

# 空间变化场景下卫星部组件域适应识别研究\*

牟金震<sup>1,2,3</sup>, 朱文山<sup>1,2,3</sup>, 盛延平<sup>1,2</sup>, 李爽<sup>✉3</sup>, 梁彦<sup>1,2</sup>

(1 上海航天控制技术研究所 上海 201109

2 上海空间智能控制技术重点实验室 上海 201109

3 南京航空航天大学 航天学院 南京 211106)

**摘要:** 针对小样本限制下卫星部组件识别域适应困难的问题, 提出一种变化场景下自适应迁移的目标识别算法。卫星部组件的识别模型框架为 YOLO, 迁移算法包括 3 个策略: 基于特征关联性的样本加权策略, 基于模型的参数自适应策略和最优特征变换自适应迁移策略。基于以上策略, YOLO 模型建立域特征空间的相似性, 选择性地迁移源域知识, 同时在适应过程中通过调整策略边界学习不变特征表示, 以此来加强模型的自适应迁移能力。迁移实验中, 分别验证了 3 个策略的迁移能力, 有效提升 YOLO 模型在复杂多变空间环境下对卫星部组件的稳定识别。实验结果表明: 基于特征关联性学习到的权重重要优于随机初始化权重, 参数自适应迁移显著提升了目标域的测试精度, 最优特征变换显著提升模型的泛化性能力。

**关键词:** 卫星部组件识别; 域适应; 迁移学习; 在轨服务

中图分类号: V19 文献标识码: A 文章编号: CN11-1780(2022)02-0001-09

DOI: 10.12347/j.ycyk.20211018001

引用格式: 牟金震, 朱文山, 盛延平, 等. 空间变化场景下卫星部组件域适应识别研究[J]. 遥测遥控, 2022, 43(2): 1-9.

## Research on adaptive domain detection of satellite component under space variable environment

MU Jinzhen<sup>1,2,3</sup>, ZHU Wenshan<sup>1,2,3</sup>, SHENG Yanping<sup>1,2</sup>, LI Shuang<sup>3</sup>, LIANG Yan<sup>1,2</sup>

(1. Shanghai Aerospace Control Technology Institute, Shanghai 201109, China;

2. Shanghai Key Laboratory of Aerospace Intelligent Control Technology, Shanghai 201109, China;

3. College of Astronautics, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

**Abstract:** To solve the few-shot satellite components domain detection, this paper proposes an object detection algorithm for adaptive migration in variable scenarios. The model is based on YOLO, the improvements include three parts: a sample weighting strategy based on feature relevance, and a model-based parameter adaptive strategy and an optimal feature transformation adaptive migration strategy. Based on the above strategies, YOLO builds the similarity of the domain feature space, selectively migrates the source domain knowledge, and adjusts the boundary of the strategy to learn the invariant feature representation during the adaptation process to enhance the adaptive migration ability of the model. In the migration experiment, the migration ability of the three strategies is verified respectively, which effectively improves the stable detection of YOLO-based satellite components detection in the complex space environment. The experimental results show that the weight importance based on feature association learning is better than the random initial weight, the parameter adaptive transfer significantly improves the testing accuracy of the target domain, and the optimal feature transformation significantly improves the generalization ability of the model.

**Key words:** Satellite component detection; Domain adaptation; Transfer learning; On-orbit service

**DOI:** 10.12347/j.ycyk.20211018001

**Citation:** MU Jinzhen, ZHU Wenshan, SHENG Yanping, et al. Research on adaptive domain detection of satellite component under space variable environment[J]. Journal of Telemetry, Tracking and Command, 2022, 43(2): 1-9.

\*基金项目: 国家自然科学基金(U20B2056); 上海市科技创新行动计划(19511120900); 国防基础科研项目(JCKY2018203B036, JCKY2021606B202)

✉通信作者: 李爽(lishuang@nuaa.edu.cn)

收稿日期: 2021-10-18 收修改稿日期: 2021-12-19

## 引言

空间飞行器在轨服务与维护属于我国科技创新 2030 重大专项, 对卫星的在轨服务与维护提出了更高的要求<sup>[1,2]</sup>。卫星部组件的高可靠识别技术是实现上述需求的核心技术。服务航天器对卫星实施在轨服务之前, 需要对卫星及其部组件进行精确的识别与定位, 为下一步操控任务做准备。但是在太空环境中, 相机对太阳光照等外界干扰信息十分敏感, 传统的目标检测算法需要人为提取特征, 泛化能力较差, 在卫星部组件检测任务上表现不佳<sup>[3]</sup>, 因此, 卫星部组件的稳定识别仍然是一个难题<sup>[4-6]</sup>。传统卫星部组件识别采用基于知识或基于分类的识别方法, 算法会对采集到的图像首先进行去噪或图像增强处理, 之后采取基于手工特征描述算法与分类器结合的方式进行识别<sup>[7]</sup>。

