

文章编号 1004-924X(2026)10-1592-20

Sat-YOLO: 面向空间卫星的目标检测器

贾国瑜^{1,2*}, 任 龙¹, 张海峰¹, 肖海峰^{1,2}, 钟 琼^{1,2}, 秦欣睿^{1,2}

(1. 中国科学院 西安光学精密机械研究所, 陕西 西安 710119;

2. 中国科学院大学, 北京 101408)

摘要:空间卫星目标检测是在轨航天器自主服务、空间态势感知等国家重大航天工程的核心支撑技术,直接决定航天任务的执行安全与可靠性。针对空间卫星目标检测中存在的弱纹理、目标非对称、多尺度分布及复杂光照干扰等难题,现有方案检测精度不足、背景干扰抑制能力弱等问题。本文以 YOLOv11n 为基线,设计三大改进模块构建 Sat-YOLO,首先引入移动风车卷积 SPCov 替代传统下采样卷积,强化非对称卫星目标特征捕捉与稀疏特征聚合;其次在 YOLOv11 原生 C3K2 模块基础上集成 ASTSA 注意力机制,提出 C3K2_ASTSA 特征增强检测头,抑制太空背景噪声并提升目标特征判别性;最后设计多尺度大核分解注意力 MLKDA 模块,实现全尺度目标特征覆盖,提升检测精度。同时搭建航天器在轨模拟观测系统,构建包含 8 000 张样本的空间卫星专用数据集,涵盖复杂光照场景下卫星、太阳能电池板、不规则球形天线等三类目标,通过消融实验、对比实验及跨数据集验证,系统评估检测算法性能。实验结果表明:在自建空间卫星数据集上,Sat-YOLO 精度达 88.4%、召回率达 85.5%,mAP@0.5 达 93.7%,mAP@0.5:0.95 达 57.8%,相较于基线 YOLOv11n,分别提升 3.7%,1.3%,3.2%,2.9%;在 ExDark 暗光数据集上,综合性能优于 RT-DETR-1, YOLO 系列, MHSa-YOLOv5s, YKSB 等主流对比方案。本文提出的 Sat-YOLO 有效缓解了空间卫星目标检测的核心难题,实现了检测精度的显著提升,具备优异的环境适应性和跨场景泛化能力,可为复杂空间场景下的卫星目标检测提供可靠的技术支撑。

关键词:空间卫星;目标检测;注意力机制;多尺度特征;航天器感知

中图分类号: TP751 **文献标识码:** A

doi: 10. 37188/OPE. 20263410. 1592

CSTR: 32169. 14. OPE. 20263410. 1592

Sat-YOLO: A target detector for space satellites

JIA Guoyu^{1,2*}, REN Long¹, ZHANG Haifeng¹, XIAO Haifeng^{1,2}, ZHONG Qiong^{1,2}, QIN Xinrui^{1,2}

(1. Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences,

Xi'an 710119, China;

2. University of Chinese Academy of Sciences, Beijing 101408, China)

* Corresponding author, E-mail: renlong@opt. ac. cn

Abstract: Space satellite target detection is the core supporting technology for major national aerospace projects such as on-orbit autonomous spacecraft service and space situational awareness (SSA), and directly determines the execution safety and reliability of space missions. This study addressed the key challenges in space satellite target detection, including weak texture, asymmetric targets, multi-scale distribution and complex illumination interference, as well as the limitations of existing methods such as insuffi-

收稿日期:2026-03-11;修订日期:2026-04-01.

基金项目:陕西省自然科学基金基础研究计划资助(No. 2023-JQ-QC-0714)

