

非合作目标局部特征识别轻量化特征融合网络设计

徐云飞¹, 张笃周^{2*}, 王立¹, 华宝成¹

- (1. 北京控制工程研究所 空间光电测量与感知实验室, 北京 100190;
2. 中国空间技术研究院, 北京 100094)

摘要: 给出一种基于轻量化卷积神经网络的空间非合作目标局部特征检测网络, 即 NCDN 模型。在 SSD 模型中引入特征融合策略以适应不同距离下的检测需求, 提高模型对图像尺度变换引起局部特征分辨率降低的鲁棒性; 并采用不同压缩比例对 MobileNetV2 内部卷积通道数量做压缩, 从而得到轻量化特征提取网络; 对 SPEED 数据集进行局部特征标注与训练以验证 NCDN 适用的距离范围。实验结果表明, 该模型能够在 45 m 内距离范围保证 mAP 达到 0.90, 同时通道压缩节省 75% 计算量后模型精度损失仅为 5%。满足在轨检测精度和计算量需求。

关键词: 卷积神经网络; 空间非合作目标; 轻量化; 特征融合

中图分类号: TP991 **文献标志码:** A **DOI:** 10.3788/IRLA20200170

Lightweight feature fusion network design for local feature recognition of non-cooperative target

Xu Yunfei¹, Zhang Duzhou^{2*}, Wang Li¹, Hua Baocheng¹

- (1. The Lab of Space Optoelectronic Measurement & Perception, Beijing Institute of Control Engineering, Beijing 100190, China;
2. China Academy of Space Technology, Beijing 100094, China)

Abstract: The Non-cooperative Detection Network(NCDN) model is a kind of local feature detection network based on lightweight convolution neural network. In SSD model, the feature fusion strategy was introduced to meet the detection requirements at different distances, and the robustness of the model to the reduction of local feature resolution caused by image scale transformation was improved; the number of convolution channels in mobilenetv2 was compressed with different compression ratios to obtain lightweight feature extraction network; local feature labeling and training of speed data were set to verify the applicable distance range of NCDN. The experimental results show that the mAP of the model can reach 0.90 within 45 m, and the accuracy loss of the model is only 5% after saving 75% of the calculation amount in channel compression. It meets the requirements of on orbit detection accuracy and calculation amount.

Key words: convolutional neural network; space non-cooperative target; lightweight; feature fusion

收稿日期:2020-03-06; 修订日期:2020-04-07

基金项目:“十三五”装备预研共用技术和领域基金项目(复杂光场景下非合作目标高可靠识别技术 41412070204)

作者简介:徐云飞(1994-),男,硕士生,主要研究方向为模式识别与智能系统。Email:xyf940915@sina.com

通讯作者:张笃周(1966-),男,研究员,主要研究方向为导航制导与控制,卫星姿态控制系统设计。Email:zhangduzhou@spacechina.com

0 引言

在轨服务和空间攻防是未来航天重要发展方向,而目标的局部特征识别是关键技术之一。非合作目标上没有配合测量的光标、角反射器等设施,且目标的形状、局部特征各异,成像特性易受到空间光照条件变化的影响。这给目标识别以及进一步的抵近、绕飞、测量、捕获带来了巨大的挑战。