近年来, 深度学习在该领域的应用日益增多, 如文献[8,9]则使用深度卷积网对卫星进行了较为准确的识别。应用深度学习实现卫星部组件识别, 模型无法有效实现训练场景与实际应用场景的迁移。因此, 如何将训练场景下学习到的知识, 自适应地迁移到其他场景, 从而更好地适应环境变化和识别目标需求变化是一个亟待解决的问题<sup>[10-12]</sup>。

本文基于域适应 YOLO<sup>[13]</sup>算法实现了对复杂光源、动态干扰等复杂多变空间环境下卫星部组件的稳定识别, 并基于半物理仿真实验验证了算法的有效性。实验结果表明, 本文所提出的域适应识别算法可以适应复杂的空间环境。本文的创新之处在于:

- ① 提出一种变化场景下自适应迁移的目标识别算法;
- ② 半物理方式制作卫星部组件的数据集;
- ③ 解决不同环境条件下卫星部组件识别难易度差别大的问题。

## 1 基于特征关联性的样本加权自适应迁移

用  $F$  来表示特征提取器。对于一个样本  $x$ ,  $f = F(x)$ , 为  $f$  的每一个特征通道计算空间上的均值  $\mu_c(f)$  和方差  $\sigma_c(f)$ , 并将均值方差拼接成一个新的向量  $\mathbf{svec}_{2c}$  来表征样本特性:

$$\begin{aligned}\mu_c(f) &= \frac{1}{HW} \sum_{h=1}^H \sum_{w=1}^W f_{chw} \\ \sigma_c(f) &= \sqrt{\frac{1}{HW} \sum_{h=1}^H \sum_{w=1}^W (f_{chw} - \mu_c(f))^2} \\ \mathbf{svec}_{2c} &= \text{cat}(\mu_c(f), \sigma_c(f))\end{aligned}\quad (1)$$

其中  $H$  与  $W$  分别表示图像的高和宽。对于任意一个源域样本特征  $f_s$  和目标域样本  $f_t$ , 得到  $\mathbf{svec}(f_s)$  和  $\mathbf{svec}(f_t)$ , 并且用归一化的内积  $sr$  来表示这两个样本的关联性

$$sr = \left\langle \frac{\mathbf{svec}(f_s)}{\|\mathbf{svec}(f_s)\|}, \frac{\mathbf{svec}(f_t)}{\|\mathbf{svec}(f_t)\|} \right\rangle \quad (2)$$

为近似度量源域样本和目标域空间的关联性, 在模型训练过程中, 将源域数据集打乱并进行顺序采样, 对目标域数据集进行随机采样。迭代  $m$  次后, 可以得到均值  $\mu_{\text{rele}} = \frac{1}{m} \sum_{k=1}^m sr_k$ 。在一个 epoch 定义内, 以  $\mu_{\text{rele}}$  作为阈值, 源域样本  $x_s^i$  计算得到的  $sr > \mu_{\text{rele}}$ , 则表示该源域样本被击中, 与目标域场景关联性较强。在训练多个 epoch 后, 可以得到

$$\text{dict}_{\text{rele}} = \left\{ \mu_{\text{rele}}, n_{\text{ep}}, (n_{\text{hit}}^i)_{i=1}^{n_s} \right\} \quad (3)$$

其中  $\mu_{\text{rele}}$  代表相关性的均值,  $n_{\text{ep}}$  为 epoch 次数,  $(n_{\text{hit}}^i)_{i=1}^{n_s}$  为在  $n_{\text{ep}}$  中各源域样本被击中的次数。初始时每个源域样本权重都为 1,  $n_{\text{ep}} > I$  后对源域样本进行加权, 其中  $I=5$  表示对源域样本进行加权的阈值。对于一个源域样本  $x_s^i$ , 在迭代 epoch =  $n_{\text{ep}}$  时其被击中的概率为  $p_{\text{hit}}(x_s^i) = n_{\text{hit}}^i / n_{\text{ep}}$ 。

综上，空间卫星图像的源域样本训练权重可写成

$$w(x_s^i) = bs \times \frac{p_{hit}(x_s^i)}{\sum_{j=1}^{bs} p_{hit}(x_s^j)} \tag{4}$$