cient detection accuracy and weak background interference suppression capability. We took the You Only Look Once version 11 nano (YOLOv11n) as the baseline, and constructed a novel Sat-YOLO model with three customized improved modules: first, we introduced Shifted Windmill Convolution (SPConv) to replace traditional downsampling convolution, which enhanced the feature capture of asymmetric satellite targets and sparse feature aggregation; second, we integrated the ASTSA attention mechanism into the native C3K2 module of YOLOv11, and proposed a C3K2_ASTSA feature-enhanced detection head to suppress space background noise and improve target feature discriminability; third, we designed a Multi-Scale Large-Kernel Decomposition Attention (MLKDA) module to achieve full-scale target feature coverage, further improving detection accuracy. Meanwhile, we built an on-orbit simulated spacecraft observation system and constructed a dedicated space satellite dataset containing 8000 samples, covering three types of targets including satellites, solar panels and irregular spherical antennas under complex illumination scenes, and systematically evaluated the performance of the detection algorithm through ablation experiments, comparative experiments and cross-dataset validation. Experimental results show that on the self-built space satellite dataset, Sat-YOLO achieves 88.4% precision, 85.5% recall, 93.7% mean Average Precision (mAP)@0.5, and 57.8% mAP@0.5:0.95, with improvements of 3.7%, 1.3%, 3.2% and 2.9% respectively over the YOLOv11n baseline; on the ExDark low-light dataset, Sat-YOLO outperforms mainstream comparative schemes including RT-DETR-l, YOLO series models, MHSA-YOLOv5s and YKSB in comprehensive performance. The proposed Sat-YOLO effectively alleviates the core challenges of space satellite target detection, achieves significant improvement in detection accuracy, and has excellent environmental adaptability and cross-scene generalization ability, which can provide reliable technical support for satellite target detection in complex space scenes.

Key words: space satellite; target detection; attention mechanism; multi-scale feature; spacecraft perception

1 引言

随着人类对太空探索的深入,以卫星为基础设施的定位导航、卫星通信、遥感观测^[1]以及监视侦察等技术^[2]得到蓬勃发展,轨道环境发生了重大转变,导致空间物体数量呈指数级增长^[3]。这些物体主要包括活跃和非活跃的卫星、火箭体^[4]。空间活动增加了不同轨道上的物体之间发生碰撞的可能性,对空间系统构成的威胁越来越大^[5]。这一情况凸显了为在轨航天器配备自主环境感知能力的紧迫需求^[6],以实现实时检测和避免潜在碰撞威胁,从而确保航天任务的安全执行^[7]。在空间平台上部署光学传感器,能够自动检测和识别非合作目标,从而为后续的在轨服务^{[8][9]}、空间态势感知^[10]任务提供关键参数和决策支持。空间态势感知(Space Situational Awareness, SSA)涵盖太空物体的检测、跟踪、识别、特征化、事件评估与验证、环境监测

及风险预测,是空间安全的基石^[11]。在这些任务中,空间物体识别尤为关键。近年来,研究人员采用了多种传感器,包括激光雷达^[12]、飞行时间摄像头^[13]以及单目或立体视觉系统^[14]。单目视觉系统因其在体积、重量、功耗和成本上的显著优势而受到特别青睐^[15],并已被应用于先进任务如 RemoveDEBRIS^[16]和 Restore-L^[17]。然而,比例、视角和照明的差异会严重影响图像特征提取。早期的空间目标识别方法主要依赖手工制作的特征和传统图像处理技术,在目标尺度变化、光照干扰等复杂场景下稳定性不足。牛海鹏^[18]等人针对星图弱小目标检测提出了基于快速局部对比度和目标特征的检测方法,为空间背景噪声抑制提供了设计思路。但该类方法对卫星多部件、非对称结构的泛化能力有限。

与传统方法相比^[19-20],基于深度神经网络的空间物体检测表现出更优的能力,使其成为航

空航天领域广泛研究和应用的技术。空间目标的非对称卫星部件等专属结构与成像特性,是导致检测难度大的核心原因^[21],针对空间目标多尺度分布与弱纹理特征提取难题,Shen^[22]等人提出了基于YOLOv5改进的YKSB模型,通过K-Means++算法优化锚框适配多尺度目标,引入SK-Net选择性核网络增强弱纹理特征表征能力,同时设计改进BiFPN结构强化多尺度特征融合,为多尺度弱纹理卫星目标检测提供了有效方案;但该模型采用对称卷积核与常规特征融合结构,对太阳能板、不规则天线等非对称结构目标的定向特征捕捉能力不足,极端光照场景下的背景噪声抑制能力仍有提升空间。针对在轨卫星多尺度检测与特征融合需求,Liu^[23]等人提出了融合多头自注意力的MHSA-YOLOv5s模型,在Neck结构中嵌入MHSA模块建模全局空间依赖,强化深浅层特征融合能力,验证了注意力机制在空间目标检测中的有效性;但该模型未针对非对称卫星部件设计专项卷积优化,对长条状、不规则结构目标的特征提取效率偏低。此外,Chen等人^[24]设计了基于区域提案网络的航天器组件检测模型,其性能优于传统滑动窗口方法,但是实时性能仍不理想,其地面模拟数据集未能充分反映地面与轨道环境之间的成像差异。寇鹏^[25]等人针对空间目标自适应光学图像的椭圆部件检测需求,改进了弧支撑线段椭圆检测算法,实现了对卫星球形天线等椭圆部件的精准识别,验证了空间卫星部件级检测的工程价值;梁海翔^[26]等人针对高分辨率遥感图像小目标检测难题,基于YOLOv8n改进了下采样卷积结构与特征金字塔,大幅提升了遥感小目标的检测精度,为YOLO系列算法在航天遥感场景的改进提供了参考。

