是不利的。因此仍需要对相关算法的重识别模块进行改进,使其具有更强的形貌区分能力。

综上,本文提出了一种航天器部件分割与跟踪算法,旨在实现在轨服务过程中对目标部件的精确分割和稳定跟踪。具体创新点如下:

第一,在实例分割方法 Mask RCNN 的掩膜分支中,添加了一个掩膜优化模块,提高了航天器部件的实例分割精度。

第二,提出了一种考虑时序和部件类别的分层加权五元组损失,在多目标跟踪算法 Deep OC SORT 中提升了重识别网络对实例分割网络输

出目标的形貌区分能力,从而提高了部件的跟踪成功率。

2 基于掩膜优化的航天器部件实例分割

一般的实例分割网络,得到的分割结果比较粗糙,不利于在轨服务过程中针对相关部件的精细操作。本文使用 10 000 张左右的包括主体、帆板和天线三种常见部件的航天器部件数据集(如图 1 所示),对精度较优的 Mask-RCNN 实例分割网络进行训练,实现了对主体、帆板和天线的部件级实例分割;然后在相关实例分割网络的掩膜分支上添加了一个属于 CascadePSP^[17] 网络的掩膜优化模块,对其粗糙的原始掩膜进行优化;最后使用优化后的掩膜作为分割输出结果,以及使用掩膜的最小矩形包络作为输出的检测框(整个方法如图 2 中的部件实例分割模块所示)。



图 1 部分航天器部件实例分割数据集

Fig. 1 Part of the spacecraft component instance segmentation dataset

CascadePSP 网络^[17]是一个与类别无关的掩膜优化网络,它主要是通过复用三次掩膜优化模块(Refinement Module,简记为 RM)来优化分割掩膜;其中掩膜优化模块是一个金字塔网络,其结构如图 3 所示,它接受一个原始图像和三个掩膜作为输入,输出三种下采样分辨率的优化掩膜。在每一次的掩膜优化中, CascadePSP 网络首先对上次输出的若干掩膜进行上采样,并利用其替换掉上次作为输入的相关掩膜;然后将新的掩膜集合连同原始图像作为优化模块新的输入

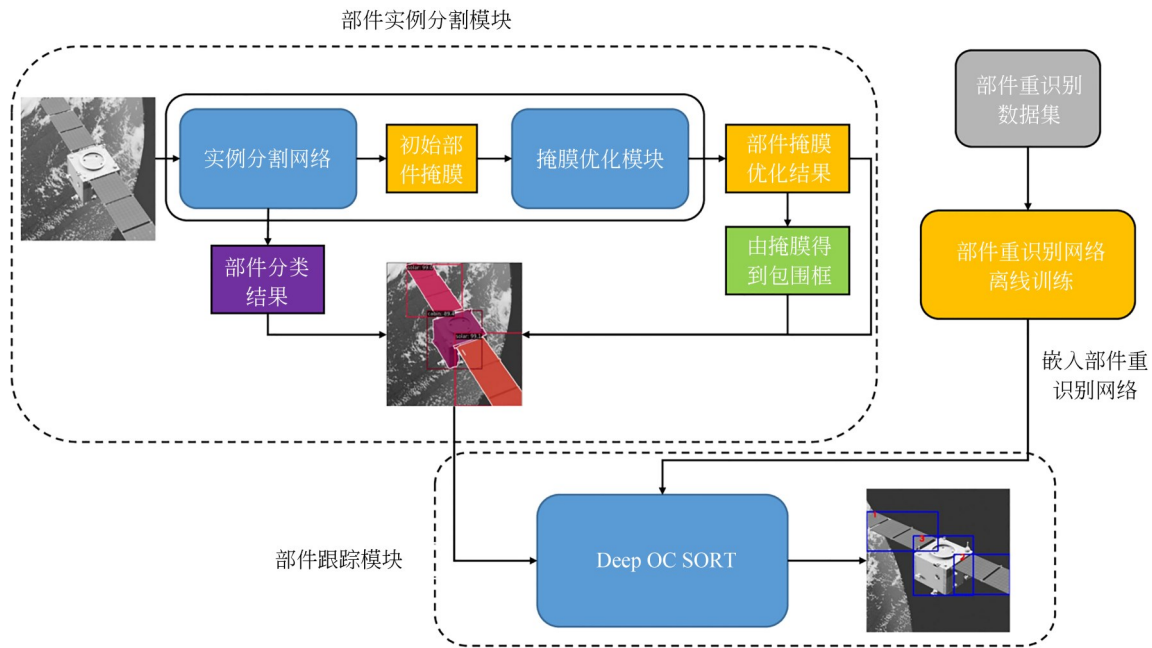


图2 系统总体流程图

Fig. 2 Overall flow chart of the system




图3 掩膜优化模块

Fig. 3 Mask refinement module

进行下一级的级联优化。该网络可以有效提升掩膜分割精度,但是连续三次的优化会导致速度显著下降。由于选用的实例分割网络本身具有一定的精度保障,为了保证一定的时效性,本文只使用了一次掩膜优化模块对初始的部件分割结果进行优化。