其中  $bs$  表示源域样本数量最大值， $j$  表示源域样本个数， $j \in [1, bs]$ 。

### 2 深度神经网络参数自适应迁移模型

假设通过训练，源域模型  $\theta_s$  已经从数据中学习到了大量的结构知识。将该结构知识迁移到与源域相似的目标域  $\theta_p$  中，在使用少量目标域有标签数据情况下，可获得更为精准的目标域模型  $\theta_t$ 。算法分两个阶段：第一阶段是在大体量数据集上进行监督学习，也称为预训练阶段；第二阶段，利用少量的标注信息微调参数模型。计算类别  $k$  所有源样本的激励函数的 softmax 的平均值，可提取类别  $k$  的软标签  $l$ ，其平均值用  $l^k$  表示。如果仅使用简单的 softmax 容易生成一个较陡的分布，因此还需使用一个高温  $\tau$  的 softmax 来保留足够多的类别关系信息。基于软标签的类别间关系知识损失可形式化定义为：

$$\mathcal{L}_{soft}(x_t, y_t; \theta_p) = -\sum_i l^k \text{soft max}(\theta_p^T f(x_T)/\tau) \tag{5}$$

其中  $f(x_T)$  表示正态分布函数， $x_T$  表示特征， $x_t$  与  $y_t$  分别表示源域与目标域样本。

### 3 基于最优特征变换的自适应迁移

假设有一组带标签的源域数据  $\{X_s, Y_s\}$ ，其中  $x_s \in X_s$  为源域中的样本图片，而  $Y_s$  为样本标签，其中  $y \in Y_s$  为源域中的样本图片，同时有一组无标签的目标域数据  $x_t \in X_t$ 。在真实场景下，源域数据和目标域数据的特征往往不重叠。在这种情况下，需要考虑对特征进行变换实现自适应迁移，如图 1 所示。

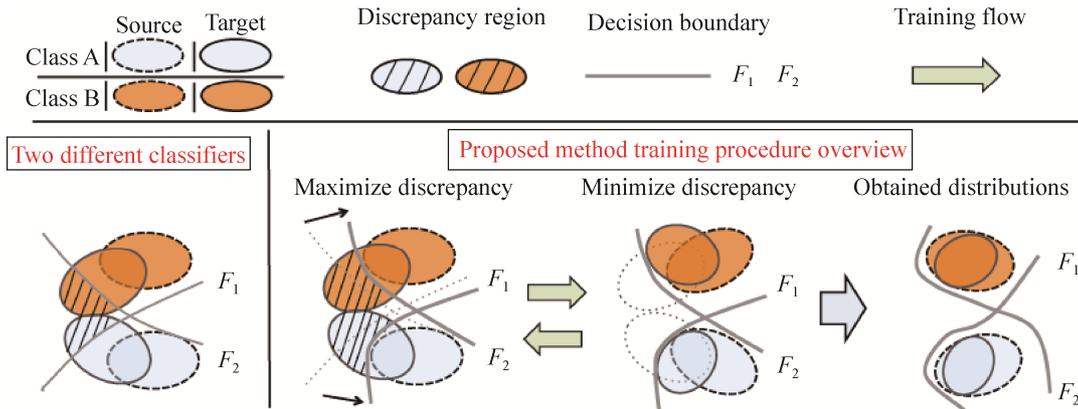


图 1 训练过程的抽象化描述  
Fig. 1 Abstract description of the training process

其中，虚线椭圆框代表源域，实线框代表目标域； $F_1$  和  $F_2$  为独立的两个分类器；阴影部分为差异区域，即分类器分类错误的区域。训练过程共有四个阶段，分别对应图 1 中从左至右四个子图。

- ① 第一阶段，产生了一些阴影，目标是要最大化阴影区域。
- ② 第二阶段，最大化两个分类器差异的结果。
- ③ 第三阶段，最小化分歧的结果。
- ④ 第四阶段，交替优化的目标。

特征迁移模型由一个特征生成器域和两个独立的分类器构成，如图 2 所示。

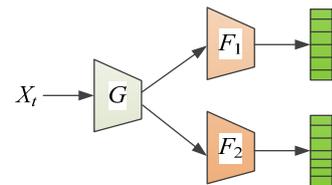


图 2 迁移模型架构  
Fig. 2 Migration model architecture

学习过程分为 Step A、Step B、Step C 三个阶段。其中 Step B、Step C 阶段的对抗训练如图 3 所示:

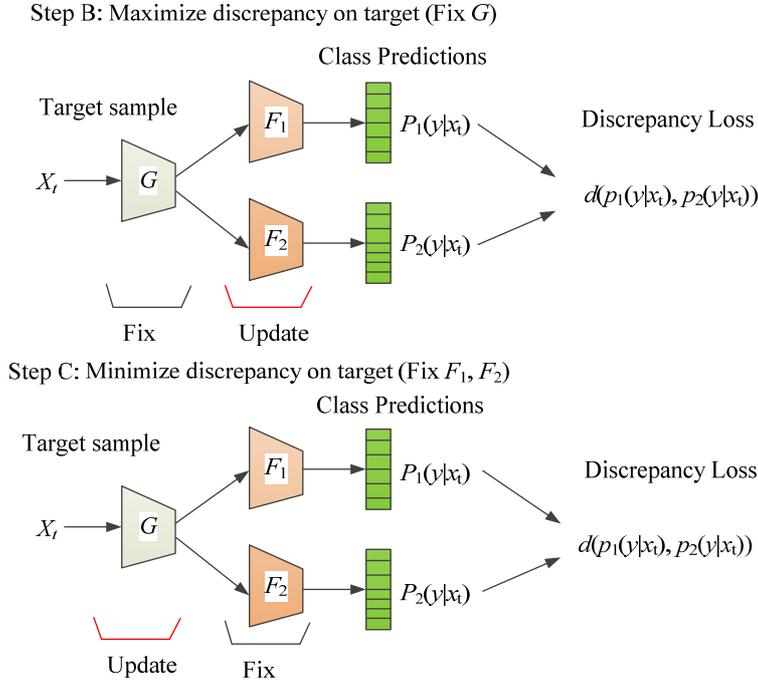


图 3 对抗训练步骤

Fig. 3 Adversarial training steps

在 Step A 阶段, 首先训练出两个不同的分类器  $F_1$  和  $F_2$ , 即求源域上的分类误差。优化目标如下:

$$\min \mathcal{L}(X_s Y_s) = -E_{(x_s, y_s) \sim (X_s, Y_s)} \sum_{k=1}^K \mathbb{I}_{[k=y_s]} \log p(y | x_s) \quad (6)$$

在 Step B 阶段, 固定特征提取器  $G$ , 训练两个不同的分类器  $F_1$  和  $F_2$ , 使得它们的差异最大。两个分离器的差异用最简单的  $\mathcal{L}_1$  损失来衡量, 优化目标如下:

$$\min_{F_1, F_2} \mathcal{L}(X_s, Y_s) - \mathcal{L}_{\text{adv}}(X_t)$$

$$\mathcal{L}_{\text{adv}}(X_t) = E_{x_t \sim X_t} [d(p_1(y | x_t), p_2(y | x_t))] \quad (7)$$

$$d(p_1, p_2) = \frac{1}{K} \sum_{r=1}^K |p_{1k} - p_{2k}|$$

其中第一项为源域上的分类损失, 目的是让  $F_1$  和  $F_2$  继续拟合源域;  $\mathcal{L}_{\text{adv}}$  为  $F_1$  和  $F_2$  的差异度量, 其中  $K$  表示将图片分为  $K$  类,  $d(p_1(y | x_t), p_2(y | x_t))$  表示测量目标样本的差异,  $d$  表示测量两个概率输出之间差异的函数。

在 Step C 阶段, 固定两个分类器, 优化特征生成器  $G$ , 使得特征对两个分类器效果尽可能一样, 优化目标如下:

$$\min_G \mathcal{L}_{\text{adv}}(X_t) \quad (8)$$

本文选择 YOLO 的主干网络 Darknet53 作为特征提取器, 网络的其余部分作为识别器 (对应图 3 中的分类器  $F$ ), 架构如图 4 所示 (红色虚线框为特征提取器  $G$ , 其余为识别器  $F$ , 其中  $F$  被复制为  $F_1$  和  $F_2$ )。

针对 YOLO, 算法对损失函数进行重新设计, 模型中的  $\mathcal{L}_{\text{adv}}$  被替换为了三个部分:

$$\mathcal{L}_{\text{adv}} = k_{\text{conf}} \mathcal{L}_{\text{adv\_conf}} + k_{\text{giou}} \mathcal{L}_{\text{adv\_giou}} + k_{\text{cls}} \mathcal{L}_{\text{adv\_cls}} \quad (9)$$