在空间对抗与在轨服务领域中,需要对非合作目标整星、帆板、支架、喷管、对接环等局部特征进行识别检测,从而触发对应捕获的渔网、鱼叉、飞爪、加注管等相应部件,或完成相关跟踪测量。欧空局“清除碎片”(RemoveDebris)项目成功试验渔网对立方星的抓捕,并开展鱼叉、飞爪、拖曳帆、运动跟踪技术验证。德国宇航局开展的“实验服务卫星”(Experimental Serving Satellite, ESS)项目^[1],通过卫星机械臂上搭载的立体摄像机对目标卫星上的发动机喷管进行成像识别。美国的 FRENDS 机械臂上的立体视觉系统能够对分离螺栓孔和星箭对接环进行识别和抓捕^[2]。传统基于点线、边沿特征^[3],圆形特征^[4],以及关键点提取匹配^[5]的方法用以识别帆板支架、卫星对接环和天线等局部特征。然而传统方法通过人工设计特征,难以适用于各类空间条件。且目标卫星上的天线、帆板、对接环、喷管以及各类传感器会随着其位姿和所受光照条件的变化发生成像模糊,局部遮挡,尺度变化,以及出现阴影等情况。传统方法应对这类问题时,难以持续稳定地发挥其作用,还需将图片下载到地面,由操作人员来对非合作目标上局部特征进行识别标注,花费大量的人力且“自主性”不高。针对上述问题,基于卷积神经网络的空间非合作目标局部特征识别方法成为新的研究热点,使用 RCNN、YOLO 系列网络对非合作目标整星、天线、帆板、支架、对接环、喷管等典型局部特征进行检测或语义分割^[6-8],以及基于卷积神经网络的非合作目标相对姿态测量^[9-11]。近些年基于卷积神经网络的目标检测模型主要包含和 SSD 系列。且相比而言 SSD 能够兼顾检测精度和检测时间,为在轨应用提供可能。

文中设计一种轻量化特征融合网络 (Non-cooperative Detection Network, NCDN)。构建 SSD 时引入特征融合策略,融合不同卷积层之间细节特征和

语义信息,以适应局部特征尺度变换并提高微小部件的检测精度。同时对特征提取网络 MobileNetV2 进行轻量化改进。通过通道压缩减少模型计算量和参数量的冗余。并在非合作目标公开数据集 SPEED 上进行验证。

1 非合作目标局部特征检测框架

文中设计 NCDN 思路如图 1 所示。整体架构为 SSD 目标检测模型,并以 MobileNetV2 作为特征提取网络。在 SSD 模型中引入了特征融合策略,将 MobileNetV2 中多个卷积层提取的特征进行融合,同时在模型新加的 Conv1-Conv5 中的两层采取同样的方式融合,使得模型对不同尺度目标具有适应性。此外为减少模型计算量,设计网络轻量化方法,压缩卷积通道以减少特征提取网络 MobileNetV2 中冗余的参数。并对 SPEED 数据集中非合作目标 Tango 局部特征进行检测。

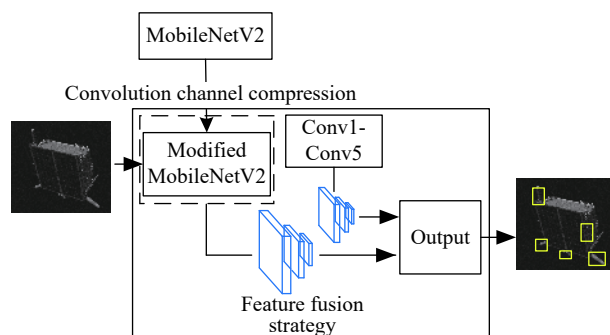


图 1 NCDN 设计思路

Fig.1 Design idea of NCDN

1.1 SSD 结构设计与特征融合策略

本文设计的 SSD 网络引入特征融合策略 (Feature Fusion)。基础网络采用 MobileNetV2 中 2 个卷积层 7 个 Bottleneck 结构,共 19 层。并在其基础上添加 8 个卷积层 Conv2-Conv5,其中每层包含 2 个小层 (Conv_X_1, Conv_X_2)。由于模型对于目标尺度变化较为敏感,不利于检测尺微小目标,因此借鉴 FPN^[12]、FSSD^[13]和 FE-SSD^[14]思想引入特征融合策略,将 Bottleneck₄_4, Bottleneck₅_3,和 Bottleneck₇_1 的输出特征进行融合,并将 Conv_X_1 与 Conv_X_2 之间特征进行融合。因为卷积网络在提取图像特征时,随着卷积层变深,提取的语义信息也更为丰富。然而传统 SSD 模型中这些卷积层之间相互独立,直接从各层特