3 基于改进损失训练的重识别网络的航天器部件跟踪

在轨服务过程中,目标的部件形貌变化明显,为了区分不同部件并稳定地获得前后关联的

部件,本文使用部件重识别数据集并基于分层加权的五元组损失对重识别网络进行了训练,提高了其对实例分割输出部件的区分能力;之后将训练好的重识别网络嵌入 Deep-OC-SORT 框架,提升了相关部件的连续跟踪能力(方法如图2中的部件跟踪模块所示)。

Quit_trihard^[18]损失的主要思想是通过选择多个正例和一个(或若干个)负例,让锚和正例在编码空间内的距离尽可能的小,锚和负例之间的距离尽可能的大,以实现区分的目的。当选择两个正例时和一个难的负例时,其形式化描述如公式(1)所示:

$$L = h\left(\left\|g^{(a)} - g^{(p1)}\right\|_2 - \left\|g^{(a)} - g^{(n1)}\right\|_2 + \alpha\right) + h\left(\left\|g^{(a)} - g^{(p2)}\right\|_2 - \left\|g^{(a)} - g^{(n1)}\right\|_2 + \alpha\right), \quad (1)$$

其中: $h(x) = \max(x, 0)$, $g^{(a)}$ 为锚图像在编码空间的编码向量, $g^{(p1)}$ 为正例图像1在编码空间的编码向量, $g^{(p2)}$ 为正例图像2在编码空间的编码向量, $g^{(n1)}$ 为不易区分的较难的负例在编码空间的编码向量,这三个样本与锚图像之间的编码距离需满足 $\left\|g^{(a)} - g^{(p1)}\right\|_2 < \left\|g^{(a)} - g^{(p2)}\right\|_2 <$

$\|g^{(a)} - g^{(n1)}\|_2$; α 为一正则项,表示负例和锚之间的编码距离应至少大于 α ,为了方便起见后续实验将该值取作 0。

结合航天器部件重识别任务,本文提出的分层加权五元组损失,将正例区分为时序较近的同部件正例和时序较远的同部件正例,将负例区分为同类部件负例和不同类部件负例两种,并对不同的正例和负例使用不同的权重;其形式化描述如公式(2)所示,示意如图 4。

$$L = h\left(\|g^{(a)} - g^{(p1)}\|_2 - \eta\|g^{(a)} - g^{(n1)}\|_2 + \alpha\right) + h\left(\mu\|g^{(a)} - g^{(p2)}\|_2 - \|g^{(a)} - g^{(n2)}\|_2 + \alpha\right), \quad (2)$$

其中: η 为同类部件负例和锚图像编码距离的权重, μ 为时序较远的同部件正例和锚图像编码距离的权重,两者需大于 1,后续实验均取值为 2;同时这四个样本与锚图像之间的编码距离需满足 $\|g^{(a)} - g^{(p1)}\|_2 < \|g^{(a)} - g^{(p2)}\|_2 < \|g^{(a)} - g^{(n1)}\|_2 < \|g^{(a)} - g^{(n2)}\|_2$, α 和 $h(x)$ 与其在公式(1)中的含义和取值相同。

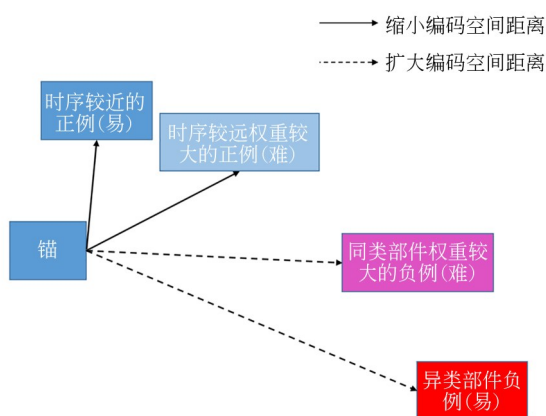


图 4 分层加权五元组损失

Fig. 4 Hierarchical weighted quintuple loss

使用改进的分层加权五元组损失训练重识别网络,前提是要获得分层次的部件重识别数据集(示意如图 5)。具体做法是,首先对章节 2 里面提到的数据集中包含航天器部件的图像区域进行剪裁,然后将同一个部件的数据进行聚类,再将同种类部件的数据按照太阳能帆板、主体和天线进行第二次聚类。

在训练过程中,首先选定数据集中一个图像




图 5 部分部件重识别数据集

Fig. 5 Part of the component re-identification dataset

作为锚,接着分别加载和锚属于同一部件的时序不同的图像作为正例,和锚同一类的其他部件图像作为同类负例,和锚不同类的其他部件图像作为异类负例;然后将五幅图像输入重识别网络获得对应维度的编码向量,并在编码空间分别计算锚向量和其他向量的编码距离;最后将相关编码距离代入公式(2)计算损失,并通过梯度反传算法更新网络中的参数。