目前主流的目标检测方法可分为两类:单阶段检测方法与两阶段检测方法。两阶段目标检测模型以Faster R-CNN为代表,检测精度优异但参数量大、推理速度慢,难以适配星载实时性需求;单阶段模型包括SSD^[27]与YOLO系列模型,通过端到端推理实现检测速度与精度的平衡,是星载部署的主流方案。

YOLO系列模型作为单阶段目标检测的代表性方案,已广泛应用于各类目标检测场景。相比其他主流检测模型如YOLOv5n、YOLOv8n、DETR等,YOLOv11通过高效的C3K2特征提取模块、紧凑的网络架构与多尺度特征融合机制,天然适配空间任务的算力约束需求,同时具备极强的可扩展性,可针对空间目标的特性进行定向优化。从空间场景适配性分析YOLOv11对高纹理、结构规则、尺度分布均匀的目标具备优异的检测性能,但空间卫星的弱纹理、非对称、多尺度、低信噪比特性,恰好是其原生架构的检测短板,具体存在三点核心局限性:(1)传统对称正方形卷积核,难以精准捕捉卫星太阳能板、不规则天线等非对称结构的定向特征,易导致边缘与纹理信息丢失;(2)原生C3K2模块仅依赖局部卷积,缺乏背景噪声抑制机制,无法建模卫星部件间的长距离空间关联,弱纹理特征易被深空背景淹没;(3)固定感受野设计无法适配多尺度目标,小目标卫星的特征易在下采样过程中丢失。

针对上述三大核心局限性,本文提出面向空间卫星目标检测的专用模型Sat-YOLO,以YOLOv11n为基线,通过三大核心改进模块解决上述的空间场景难题,形成完整的技术解决方案:

(1)设计移动风车形状卷积SPConv(Shifted Pinwheel-shaped Convolution)替代传统下采样卷积,通过非对称填充构建定向感受野,结合无参数循环移位操作,解决非对称结构目标特征捕捉不足、稀疏特征聚合能力弱的问题;

(2)提出C3K2_ASTSA特征增强检测头,在原生C3K2模块中集成ASTSA(Adaptive Spatial-enhanced Top-k Sparse Attention)注意力机制,通过通道稀疏筛选与空间长距离依赖建模,抑制太空背景噪声,提升弱纹理目标的特征判别性;

(3)构建多尺度大核分解注意力MLKDA(Multi-scale Large Kernel Decomposition Attention)模块,通过四分支多尺度大核卷积分解设计,实现全尺度特征覆盖,解决空间卫星多尺度目标检测难题。

同时对于卫星图像中的模态多样性问题,存在众多不同的视角、尺寸和姿态,而已知的空间卫星目标图像数量有限,阻碍了检测器在复杂真实场景中的性能发挥。本文搭建航天器在轨模拟观测系统,构建了包含 8 000 张标注样本的空间卫星专用数据集,验证模型的工程部署可行性。

2 基本原理

2.1 Sat-YOLO 网络结构

为解决复杂空间场景中卫星目标检测精度不足的问题,本文提出了基于改进 YOLOv11n 的多尺度特征融合检测模型 Sat-YOLO。整体模型

结构如图 1 所示。

模型整体分为骨干网络、特征融合颈部(Neck)、检测头三部分,改进方案如下:

骨干网络:采用 SPCov 替代原生下采样卷积,强化非对称目标特征捕捉能力;嵌入 MLK-DA 模块,实现多尺度特征增强,提升小目标特征表征能力;

特征融合颈部(Neck):采用 SPCov 替换传统下采样卷积,结合多尺度特征融合结构,聚合不同层级的特征信息,缓解小目标特征丢失问题;