征图中输出检测结果,使得局部细节特征和全局语义特征无法相融合,进而难以检测尺度微小的局部特征。因此特征融合策略可以让低层高分辨率特征图共享高层提取的丰富语义信息以提高检测精度。

以卷积层 Bottleneck4_4, Bottleneck5_3,和 Bottleneck7_1 为例,特征融合策略如下:

(1) 以 Bottleneck4_4 输出通道数64基准,通过通过 1×1 卷积将 Bottleneck5_3,和 Bottleneck7_1 输出通道同降为 64;

(2) 以 Bottleneck4_4 特征图尺寸为 64×64 基准,通过BilinearInterp.(BI)将Bottleneck5_3,和Bottleneck7_1 输出特征图尺寸升为 64×64 ;

(3) 采用 Concatenation (Concat) 融合方式,将 3 个同维度特征图融合。并通过 BatchNormal 和 Relu 处理后融合成尺度为 $64 \times 64 \times 320$ 的新特征图。

ConvX_1 与 ConvX_2(X=2,3) 采用同样的融合策略, ConvX_2 为 ConvX_1 基础上添加 3×3 卷积得到。由于特征图尺寸过小导致特征融合中携带的信息不足,因此最后 2 层 Conv4, Conv5 不进行融合,直接从 ConvX_2(X=4,5) 中生成特征图。如图 2 所示。

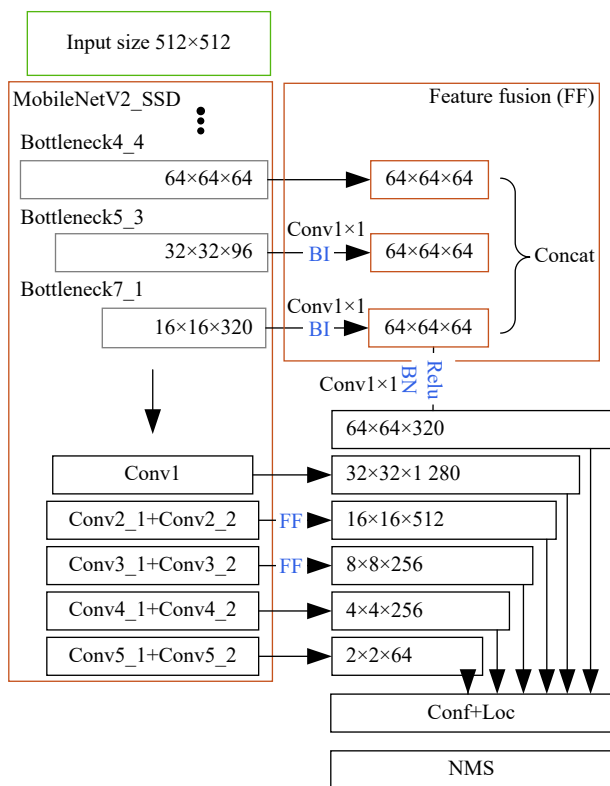


图 2 基于特征融合的 SSD 框架

Fig.2 SSD framework based on feature fusion

多尺度融合特征图最终送入类别预测和经过默认框结构回归得到的位置坐标预测。并通过非极大值抑制算法 (Non-maximum Suppression, NMS) 得到最终目标检测结果。模型损失函数包括类别损失和位置损失:

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*)$$

式中: p_i, p_i^* 为类别真值和预测类别; t_i, t_i^* 为位置真值和预测位置; L_{cls} 为类别损失 Softmax 交叉熵函数; L_{reg} 为位置损失 SmoothL1 函数; N_{cls} 为类别总数 λ 为权重系数。