4 实验结果与分析

实验在 Ubuntu18.04 操作系统上进行训练和测试,CPU 使用 16 核的 Intel(R)Core(TM) i9-9900K@3.60 GHz,显卡使用 Nvidia GeForce RTX 2080 Ti,深度学习框架为 Pytorch2.0.1。部件实例分割的训练数据在前文中已经进行了介绍;其测试图像是通过 Blender 仿真引擎对一个双翼卫星模型进行绕飞和直线逼近得到的,共计 400 张,示意图如图 6。部件重识别的训练和测试数据由文中方法获得,跟踪算法的测试数据和实例分割的测试数据一致。其中训练数据和测试数据之间不存在数据泄漏,下文的实验结果

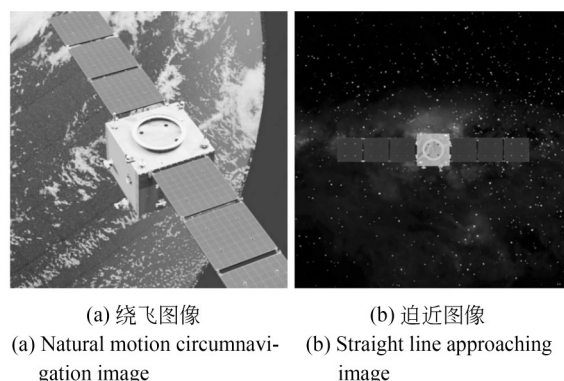


图 6 分割和跟踪测试集示意

Fig. 6 Schematic representation of segmentation test set and tracking test set

是通过多次实验求平均得到的。

4.1 基于掩膜优化的航天器部件实例分割

为了验证基于掩膜优化的实例分割算法的有效性,我们在目标检测平台 mmdetection 下选取了比较经典的 Mask RCNN^[6],Cacade Mask RCNN^[7],SOLOv2^[12],YOLACT^[19]和 Spar-

seInst^[21]网络模型,在航天器部件数据集上进行训练和验证;之后选用最优的模型,添加掩膜优化模块对测试集上置信度大于 0.8 的初始分割结果进行优化(太阳能帆板的分割优化示意如图 7,主体的分割优化示意如图 8)。