检测头:采用 C3K2_ASTSA 模块替换原生 C3K2 模块,抑制背景噪声干扰,提升目标特征判别性。

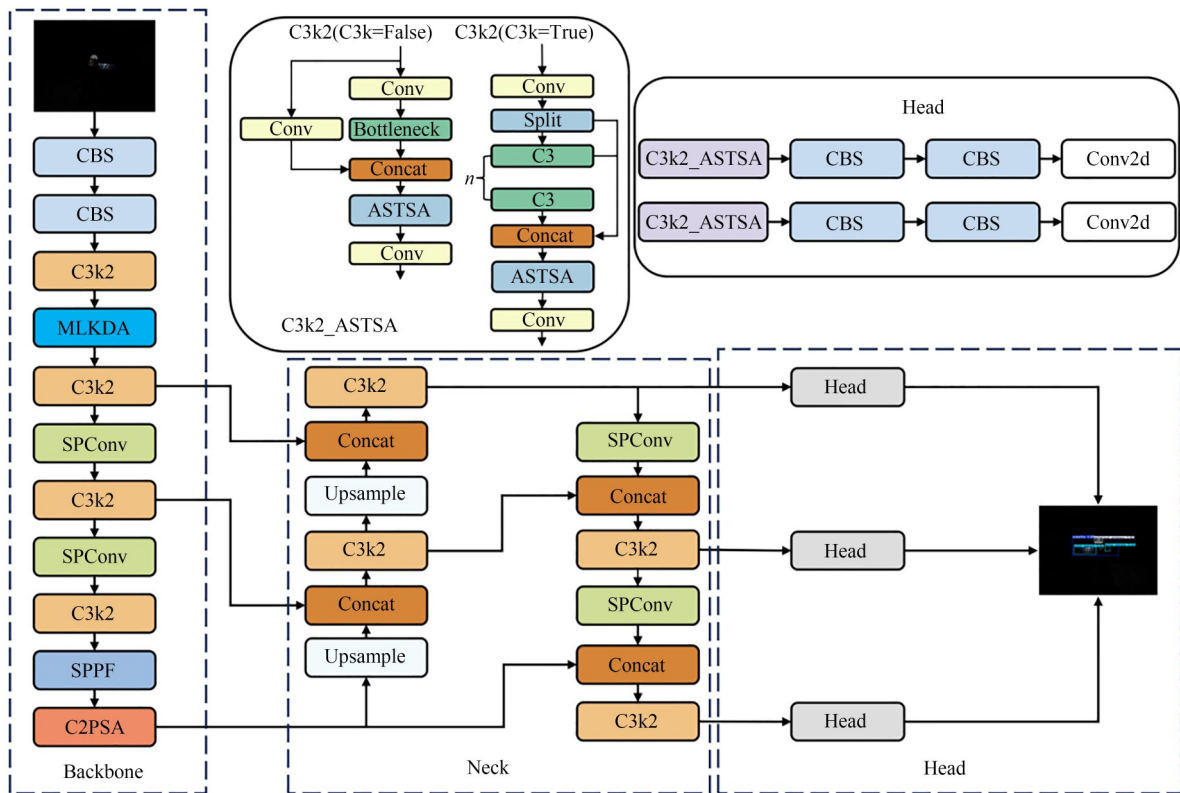


图1 Sat-YOLO模型结构

Fig. 1 Architecture of the Improved Sat-YOLO Algorithm

2.2 移动风车形状卷积

空间卫星目标的结构特性与检测场景对传统卷积提出双重挑战:一方面,卫星目标多由非对称组件构成,如长条状太阳能板、不规则舱体等等。传统 3×3 卷积的对称正方形感受野难

以精准捕捉此类定向结构特征,易导致边缘与纹理信息丢失;另一方面,空间成像环境复杂,卫星图像中目标像素占比低(小目标占比超 60%),特征分布稀疏且分散,同时受太空背景中杂散光、暗场冗余像素等噪声干扰,传统卷积

依赖局部邻域计算,难以有效整合跨位置关联特征,且无法适配目标像素的高斯分布特性,导致目标与背景的分度不足。本文所设计的SPConv嵌入到主干网络和Neck层中,是基于空间目标的结构特性与成像分布规律,摒弃传统卷积的对称填充模式,采用非对称填充策略为图像不同区域创建水平与垂直方向的专用卷积核,构建动态“风车状”感受野。随后引入无参数循环移位交互增强特征关联性,强化卫星目标特征捕捉能力,实现检测模型在空间卫星检测场景的性能提升。