1.2 基于通道压缩的 MobileNetV2 改进方法

基于轻量化特征提取网络的 NCDN 采用 MobileNetV2 作为基干。在检测精度上已经能够满足空间非合作目标局部特征检测任务,但训练后的模型存储空间仍有 19M, 难以满足星上存储空间需求。考虑到非合作目标局部特征类别数量不多于 10 种, 远少于公开数据集所一般要求的 1 000+种, 从而认为特征提取网络 MobileNetV2 内部卷积参数有大量冗余。因此, 文中提出基于通道压缩的 MobileNetV2 改进方法, 压缩卷积层之间的通道数量, 在不过分牺牲检测精度前提下, 摒弃冗余参数以换取存储空间的进一步优化。

MobileNet 在模型结构上采用了逐通道 (Depth-wise, DW) 卷积搭配逐点 (Point-wise, PW) 卷积的方式来提特征, 这两个操作结合成为深度可分离卷积结构 (Depth-wise Separable Convolution)。如图 3 所示: M, N 分别为输入、输出特征通道数, D_K, D_F 分别为卷积核、特征图尺寸。这种结构可以成倍地减少卷积层的时间复杂度和空间复杂度。

MobileNet 已经极大地减小了计算量, 然而对于空间非合作目标局部特征检测任务而言, 参数量上仍有冗余。通过在结构中对所有卷积层中卷积核数量乘以缩小因子 α (其中 $\alpha \in (0, 1)$) 以压缩网络。并以此通道压缩方法改进图 3(b) 结构。

通道压缩后深度方向卷积计算量:

用图 3 中的图 3(b)+(c) 代替图 3(a), 假设有 N 个卷积核, 每个卷积核维度是 $D_K \times D_K \times \alpha M$, 输入特征图的通道数是 αM , 输出特征图维度 $D_F' \times D_F' \times N$ 。则图 3(b) 表示用 αM 个维度为 $D_K \times D_K \times 1$ 的卷积核去卷积对应输入的特征图, 然后得到 αM 个结果, 且相互之




图 3 MobileNet-Depthwise/Pointwise 卷积结构

Fig.3 Convolutional architecture of MobileNet Depthwise/Pointwise

间不累加。因此计算量是 $D_F \times D_F \times D_K \times D_K \times \alpha M$ ，比压缩前节省 α 倍。如图 4 所示。

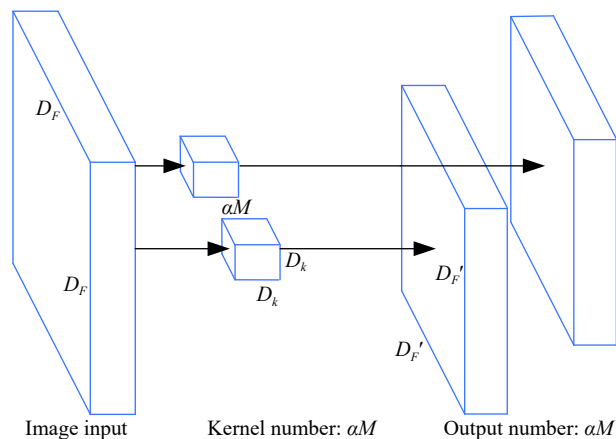


图 4 卷积通道压缩

Fig.4 Convolution channel compression

通道压缩后点方向卷积计算量:

图 3(b) 生成的特征图维度 $D_F' \times D_F' \times \alpha M$ ，图 3(c) 表示用 N 个维度为 $1 \times 1 \times \alpha M$ 的卷积核卷积 (图 3(b)) 的结果，从而输出特征图维度为 $D_F \times D_F \times \alpha M \times N$ ，比压缩前节省 α 倍。

因此压缩后总体计算量为:

$$D_K \times D_K \times \alpha M \times D_F' \times D_F' + \alpha M \times N \times D_F' \times D_F'$$

节省 α 倍。

2 模型训练与实验结果

2.1 SPEED 数据集标注

航天器姿态估计数据集 (Spacecraft Pose Estimation Dataset, SPEED) 由空间交会实验室 (Space Rendezvous Laboratory, SLAB) 采集。由 PRISMA^[15-16] 任务中低轨卫星 Mango 对航天器 Tango 进行拍摄。如图 5 所示。