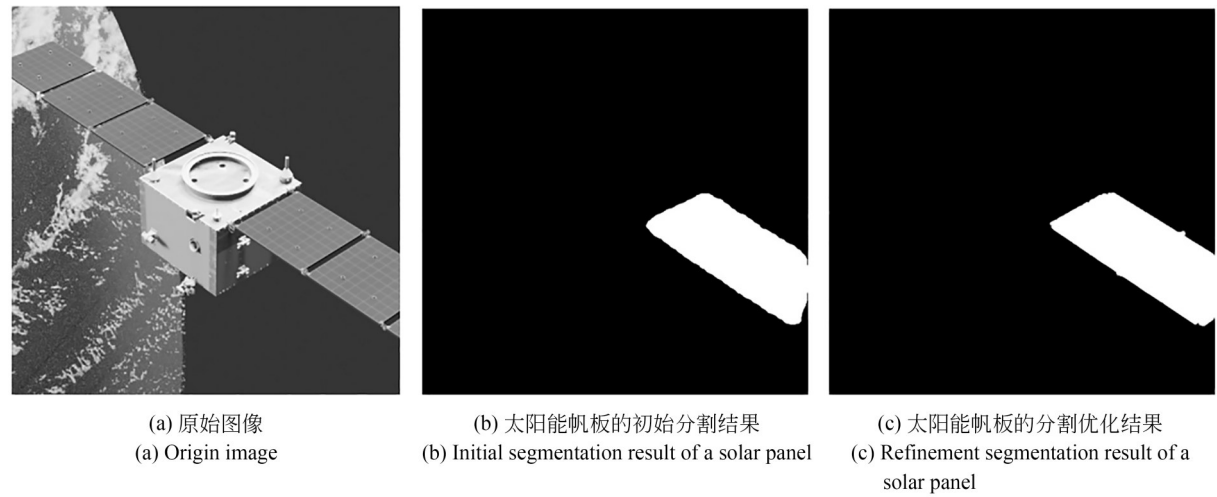


图 7 太阳能帆板的分割优化示意
Fig. 7 Segmentation refinement of a solar panel

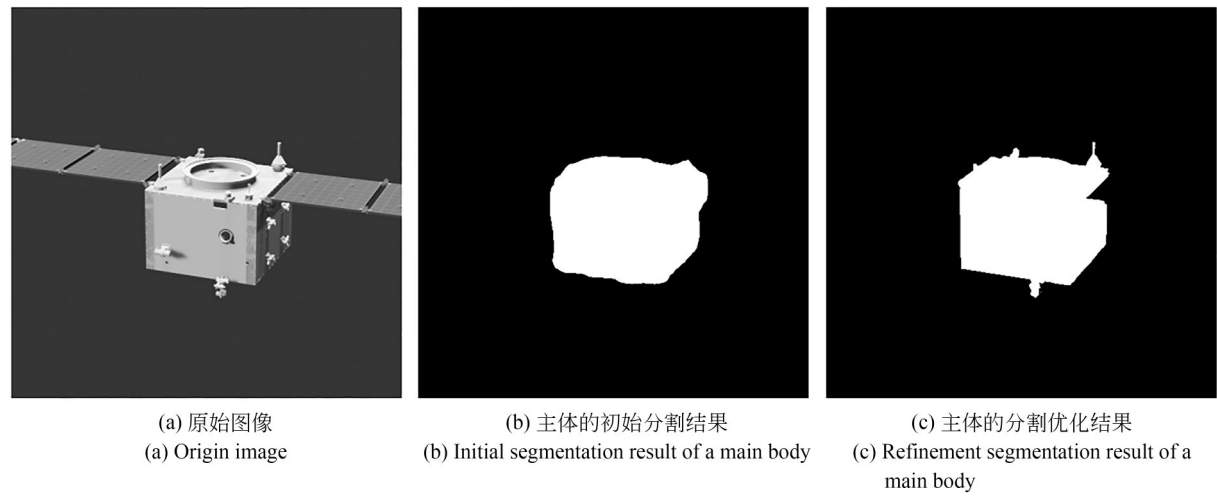


图 8 主体的分割优化示意
Fig. 8 Segmentation refinement of a main body

在训练时,所有网络模型训练的样本批量大小为 2,具体的迭代次数为 6 万到 27 万不等。各网络的训练损失曲线如图 9,从图中可以看出经过相应的迭代次数的训练后各算法基本收敛。

在测试时,具体的实例分割精度采用 mmdetection 实现的 segm_mAP 指标,速度采用每秒处

理帧数(FPS)的指标,相关实验结果如表 1 所示。其中 segm_mAP 是多个类别的平均精度的平均,结合部件实例分割其具体定义如下:

第一步,对于某类部件的平均精度 segm_mAP,首先选定一系列的掩膜交并比阈值,然后在每个掩膜交并比阈值下把和真值超过掩膜阈值

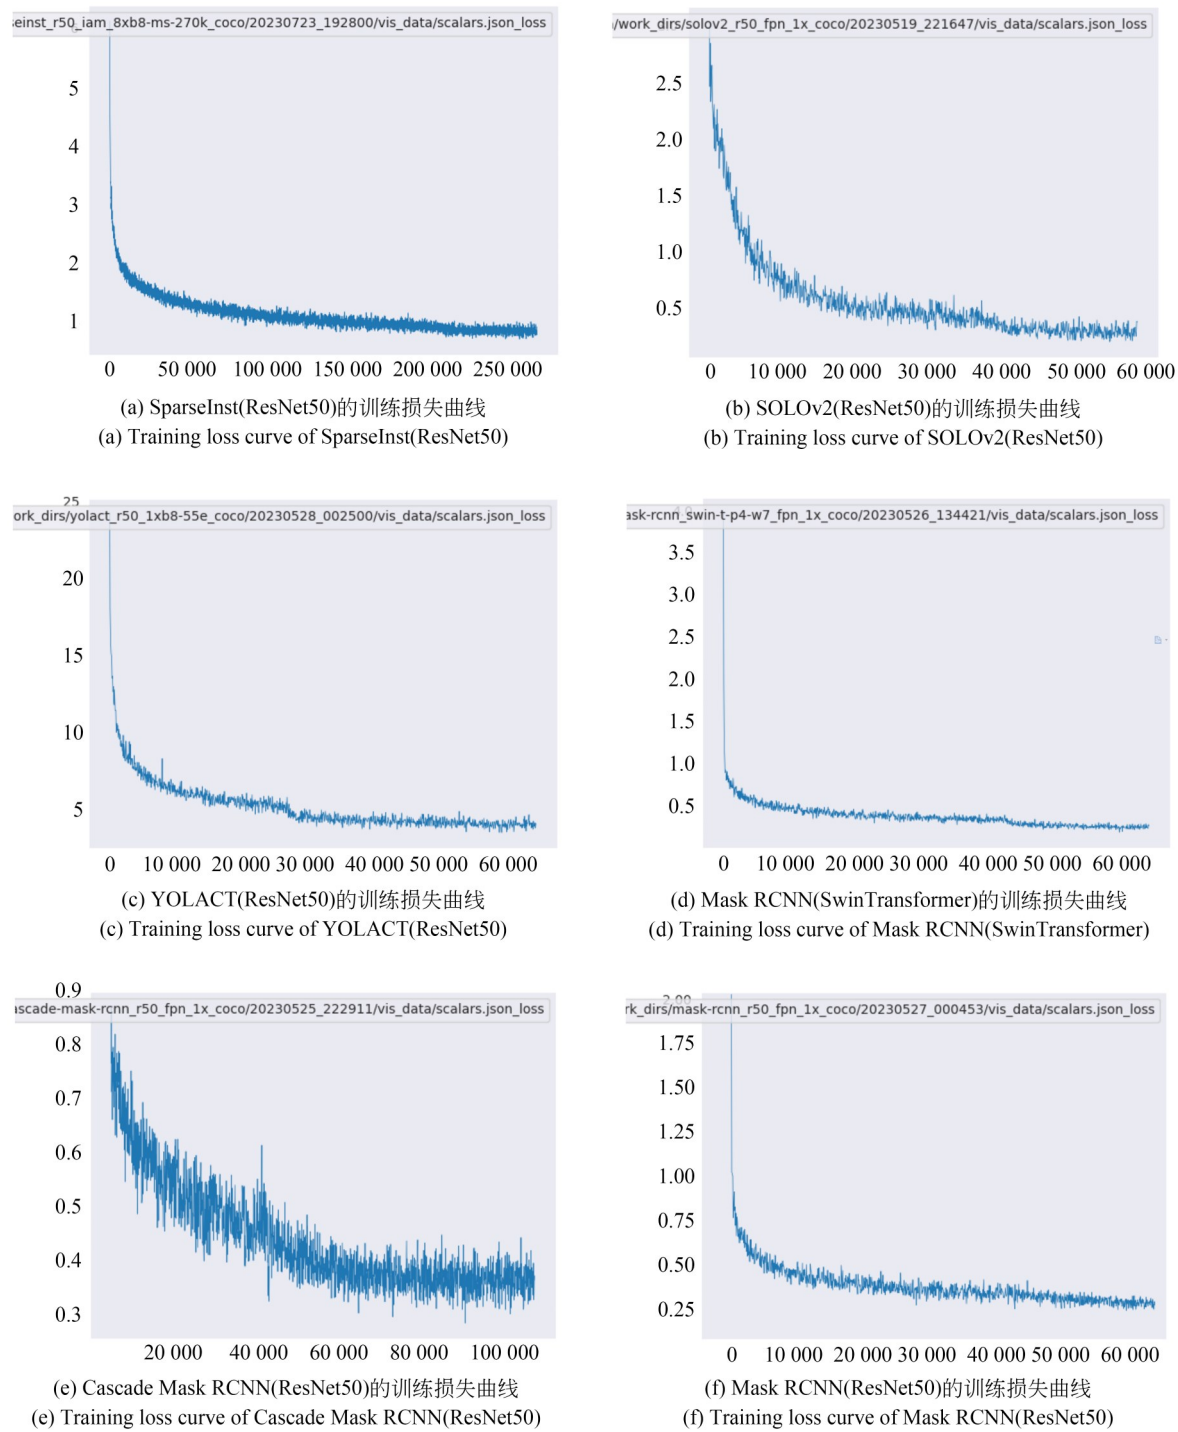


图 9 各网络的训练损失曲线
Fig. 9 Training loss curves for each network

的实例分割结果按置信度进行排序；

第二步,对于每一个排好序的队列,再选定若干置信度阈值,对于每个置信度阈值,把超过交并比阈值和置信度阈值的实例分割结果当做真阳性样本,不满足的和重复出现的以及类别预测错的结果则当做假阳性样本,对于没有预测到的真值则作为假阴性样本;由此可以计算某类部件某交并比阈值下的精度(Precision)和召回率(Recall)曲线下面积(越接近于1越优);

第三步,将某类部件每一个掩膜交并比阈值下的精度和召回率曲线下面积进行平均得到 segm_AP;

第四步,将每一类的 segm_AP 进行平均得到最终的所有部件类的 segm_mAP。

表 1 中的 segm_mAP_50:5:95 指的是掩膜交并比阈值取 0.5 到 0.95 间隔 0.05 的 10 个数, segm_mAP_75 指的是掩膜交并比阈值取 0.75, segm_mAP_s 则指的是选择那些像素数量小于一定阈值的小目标进行评价。

表 1 分割测试集上航天器部件实例分割性能

Tab. 1 Result of spacecraft component instance segmentation accuracy on segmentation test set

网络模型	主干网络	Segm_mAP/%			速度/ FPS
		Segm_mAP_50:5:95	Segm_mAP_75	Segm_mAP_s	
SparseInst	ResNet50 ^[20]	57.60	69.00	61.20	23.12
SparseInst+RM	ResNet50	60.60	69.30	64.20	2.82
SOLOv2	ResNet50	76.60	90.80	81.30	17.38
SOLOv2+RM	ResNet50	78.10	90.80	82.50	5.62
YOLACT	ResNet50	78.80	93.90	81.70	34.13
YOLACT+RM	ResNet50	82.90	94.00	85.60	2.07
Mask RCNN	SwinTransformer ^[22]	79.90	91.50	93.70	17.65
Mask RCNN+RM	SwinTransformer	83.60	92.30	87.70	1.07
Cascade Mask RCNN	ResNet50	80.20	91.80	85.00	16.89
Cascade Mask RCNN+RM	ResNet50	82.00	93.00	86.90	1.25
Mask RCNN	ResNet50	81.80	93.90	84.60	20.55
Mask RCNN+RM	ResNet50	84.90	96.20	87.80	1.54