SPConv模块与标准卷积不同,SPConv采用非对称填充,为图像的不同区域创建水平和垂直卷积核。卷积核向外扩散, h_1, w_1, c_1 分别表示输入张量 $\mathbf{X}^{(h_1, w_1, c_1)}$ 的高度、宽度和通道数。为提升训练稳定性和速度,本文在每次卷积后应用批量归一化和SiLU激活函数,有效提升模型的训练稳定性与收敛速度,避免梯度消失或爆炸问题。SPConv的第一层执行并行卷积:

$$\mathbf{X}_1^{(h', w', c')} = \text{SiLU} \left(\text{BN} \left(\mathbf{X}_{P_1(1, 0, 0, 3)}^{(h_1, w_1, c_1)} \otimes \mathbf{W}_1^{(1, 3, c')} \right) \right), \quad (1)$$

$$\mathbf{X}_2^{(h', w', c')} = \text{SiLU} \left(\text{BN} \left(\mathbf{X}_{P_2(0, 3, 0, 1)}^{(h_1, w_1, c_1)} \otimes \mathbf{W}_2^{(3, 1, c')} \right) \right), \quad (2)$$

$$\mathbf{X}_3^{(h', w', c')} = \text{SiLU} \left(\text{BN} \left(\mathbf{X}_{P_3(0, 1, 3, 0)}^{(h_1, w_1, c_1)} \otimes \mathbf{W}_3^{(1, 3, c')} \right) \right), \quad (3)$$

$$\mathbf{X}_4^{(h', w', c')} = \text{SiLU} \left(\text{BN} \left(\mathbf{X}_{P_4(3, 0, 1, 0)}^{(h_1, w_1, c_1)} \otimes \mathbf{W}_4^{(3, 1, c')} \right) \right), \quad (4)$$

其中: \otimes 表示卷积运算符, $\mathbf{W}_1^{(1, 3, c')}$ 是输出通道数为 c' 的 1×3 卷积核。填充参数 $P_1(1, 0, 0, 3)$ 分别表示左、右、上、下四个方向的填充像素数,通过差异化填充适配目标不同方向的结构特征。四分支并行卷积后,输出特征图的高度 h' 、宽度 w' 与通道数 c' 满足以下关系:

$$h' = \frac{h_1}{s} + 1, w' = \frac{w_1}{s} + 1, c' = \frac{c_2}{4}, \quad (5)$$

其中: s 为卷积步长, c_2 为SPConv模块最终输出特征图的通道数。随后对四分支输出特征图进行通道拼接操作,融合多维定向特征:

$$\mathbf{X}^{(h', w', 4c')} = \text{Cat} \left(\mathbf{X}_1^{(h', w', c')}, \dots, \mathbf{X}_4^{(h', w', c')} \right). \quad (6)$$

为实现与标准卷积层的无缝替换,并自适应整合不同方向特征的贡献度,拼接后的特征图通过一个无填充的 2×2 卷积核 $\mathbf{W}^{(2, 2, c_2)}$ 进行归一化处理,输出特征图的高度和宽度被调整为预设

值 h_2 和 w_2 :

$$h_2 = h' - 1 = \frac{h_1}{s}, w_2 = w' - 1 = \frac{w_1}{s}. \quad (7)$$

最终输出特征图 $\mathbf{Y}^{h_2, w_2, c_2}$ 的表达式如式(8):

$$\mathbf{Y}^{h_2, w_2, c_2} = \text{SiLU} \left(\text{BN} \left(\mathbf{X}^{(h', w', 4c')} \otimes \mathbf{W}^{(2, 2, c_2)} \right) \right). \quad (8)$$

风车状感受野由两组水平 1×3 卷积、两组垂直 3×1 卷积通过非对称填充构建,形成以目标中心为核心、沿水平和垂直双轴向扩散的风车形态,卷积核权重分布遵循高斯特性,与小目标卫星的像素分布特性高度契合。水平卷积专门捕捉太阳能板等水平延展结构的长轴特征,垂直卷积强化杆状天线等纵向结构的轮廓提取,四分支融合可同时覆盖水平、垂直、斜向的非对称结构特征。相比传统对称卷积,风车状感受野对卫星大长宽比非对称部件的有效特征像素占比显著提升,从卷积核设计根源上解决了对称卷积对非对称结构特征提取效率低、背景干扰强的核心痛点。