图 5 Tango(左)与Mango(右)

Fig.5 Tango(left) and Mango(right)


利用光学模拟器^[17]合成的图像 (约 15 000 张) 并给出三轴姿态和 4 个关键点真值，还设立姿态估计公开挑战赛。文中利用该数据集验证 NCDN 网络性能，因此首先对数据集非合作目标图像局部特征进行定义与标注。如图 6 所示。

Tango 可供识别的明显局部特征包括 GPS 天线、



(a) SSC 实验室中 Tango (左) 与 Mango (右)

(a) Tango (left) and Mango (right) in laboratory SSC



(b) 合成图像 (c) Sobel 目标提取 (d) 局部特征定义与标注
(b) Synthetic figure (c) Object extraction with Sobel (d) Local feature definition and label

图 6 SPEED 局部特征定义与标注

Fig.6 Local feature definition and label of SPEED

FFRT 天线以及敏感器。选取数据集中 1 000 张图像按照 7:3 划分为训练集和测试集,训练样本进行了左右翻转并设置 2 种光照条件,数据增强后将样本扩充至 4 倍。针对空间非合作目标的图像处理通常先去除星空背景,使得处理具有尺度变化目标时最大程度上将有效信息输入算法模型中。因此,在标注训练前利用 Sobel 算法检测目标边缘并将目标从背景中分离出。

训练处理单元采用 20 核 CPU 单元 Interl(R) Xeon(R) Silver 4 114 CPU@220GHz, 64G 内存;GPU 采用 NVIDIA Quadro P4000,8G 显存;Win10 系统下用 MATLAB2020a 配置 CUDA10.1 进行网络训练。超参数设置为:小批量尺寸为 1,训练 10 代,学习率 0.001,采用 Adam 优化器。

2.2 NCDN 尺度适应性分析

参考文献 [18] 中指出,合成数据对应距离的正态分布区间在 50 m 内(如图 7(a)所示)。




图 7 SPEED 目标尺度变化

Fig.7 Scale changes of target on SPEED

根据相机模型成像公式:

$$f = h \times D / H$$

$$h = n \times du$$

可估算出 Tango 占据不同像素数为 n , 即所占图像尺寸为 h 时,对应的实际拍摄距离为 D (如图 7(b)所示)。从而通过实验确定 NCDN 实际使用范围。公式中其余变量含义及实际值如表 1 所示。


由于 NCDN 采用了特征融合策略,可将不同卷积层之间信息互通,因此,模型对不同距离下尺度变化导致的非合作目标局部特征分辨率差异有较好的鲁棒性。

表 1 相机模型变量含义

Tab.1 Meaning of variables in camera model

| Variables | Meaning | Variables' value/m |
|-----------|------------------------|---------------------------------|
| f | Focus | 0.0176 |
| H | Actual size of Tango | $0.56 \times 0.75 \times 0.025$ |
| du | Pixel size of detector | 5.86×10^{-6} |


从图 8 定性对比可看出,目标局部特征随距离变远而分辨率逐渐降低。且随目标姿态变化出现光照条件不均,以及几何形态上的旋转、仿射变换等。不同距离下模型对 3 种特征平均准确率均值 (mean Average Precision, mAP) 变化如图 9 所示。



(a) 5 m 特征融合前后效果对比
(a) Comparison effects before and after feature fusion at 5 m



(b) 15 m 特征融合前后效果对比
(b) Comparison effects before and after feature fusion at 15 m



(c) 40 m 特征融合前后效果对比
(c) Comparison effects before and after feature fusion at 40 m