注:网络模型里面的“+RM”指的是在原有的方法上添加掩膜优化模块进行分割优化

基于表 1 的实验数据,可以看出各个实例分割算法在不添加掩膜优化模块时,Mask RCNN 取得 81.80mAP 的最高实例分割精度;在添加掩膜优化模块后各实例分割算法的精度均获得提升,提升幅度在 1.50mAP 至 4.10mAP,其中对应的 Mask RCNN 方法亦取得了 84.90mAP 的最高实例分割精度。在速度上,添加优化模块后,各网络的速度均有明显下降,但总体上各个方法均可以提供 1 FPS 以上的运行速度。速度的明显下降是因为计算量的大幅度增加;具体原因包括掩膜优化模块的输入为四张图片(一张原始图像和三张初始掩膜),该模块自身是一个计算量偏高的金字塔网络,并且每一个置信度超过 0.8 的部件识别结果都会进行一次优化。从表 1 中还可以看出,添加掩膜优化模块后各方法速度的下降程度不同,比如 SOLOv2 的速度下降幅度明显小

于其他方法。这是由于不同实例分割网络的对结果的置信情况不一致,因而它们对于同一批图像会进行不同次数的优化。

4.2 基于分层加权五元组损失的部件重识别和跟踪

为了验证使用分层加权五元组损失的有效性,分别使用 Triplet^[23] 损失、Quit_Trihard^[18] 损失、不加权的分层五元组损失以及本文提出的分层加权五元组损失对一个 21 层的重识别网络进行训练。所有网络模型训练时,样本的批量大小为 32,一共进行了 1600 余次的迭代计算。使用各损失函数的网络损失曲线如图 10,从图中看出经过相应迭代次数的训练后,网络的损失基本收敛。