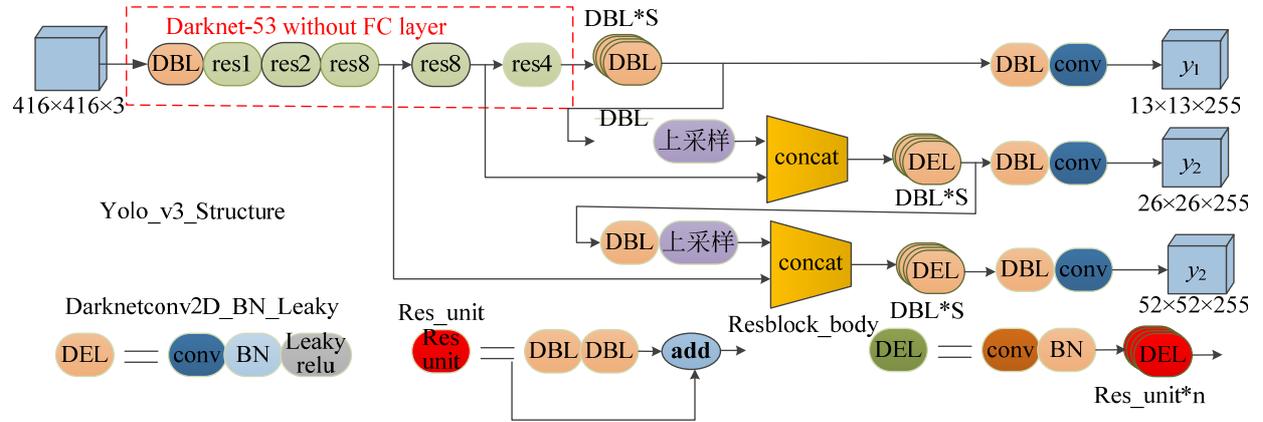


图4 YOLO架构

Fig. 4 YOLO architecture

其中  $\mathcal{L}_{adv\_conf}$  为描述  $F_1$  和  $F_2$  输出的置信度分歧损失:

$$\mathcal{L}_{adv\_conf} = \text{abs} |F_1(x)_{conf} - F_2(x)_{conf}| \quad (10)$$

$\mathcal{L}_{adv\_cls}$  为描述  $F_1$  和  $F_2$  输出的类别分歧损失:

$$\mathcal{L}_{adv\_cls} = \text{abs} |\text{softmax}(F_1(x)_{cls}) - \text{softmax}(F_2(x)_{cls})| \quad (11)$$

$\mathcal{L}_{adv\_giou}$  为描述  $F_1$  和  $F_2$  输出的 GIoU 分歧损失:

$$\mathcal{L}_{adv\_giou} = \text{abs} |Giou(F_1(x)_{xywh}) - Giou(F_2(x)_{xywh})| \quad (12)$$

## 4 实验

### 4.1 实验环境

实验的硬件及软件系统组成如表 1 所示。实验所需要的半物理数据采集环境如图 5 所示。

表 1 实验的系统环境

Table 1 The system environment of the experiment

项目	详情	
硬件环境	GPU	2×NVIDIA GTX1080 Ti 显卡
	主板	Intel Xeon Processor E5-2630v4 主频 2.20 GHz
软件环境	Linux	Ubuntu 16.04



图 5 半物理数据采集环境

Fig. 5 Semi-physical data collection environment

### 4.2 实验数据集

sat1 与 sat2 两个数据集的共同标签域如表 2 所示。在实验中, 分别验证 sat1 (源域/目标域) 与 sat2 (目标域/源域) 之间的迁移过程。

表 2 sat1 与 sat2 目标对象所有标注  
Table 2 All labels of sat1 and sat2 target objects

ID	标签	对应(部组件)实体
0	0_background	背景
1	1_dish_antenna	锅形天线
2	2_thruster	推力器
3	3_earth_observing_camera	对地观测相机
4	4_solar_array	太阳能电池阵列/帆板
5	5_sun_sensor	太阳敏感器
6	6_earth_sensor_assembly	红外地平仪
7	7_antenna_tower	天线塔
8	8_feed_source	馈源
9	10_solar_panel_support	太阳能帆板支架
10	11_conical_spiral_antenna	锥形螺旋天线
11	12_ontology	卫星本体
12	13_star_sensor	星敏感器
13	14_docking_ring	对接环
14	15_docking_surface	对接面
15	16_laser_transmitter	激光数传
16	17_nozzle	喷管
17	18_forward_omni_antenna	全波段前置天线