针对空间卫星目标特征稀疏分散、跨邻域非对称结构易出现特征断裂的问题,新增无参数循环移位操作对风车状感受野的特征捕捉能力进行强化。即特征图边缘像素移位后绕回至对侧,增强不同方向特征的交互能力,模拟“风车旋转”式感受野覆盖,对四个定向分支的特征图分别进行水平与垂直方向的像素循环重排,在不增加参数量与计算量的前提下,实现了邻域特征交互,聚合分散的非对称结构特征,提升特征图的有效信息密度。循环移位操作定义为:对特征图 \mathbf{X} 沿维度 d 以步长 s 进行循环移位,输出张量 F ,其元素满足:

$$F'_{b, c, h, w} = \begin{cases} \mathbf{X}_{b, c, (h-t) \bmod H}, & d = 2 \\ \mathbf{X}_{b, c, h, (w-t) \bmod W}, & d = 3 \end{cases}, \quad (9)$$

其中: t 为移位步长, $t > 0$ 表示向上或者向右移位, d 为移位维度, $d = 2$ 对应垂直方向, $d = 3$ 对应水平方向, \bmod 是模运算加持的维度偏移,保证边缘像素移位后绕回对侧,实现无边界损失的跨位置特征融合。通过上述结构设计,SPConv能够在特征提取过程中同步实现定向捕捉、噪声抑制与特征增强,显著提升对空间卫星目标的特征表征能力。SPConv模块结构如图2所示。

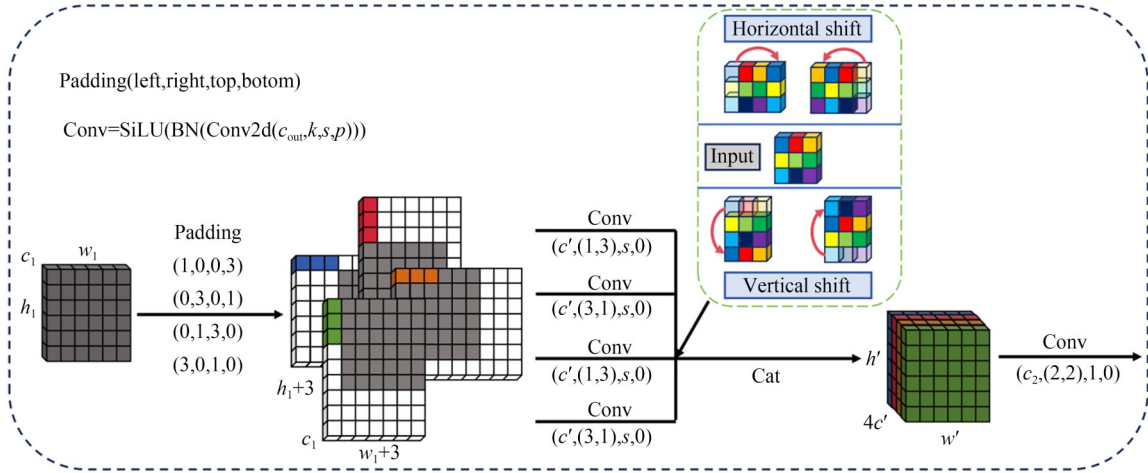


图 2 移动风车卷积模块

Fig. 2 Architecture of the shifted pinwheel-shaped convolutional module

2.3 C3K2_ASTSA 特征增强检测头

在YOLOv11原生C3K2模块仅依赖局部卷积,无法建模卫星部件间的长距离空间关联,缺乏通道稀疏筛选机制,难以抑制太空杂散光、暗场冗余像素等背景噪声,对弱纹理目标的特征判别性不足。针对该问题,本文在原生C3K2模块基础上集成ASTSA稀疏注意力机制,提出C3K2_ASTSA特征增强检测头,替换检测头中的C3k2模块,在不改变模块输入输出维度的前提下,实现背景噪声抑制、长距离空间关联建模与弱纹理特征增强。该模块完全保留原生C3K2高效特征传播特性,完美适配空间卫星目标检测的场景需求。ASTSA注意力模块依次经过通道维度编码、Top-k稀疏注意力计算、SAM空间注意力增强,最终通过残差连接输出特征图,模块结构如图3所示。

ASTSA使用Top-k选择算子^[28]来选择最大的 k 个相似度分数,忽略其他较小的分数,使模型聚焦于目标的细节信息,抑制潜在噪声,结合SAM(Spatial Attention Module)模块捕捉空间全局关联以构建完整目标特征,最后通过高效残差融合策略实现双重增益,解决空间卫星目标图像背景噪声干扰强,目标特征易被淹没,空间长距离依赖建模不足的问题