在部件重识别测试集上进行测试时,每次加载一个图片作为锚,加载一个相同部件的图片作为正例,加载 31 个其他部件的负例,分别计算图

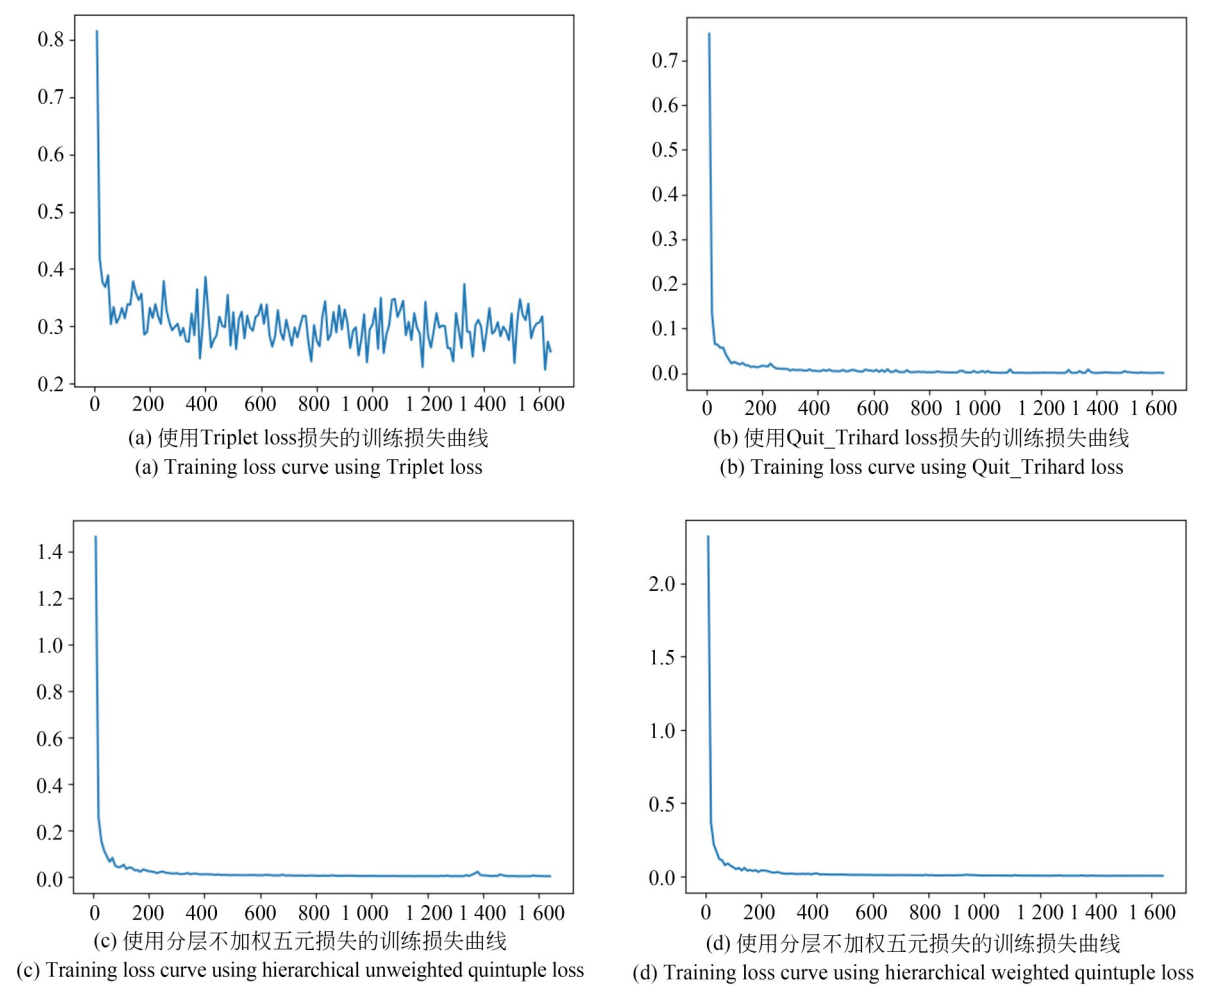


图 10 使用各损失函数的训练损失曲线
Fig. 10 Training loss curves using each loss function

像相似度;当正例和错的相似度高于所有的负例时,认为这一次判别成功,最终统计各方法最优

训练结果的识别成功比例作为部件识别成功率(如表 2 所示)。

表 2 部件识别测试集上的部件识别成功率	
Tab. 2 Component identification success rate on component identification test set	
方法	识别成功率/%
基于 Triplet 损失训练的部件重识别网络	69.95
基于 Quit_Trihard 损失训练的部件重识别网络	71.05
基于分层不加权五元组损失训练的部件重识别网络	75.44
基于分层加权五元组损失训练的部件重识别网络	76.86

为了进一步验证使用分层加权五元组损失用于多目标跟踪的有效性,分别将以上损失函数训练得到的最优部件重识别网络嵌入 Deep-OC-SORT 多目标跟踪算法;然后使用精度最优的部件实例分割网络 Mask RCNN+RM 提供置信度高于 0.9 的检测目标并进行跟踪(短时序的跟踪结果如图 11,长时序的跟踪结果如图 12);最后统计有关部件被分配至同一 ID(Identity)的次数占




图 11 短时序的部件跟踪结果

Fig. 11 Component tracking results for short timings




图 12 长时序的部件跟踪结果

Fig. 12 Component tracking results for long timings

总共检测结果的比例作为跟踪成功率(如表 3 所示)。

根据表 2 和表 3,可以发现使用分层加权五元组损失训练的部件重识别网络对于相同部件的识别成功率较高;并且使用该重识别网络进行多部件跟踪时,其跟踪成功率也较高。此

外,从图 11 和图 12 可以看出,本文方法除了在短期内可以提供稳定的部件跟踪;在长期跟踪过程中,即使由于极端情况(帆板成为一条线)而导致相应的部件出现跟踪丢失,随着后续观测条件的好转,该算法也可以继续稳定地跟踪。

表 3 跟踪测试集上的部件跟踪成功率

Tab. 3 Component tracking success rate on tracking test set

方法	跟踪成功率/%
基于 Triplet 损失训练的部件重识别网络进行跟踪	85.34
基于 Quit_Trihard 损失训练的部件重识别网络进行跟踪	86.73
基于分层不加权五元组损失训练的部件重识别网络进行跟踪	78.57
基于分层加权五元组损失训练的部件重识别网络进行跟踪	89.38

4.3 系统整体运行速度

根据前文的实验结果,本文选取实例分割精度最优 Mask RCNN+RM 作为实例分割方法,将分层加权五元组损失训练的部件重识别网络嵌入 Deep OC SORT 进行多部件跟踪,统计在测试数据上各模块及系统整体运行速度如表 4 所示。

从表 4 中可以看出,该系统整体上可以提供

大于 1 FPS 的运行速度,不过其速度受制于实例分割模块。

5 结 论

针对空间在轨服务过程中航天器部件的精细分割和稳定跟踪问题,本文通过对实例分割网络 Mask RCNN 的分割分支添加掩膜优化模块,在测试数据上将部件分割精度提高至 84.90 mAP;通过使用区分时序远近正例和同类异类负例的分层加权五元组损失对部件重识别网络进行训练,在测试集上将部件跟踪的成功率提升至 89.38%。下一步将通过知识蒸馏方法将掩膜优化模块的功能蒸馏至一个轻量级的实时网络,以实现提高部件分割精度的同时保证较高的运行速度。

表 4 算法运行速度

Tab. 4 Algorithm running speed

模块	速度/FPS
Mask RCNN+RM	1.54
Deep OC SORT	202.56
系统整体	1.53

参考文献:

[1] FLORESABAD A, MA O, PHAM K, *et al.* A

review of space robotics technologies for on-orbit servicing [J]. *Progress in Aerospace Sciences*, 2014,