图 8 NCDN 不同距离下效果对比

Fig.8 Comparison effects of NCDN at different distances




图 9 不同距离下模型 mAP 变化对比

Fig.9 mAP comparison of model changes at different distances

从图 9 中看出,引入特征融合策略使得模型对小尺度低分辨率局部特征检测效果有所提升,50 m 内 mAP 从 0.857 提升至 0.898。改进后基本能够满足相关课题和工程项目中近距(25 m 内)非合作目标局部特征检测精度 0.90 的指标。若以各距离段内检测精度 0.85 为准,整体稳定检测距离区间 25 m 内提升至 45 m 内。且图 8(b) 中 40 m 下即便引入特征融合,对于局部特征分辨率较低时也较难区分形态相近的 Sensor 和 FFRT,此距离段下 NCDN 性能逼近极限。

2.3 通道压缩效果分析

文中按照不同比例压缩卷积通道数,以探究在满足不同任务需求下压缩比例可调至多少,压缩比例选定 0.25/0.5/0.75/1 四个档位,对应压缩比所带来的存储空间节省和相对精度损失如表 2 所示。

表 2 通道压缩对 NCDN 影响

Tab.2 Influence of channel compression on NCDN

| Channel compression rate | Storage space of model/MB | Relative accuracy loss |
|--------------------------|---------------------------|------------------------|
| $\alpha = 1$ | 19.0 | 0% |
| $\alpha = 0.75$ | 10.3 | 1% |
| $\alpha = 0.5$ | 5.1 | 2% |
| $\alpha = 0.25$ | 2.2 | 5% |

从表中可以看出,按照 0.25 倍压缩卷积通道后模型计算量节省 75%,存储空间节省 88%,而相对检测精度损失仅有 5%。当前星上存储资源一般在数 MB 至百 MB,处理器计算能力基本在百 MHz 的处理能力。根据实际任务需求变换以调整通道压缩比,可使模型存储有效空间减少。实验验证了方法的可行性,也为卷积神经网络部署在嵌入式系统中实现在轨实时检测提供基础。

3 结 论

文中设计一种用于非合作目标局部特征识别的轻量化特征融合网络,即 NCDN 模型。通过引入特征融合策略实现对不同尺度大小的非合作目标局部特征的准确检测,在 SPEED 数据集上 50 m 内 mAP 可达到 0.898,特征融合策略使得效果提升 4.1%,可以准确识别 SPEED 数据集中非合作目标 Tango 上的 GPS 天线、FFRF 天线和敏感器 3 种局部特征。卷积核通道压缩后能够在保证不过分牺牲卷积核表征能力、降低网络整体检测精度的情况下,优化卷积核参数的冗余,极大地节省了模型的计算量和存储开销。采用 25% 计算量时检测精度牺牲约 5%,15 m 内 mAP 仍可达 0.90。且模型整体存储空间约 2.2MB,节省约 88%。通道压缩后的模型更适用于空间非合作目标局部特征实时检测,为将来模型部署在嵌入式系统和在轨应用奠定基础。

参考文献:

- [1] DLR. Closed Space Robotics Missions (in alphabetical order)ESS[EB/OL].[2020-05-03].[2010-04-13]http://www.dlr.de/rm/en/desktopdefault.aspx/tabid-3827/5969_read-8750/.html.
- [2] DARPA Tactical Technology Office. Front-end robotic enabling near-term demonstrations(FREND)Project Page[EB/OL]. [2020-05-03][2010-10-11].<http://www.darpa.mil/tto/programs/frend.html>.
- [3] Xu Wenfu, Liu Yu, Liang Bin, et al. Measurement of relative poses between two noncooperative spacecrafts [J]. *Optics and Precision Engineering*, 2009, 17(7): 1570–1581. (in Chinese) 徐文福, 刘宇, 梁斌, 等. 非合作航天器的相对位姿测量[J]. *光学精密工程*, 2009, 17(7): 1570–1581.
- [4] Wang Zhichao, Wang Bin, Li Zhiqi, et al. Relative pose measurement of a non-cooperative spacecraft based on feature information fusion [J]. *Chinese High Technology Letters*, 2013, 23(11): 1178–1184. (in Chinese) 王志超, 王滨, 李志奇, 等. 基于特征融合的非合作航天器位姿测量方法[J]. *高技术通讯*, 2013, 23(11): 1178–1184.
- [5] Zhang Shijie, Cao Xibin, Chen Min. Monocular vision-based relative pose parameters determination for non-cooperative spacecrafts [J]. *Journal of Nanjing University of Science and Technology*, 2013, 23(11): 1178–1184. (in Chinese) 张世杰, 曹喜滨, 陈闽. 非合作航天器间相对位姿的单目视觉确定算法[J]. *南京理工大学学报*, 2013, 23(11): 1178–1184.