由表 2 可知, sat1 数据集标签域含有 9 个标签分别是[2,3,5,11,12,13,14,15,17], sat2 数据集标签域含有 8 个标签分别是[1,3,4,8,10,12,13,16]。两个数据集共有的标签是[3,12,13]。sat1 中有 2 颗不同形状的卫星, 如图 6 所示。sat2 数据集包含有 3 颗不同类型的卫星图片, 如图 7 所示。

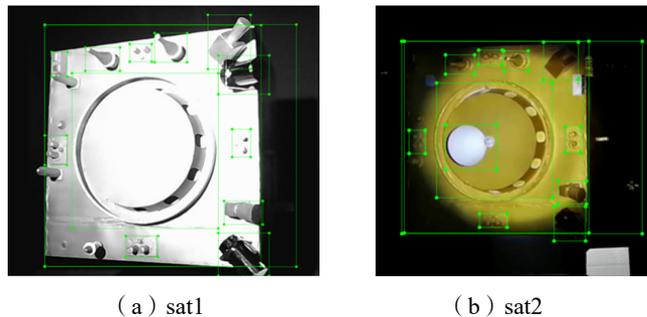


图 6 卫星图片

Fig. 6 Satellite picture

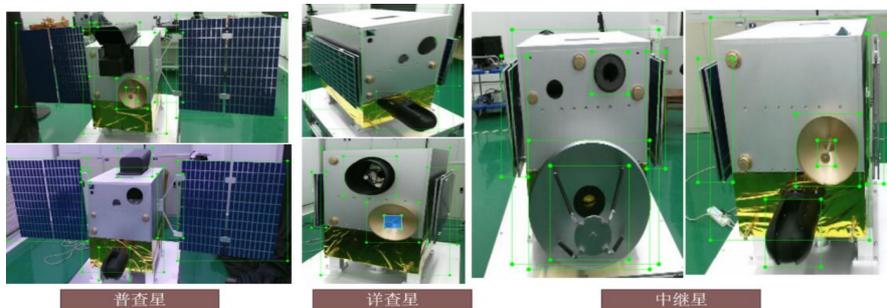


图 7 sat2 数据集中的三类不同类型的卫星, 从左到右分别是普查星, 详查星以及中继星

Fig. 7 Three types of satellites in the sat2 data set, from left to right are census satellites, detailed search satellites, and relay satellites

### 4.3 实验结果与结论

#### 4.3.1 基于特征关联性的样本加权自适应迁移

迁移实验包括两部分内容，其一是将 sat1 作为源域迁移到 sat2 中测试检测精度，其二是将 sat2 作为源域迁移到 sat1 来测试检测精度。

##### 4.3.1.1 源域 sat1 迁移到目标域 sat2

将 sat1 设置为源域，sat2 设置为目标域。测试源域 sat1 模型的训练效果，其精确率为 85.5%，召回率为 98.5%，总精度为 97.6%。由总精度为 97.6% 可知，该模型在源域上已经训练得足够好。

接下来，使用源域 sat1 训练好的模型应用到目标域 sat2 中，其精确率为 0.502%，召回率为 0.274%，总精度为 0.129%，可知 YOLO 检测精度不足 0.2%。由此可知源域与目标域之间差距较大，所以下一步将考虑如何利用已知的少量目标域图片来微调源域的模型，使之更能适用于目标域场景。如果不利用源域信息，使用随机初始化权重来训练 sat2 的少量已知图片，可得到精确率为 46%，召回率为 61.1%，总精度为 55.2%。使用源域 sat1 已经训练得比较好的权重，然后再使用 5% 目标域图片进行微调，可得到精确率为 57.5%，召回率为 71.1%，总精度为 68.1%。

##### 4.3.1.2 源域 sat2 迁移到目标域 sat1

第二个实验设置中，sat2 作为源域，sat1 作为目标域。目标域 sat1 数据集仅有 5% 的图片可用于模型训练，剩余 95% 的图片作为测试集。首先，测试仅使用 sat2 训练之后的模型来测试 sat1 数据集，可得到精确率为 0.402%，召回率为 0.174%，总精度为 0.049%。总体来说其识别精度小于 0.01。

接下来，加入少量的已知目标域的图片来对源域上的权重进行微调，从而进一步提升该模型在目标域场景下的检测精度。如果不利用源域标注信息，在随机初始化权重情况下，利用 5% sat1 数据集训练模型，可得到精确率为 59.8%，召回率为 84%，总精度为 79.8%。利用源域 sat2 数据集训练源域模型。在训练源域模型时基于特征关联性对源域样本进行加权。以源域模型的权重作为预训练权重，使用 5% 目标域 sat1 图片进行再学习之后得到精确率为 76.3%，召回率为 90.7%，总精度为 98.9%。对比两种设置可知，基于特征关联性学习到的权重要优于随机初始化的权重。