- 68: 1-26.
- [2] 苏丽, 孙雨鑫, 苑守正. 基于深度学习的实例分割研究综述[J]. 智能系统学报, 2022, 17(1): 16-31.
SU L, SUN Y X, YUAN S Z. A survey of instance segmentation research based on deep learning [J]. *CAAI Transactions on Intelligent Systems*, 2022, 17(1): 16-31. (in Chinese)
 - [3] REDMON J, FARHADI A. YOLOv3: an incremental improvement [J]. *arXiv preprint arXiv: 1804.02767*, 2018.
 - [4] HURTIK P, MOLEK V, HULA J, *et al.* Poly-YOLO: higher speed, more precise detection and instance segmentation for YOLOv3[J]. *Neural Computing and Applications*, 2022, 34 (10) : 8275-8290.
 - [5] 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.
 - [6] HE K M, GKIOXARI G, DOLLÁR P, *et al.* Mask R-CNN [C]. 2017 *IEEE International Conference on Computer Vision (ICCV)*. 22-29, 2017, Venice, Italy. IEEE, 2017: 2980-2988.
 - [7] CAI Z W, VASCONCELOS N. Cascade R-CNN: high quality object detection and instance segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(5): 1483-1498.
 - [8] LIU S, JIA J Y, FIDLER S, *et al.* SGN: sequential grouping networks for instance segmentation [C]. 2017 *IEEE International Conference on Computer Vision (ICCV)*. 22-29, 2017, Venice, Italy. IEEE, 2017: 3516-3524.
 - [9] GAO N Y, SHAN Y H, WANG Y P, *et al.* SSAP: single-shot instance segmentation with affinity pyramid [C]. 2019 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 27-November 2, 2019, Seoul, Korea (South). IEEE, 2020: 642-651.
 - [10] REDMON J, DIVVALA S, GIRSHICK R, *et al.* You only look once: unified, real-time object detection [C]. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 779-788.
 - [11] WANG X L, KONG T, SHEN C H, *et al.* SO-LO: segmenting objects by locations [C]. *Computer Vision-ECCV 2020: 16th European Conference, Glasgow, UK*, 23-28, 2020, *Proceedings, Part XVIII*. New York: ACM, 2020: 649-665.
 - [12] WANG X, ZHANG R, KONG T, *et al.* SO-LOv2: Dynamic and Fast Instance Segmentation [EB/OL]. 2020; *arXiv*: 2003.10152. <https://arxiv.org/abs/2003.10152.pdf>
 - [13] BEWLEY A, GE Z Y, OTT L, *et al.* Simple online and realtime tracking [C]. 2016 *IEEE International Conference on Image Processing (ICIP)*. 25-28, 2016, Phoenix, AZ, USA. IEEE, 2016: 3464-3468.
 - [14] CAO J K, PANG J M, WENG X S, *et al.* Observation-centric SORT: rethinking sort for robust multi-object tracking [C]. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 17-24, 2023, Vancouver, BC, Canada. IEEE, 2023: 9686-9696.
 - [15] WOJKE N, BEWLEY A, PAULUS D. Simple online and realtime tracking with a deep association metric [C]. 2017 *IEEE International Conference on Image Processing (ICIP)*. 17-20, 2017, Beijing, China. IEEE, 2018: 3645-3649.
 - [16] MAGGIOLINO G, AHMAD A, CAO J K, *et al.* Deep OC-Sort: multi-pedestrian tracking by adaptive re-identification [C]. 2023 *IEEE International Conference on Image Processing (ICIP)*. 8-11, 2023, Kuala Lumpur, Malaysia. IEEE, 2023: 3025-3029.
 - [17] CHENG H K, CHUNG J, TAI Y W, *et al.* CascadePSP: toward class-agnostic and very high-resolution segmentation via global and local refinement [C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 8887-8896.
 - [18] ZHAI Q, HUANG R, CHENG H, *et al.* Learning quintuplet loss for large-scale visual geolocalization [J]. *IEEE MultiMedia*, 2020, 27(3): 34-43.
 - [19] BOLYA D, ZHOU C, XIAO F Y, *et al.* YOLACT: Real-Time instance segmentation [C]. 2019 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 27-November 2, 2019, Seoul, Korea (South). IEEE, 2020: 9156-9165.
 - [20] HE K M, ZHANG X Y, REN S Q, *et al.* Deep

- residual learning for image recognition [C]. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 770-778.
- [21] CHENG T H, WANG X G, CHEN S Y, *et al.* Sparse instance activation for real-time instance segmentation [C]. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 18-24, 2022, New Orleans, LA, USA. IEEE, 2022: 4423-4432.
- [22] LIU Z, LIN Y T, CAO Y, *et al.* Swin Transformer: hierarchical vision transformer using shifted windows [C]. 2021 *IEEE/CVF International Conference on Computer Vision (ICCV)*. 10-17, 2021, Montreal, QC, Canada. IEEE, 2022: 9992-10002.
- [23] SCHROFF F, KALENICHENKO D, PHILBIN J. FaceNet: a unified embedding for face recognition and clustering [C]. 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 7-12, 2015, Boston, MA, USA. IEEE, 2015: 815-823.

作者简介:



邵亚东(1994—),男,河南汝州人,博士研究生,2018年于北京化工大学获得学士学位,并于同年至今就读于中国科学院大学计算机科学与技术学院,主要从事针对空间非合作目标在轨服务领域内的计算机视觉方面的研究。E-mail: shaoyadong18@csu.ac.cn

通讯作者:



万雪(1988—),女,湖北武汉人,博士,研究员,博士生导师,分别于2010年、2012年在武汉大学获得学士、硕士学位,2015年在帝国理工学院获得博士学位,主要从事针对空间非合作目标在轨服务、行星探索等领域内的计算机视觉方面的研究。
E-mail: wanxue@csu.ac.cn