- [6] Xie Yongchun, Wang Yong, Chen Ao, et al. Learning based on-orbit servicing manipulation technology of space robot [J]. *Aerospace Control and Application*, 2019, 45(4): 25–37. (in Chinese)
解永春, 王勇, 陈奥, 等. 基于学习的空间机器人在轨服务操作技术[J]. *空间控制技术与应用*, 2019, 45(4): 25–37.
- [7] Yang Ming. Multi-pattern 3d intelligent reconstruction method for non-cooperative space targets based on deep learning[D]. Harbin: Harbin Institute of Technology, 2018. (in Chinese)
杨名. 基于深度学习的空间非合作目标多模智能重建算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2018.
- [8] Liu Shuai. Intelligent control and recognition of space robot capturing non cooperative targets[D]. Dalian: Dalian University of Technology, 2019. (in Chinese)
刘帅. 空间机器人抓捕非合作目标的智能控制与识别[D]. 大连: 大连理工大学, 2019.
- [9] Sharma S, D'Amico S. Pose estimation for non-cooperative rendezvous using neural networks[C]// AAS/AIAA Astrodynamics Specialist Conference, 2019.
- [10] Pedro F, Yang G. Deep learning for space pose estimation from photorealistic rendering[C]// AAS/AIAA Astrodynamics Specialist Conference, 2019.
- [11] Li Xiang. Design of attitude estimation algorithm for space non-cooperative targets based on deep learning[D]. Harbin: Harbin Institute of Technology, 2018. (in Chinese)
李想. 基于深度学习的空间非合作目标姿态估计算法设计[D]. 哈尔滨: 哈尔滨工业大学, 2018.
- [12] Lin T Y, Dollar P, Girshick R, et al. Feature pyramid networks for object detection[J]. arXiv: 1612.03 144v2, 2016.
- [13] Li Z X, Zhou F Q. FSSD: Feature fusion single shot multibox detector[J]. arXiv: 1712.00960v3, 2018.
- [14] Tan Hongchen, Li Shuhua, Li bin, et al. Feature enhancement SSD for object detection [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2019, 31(4): 63–69. (in Chinese)
谭红臣, 李淑华, 刘彬, 等. 特征增强的SSD算法及其在目标检测中的应用[J]. *计算机辅助设计与图形学学报*, 2019, 31(4): 63–69.
- [15] D'Amico S, Bodin P, Delpech M, et al. PRISMA. Chap 21[M]// Distributed Space Missions for Earth System Monitoring: Space Technology Library, Volume 31, Part 4. US: Springer, 2013: 599-637.
- [16] D'Amico S, Benn M, Jørgensen J L. Pose estimation of an uncooperative spacecraft from actual space imagery [J]. *International Journal of Space Science and Engineering*, 2014, 2(2): 171–189.
- [17] Beierle C, D'Amico S. Variable-magnification optical stimulator for training and validation of spaceborne vision-based navigation [J]. *Journal of Spacecraft and Rockets*, 2019, 56(4): 1060–1072.
- [18] Sharma S, Beierle C, D'Amico S. Pose estimation for non-cooperative spacecraft rendezvous using convolutional neural networks[C]// The 21th IEEE Aerospace Conference, 2018.