给定维度为 $R^{L \times d}$ 的 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$,Transformer中的标准自注意力的输出表达式为:

$$\text{Att}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\lambda}\right)\mathbf{V}, \quad (10)$$

其中: $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别表示查询、键和值的矩阵形式。 λ 是可选的温度因子,定义为 $\lambda = \sqrt{d}$ 。不同于传统密集自注意力,ASTSA先通过 1×1 卷积后接 3×3 深度卷积编码通道维度上下文。接下来,计算所有重塑后的 $\mathbf{Q} \sim \mathbf{K}$ 之间的像素对相似度,并在尺寸为 $R^{c \times c}$ 的转置注意力矩阵 \mathbf{M} 中,屏蔽掉分配有较低注意力权重的不必要元素。与随机丢弃分数的dropout策略不同,本文在 \mathbf{M} 上自适应选择Top-k个有贡献的分数,保留最重要的特征通道并去除冗余特征。这里, k 是一个可调节参数,初始取值为通道数的1/4,通过梯度下降自适应优化,用于动态控制稀疏度大小,其通过适当比例的加权平均获得。因此,仅对 \mathbf{M} 每行中位于 $[\Delta_1, \Delta_2]$ 范围内的Top-k值进行归一化,用于softmax计算。对于其他小于Top-k分数的元素,本文使用scatter函数将其在指定索引处的概率替换为0。这种动态选择使注意力从密集变为稀疏,其表达式为:

$$\text{SparseATT}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(T_k\left(\frac{\mathbf{Q}\mathbf{K}^T}{\lambda}\right)\right)\mathbf{V}, \quad (11)$$

其中, T_k 是可学习的top-k选择算子:

$$[T_k(S)]_{ij} = \begin{cases} S_{ij}, & S_{ij} \in \text{top-k} \\ 0, & \text{otherwise} \end{cases}. \quad (12)$$

最后,通过矩阵乘法将softmax结果与 \mathbf{V} 相乘得到最终结果。为补全空间长距离依赖建模能力,引入SAM注意力机制,对原始输入特征图

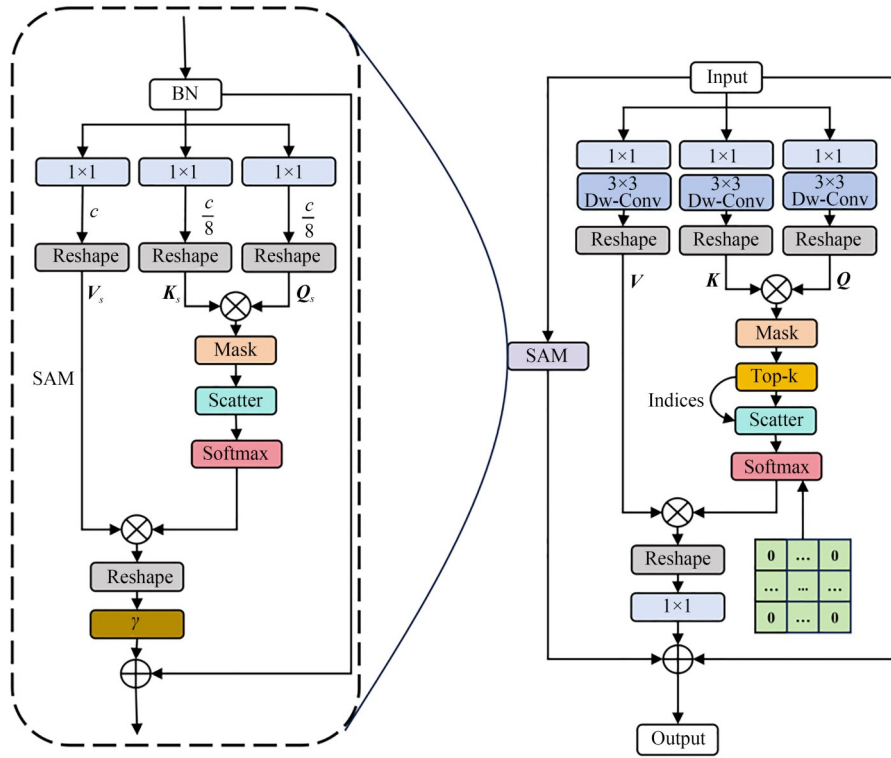


图3 ASTSA注意力
Fig. 3 ASTSA Attention

X , 通过 3 个独立的 1×1 卷积生成空间维度的 Q_s, K_s, V_s 。 Q_s 和 K_s 的通道维度降为 $c/8$ 以降低计算复杂度, V_s 保持原始通道维度 c 以保留完整特征信息。引入可学习缩放参数 γ , 初始化为全 0 张量, 动态调节注意力强度, 最后结合残差连接避免原始特征信息丢失, 计算注意力过程如下:

$$\text{SpatialATT}(Q_s, K_s, V_s) = \gamma \cdot \text{soft max} \left(\frac{Q_s \cdot K_s^T}{\lambda} \right) V_s \quad (13)$$