##### 4.3.1.3 结果分析

通过上述实验结果可知，sat2 数据集作为源域，sat1 作为目标域，会取得更好的结果。可能存在的原因是：sat2 数据集图片中，虽然光照条件充足，拍摄得比较清晰，但是每一张图片中存在多个卫星目标，各类型元器件比较复杂；而 sat1 数据集虽然光照不足，并且存在远近距离的切换，但是每张图片都只含有一个卫星目标，各种元器件组成比较清晰，所以只许通过少量的已知图片也能够比较轻松地学习到卫星各个部件的特征。为了验证分析结果，接下来的实验设置以 sat1 作为源域，sat2 作为目标域。

#### 4.3.2 参数自适应迁移

设置 sat1 为目标域。使用源域 sat2 数据训练检测模型，然后使用该模型在 sat1 上测试，得到 sat2 迁移到 sat1 的基线结果，可得到精确率为 3.69%，召回率为 0.123%，总精度为 0.24%。利用 ImageNet 训练 yolov3，然后随机选择 sat1 数据集中 5% 的图片对训练权重进行微调训练，最后使用 sat1 目标域中剩余 95% 的图片作为测试集，可得到精确率为 74.7%，召回率为 93.3%，总精度为 92.4%。对比两种设置可知，参数自适应迁移的实验结果显著提升了目标域的测试精度。

#### 4.3.3 最优特征变换的自适应迁移

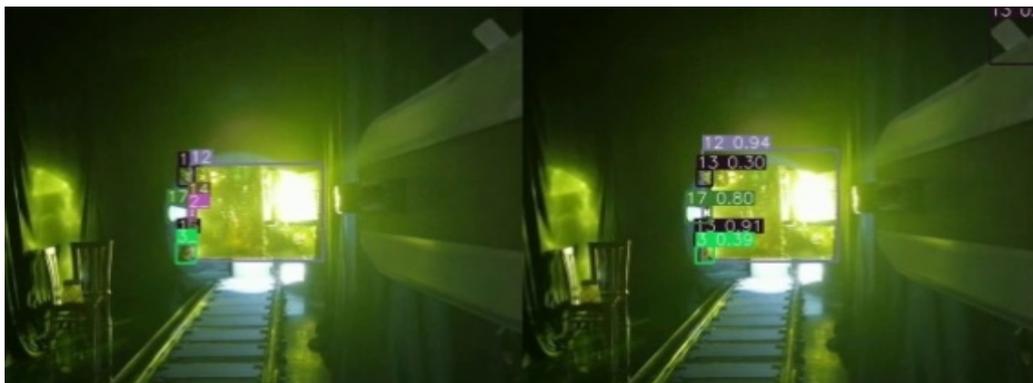
在 sat1 中，选择金色卫星图片作为源域，银色卫星图片作为目标域。利用源域数据的基线测试可得到精确率为 73.7%，召回率为 38.5%，总精度为 52.4%。利用最优特征变换迁移策略可得到精确率为 70%，召回率为 89.4%，总精度为 83%。由两种设置可知，最优特征变换可以显著提升模型的泛化性。

### 4.4 可视化结果

为进一步展示方法迁移效果，通过设置不同的光照环境、不同的识别距离以及不同的目标，以此验证域适应有效性。模型经过本文算法的训练，有效地适应了多种典型空间环境，有效地识别出多类型卫星，如图 8 所示。



(a) 远距离且光照强条件下  
(a) Distant and strong lighting



(b) 远距离且光照呈镜面反射条件下  
(b) Distant and specular reflection



(c) 其他卫星模型下的识别效果  
(c) Other satellite recognition

图 8 不同光照、不同目标以及不同识别距离下的域适应识别效果  
Fig. 8 The recognition effects of domain adaptation under different lighting, different targets and different recognition distances

### 5 结束语

本文设计了变化场景下卫星部组件识别的自适应迁移 YOLO 算法,用于实现多种干扰因素环境下的小样本卫星识别问题,特别是样本难以收集、样本量不足导致的识别精度差的问题。实验证明,本文算法对多个域可实现适应,同时对域样本数量不平衡及样本识别难度不一致情况下的卫星部组件识别非常有效。

## 参考文献

- [1] 牟金震, 郝晓龙, 朱文山, 等. 非合作目标智能感知技术研究进展与展望[J]. 中国空间科学, 2021, 41(6): 1–16.  
MU Jinzhen, HAO Xiaolong, ZHU Wenshan, et al. Review and prospect of intelligent perception for non-cooperative targets [J]. Chinese Space Science and Technology, 2021, 41(6): 1–16.
- [2] 刘付成. 人工智能在航天器控制中的应用[J]. 飞控与探测, 2018, 1(1): 16–25.  
LIU Fucheng. Application of artificial intelligence in spacecraft[J]. Flight Control and Detection, 2018, 1(1): 16–25.
- [3] 陈昱文, 熊建林, 刘斌, 等. 光学遥感图像船只目标检测识别技术[J]. 遥测遥控, 2021, 42(3): 64–73.  
CHEN Yuwen, XIONG Jianlin, LIU Bin, et al. Survey of ship detection and recognition technology in optical remote sensing images[J]. Journal of Telemetry, Tracking and Command, 2021, 42(3): 64–73.
- [4] 牟金震, 温凯瑞, 刘宗明. 非合作慢旋目标即时状态位姿确定[J]. 导航定位与授时, 2020, 7(6): 114–120.  
MOU Jinzhen, WEN Kairui, LIU Zongming. Real-time pose estimation for slow rotating non-cooperative targets[J]. Navigation Positioning and Timing, 2020, 7(6): 114–120.
- [5] 刘付成, 牟金震, 刘宗明, 等. 低照度小样本限制下的失效卫星相对位姿估计与优化[J]. 航空学报, 2021, 42(4): 546–557.  
LIU Fucheng, MU Jinzhen, LIU Zongming, et al. Relative pose estimation and optimization of a failure satellite with low-light few-shot images[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(4): 546–557.
- [6] 牟金震, 刘宗明, 周彦, 等. 失效卫星远距离相对位姿估计与优化方法研究[J/OL]. 航空学报. 2021, <http://hkxb.buaa.edu.cn/CN/10.7527/S1000-6893.2021.24959>.  
MU Jinzhen, LIU Zongming, ZHOU Yan, et al. Long-range relative pose estimation and optimization of a failure satellite [J/OL]. Acta Aeronautica et Astronautica Sinica, 2021. <http://hkxb.buaa.edu.cn/CN/10.7527/S1000-6893.2021.24959>.
- [7] 刘斌. 基于本体的多源信息融合空间目标识别方法研究[D]. 长沙: 国防科学技术大学, 2018.  
LIU Bin. Research on multi-source information fusion based on ontology for RSO recognition[D]. Changsha: Graduate School of National University of Defense Technology, 2018.
- [8] CHEN Y L, GAO J. R-CNN-based satellite components detection in optical images [J/OL]. International Journal of Aerospace Engineering, 2020. <https://www.hindawi.com/journals/ijae/2020/8816187/>.
- [9] CHEN Y L, GAO J. Satellite components detection from optical images based on instance segmentation networks[J]. Journal of Aerospace Information Systems, 2021(1): 1–11.
- [10] 李林泽, 张涛. 基于深度学习的空间非合作目标特征检测与识别[J]. 智能系统学, 2020, 15(6): 1154–1162.  
LI Linze, ZHANG Tao. Feature detection and recognition of spatial noncooperative objects based on deep learning [J]. CAAI Transactions on Intelligent Systems, 2020, 15(6): 1154–1162.
- [11] 王柳. 基于深度学习的空间多目标识别方法研究[J]. 无人系统技术, 2019(3): 49–55.  
WANG Liu. Research on spatial multi-objective recognition based on deep learning[J]. Unmanned Systems Technology, 2019(3): 49–55.
- [12] HOANG D A, CHEN B, CHIN T J. A spacecraft dataset for detection, segmentation and parts recognition [EB/OL]. ArXiv preprint: 2106.08186, 2021[2020-06-15]. <https://arxiv.org/abs/2106.08186>.
- [13] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[EB/OL]. ArXiv preprint: 1506.02640, 2015 [2016-06-08]. <https://arxiv.org/abs/1506.02640>.

## [作者简介]

牟金震 1991年生, 博士生, 工程师, 主要研究方向为空间非合作目标感知。

朱文山 1976年生, 硕士, 研究员, 主要研究方向为空间探测。

盛延平 1990年生, 硕士, 工程师, 主要研究方向为空间图像处理。

李爽 1978年生, 博士, 教授, 主要研究方向为航天器动力学与控制, 航天器智能博弈与对抗。

梁彦 1985年生, 硕士, 高级工程师, 主要研究方向为深度学习。

(本文编辑: 潘三英)