最后采用并行残差实现通道稀疏特征、空间增强特征以及原始特征的融合, 既保留各特征的核心优势, 又避免特征的冗余和信息丢失。ASTSA 模块结构如图 4 所示。计算过程如下:

$$\text{ASTSA}(x) = \text{SparseATT} + \text{SpatialATT} + x \quad (14)$$

C3K2_ASTSA 继承 C3K2 的连接核心架构, 将 ASTSA 注意力嵌入模块瓶颈结构中, 实现空间与通道双维度优化。C3K2_ASTSA 模块结构如图 4 所示。输入特征图经 Split 分支后, 经标准卷积特征提取, 另一路经嵌入 ASTSA 注意力的瓶颈结构进行特征增强, 最终通过 Concat 与卷积

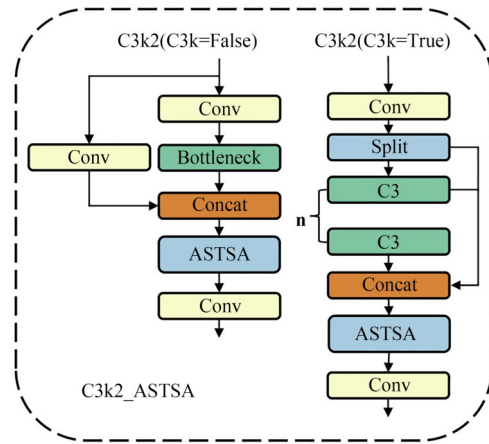


图4 C3k2_ASTSA 模块
Fig. 4 C3k2_ASTSA module

融合输出。

2.4 多尺度大核分解注意力 MLKDA

针对空间目标多尺度分布、固定感受野难以适配不同尺度目标的核心挑战, 本文提出多尺度大核分解注意力 MLKDA 模块, 嵌入到主干网络中。该模块的输入为特征图 $X \in R^{B \times C \times H \times W}$ (B 为批量大小, C 为通道数, H, W 为特征图高宽), 首先执行层归一化, 缓解特征尺度差异导致的注意

力计算偏差,其数学表达式为:

$$X_{\text{norm}} = \gamma \cdot \frac{X - \mu}{\sqrt{\sigma^2 - \epsilon}} + \beta, \quad (15)$$

其中: μ 和 σ^2 分别为特征图沿空间维度的均值与方差, γ, β 为可学习参数(初始化为1和0),用于自适应调整特征分布, $\epsilon = 10^{-6}$ 为数值稳定项,避免方差趋近于0时的计算异常;随后通过 1×1 点卷积PWConv将通道数从 C 扩展至 $2C$,该设计的核心目的是实现注意力权重生成与原始特征保留的解耦,扩展后的特征按通道维度拆分为两部分,注意力计算分支 $a \in \mathbb{R}^{B \times C \times H \times W}$ 负责提取特征关联性以生成权重,特征保留分支 $x \in \mathbb{R}^{B \times C \times H \times W}$ 负责保留原始特征的细节信息。为适配多尺度目标检测需求,进一步将注意力计算分支 a 按通道维度均分为4个并行分支(每个分支通道数为 $C/4$,记为 a_1, a_2, a_3, a_4),分别对应 $3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9$ 四种尺度的大核卷积分支, 3×3 核聚焦空间目标的局部细节特征如天线端点、太阳能板边缘拐点, 5×5 和 7×7 核捕捉中等尺度结构如太阳能板主体、舱体局部, 9×9 核覆盖全局结构特征如完整卫星舱体,实现从细节到全局的全尺度特征覆盖。针对传统大核卷积计算量激增的问题,部分分支采用深度可分离卷积DWConv分解策略,以 9×9 大核为例, 1×9 长条状深度可分离卷积DWConv 1×9 与 9×1 长条状深度可分离卷积DWConv $9 \times 1, 1 \times 9$ 和 9×1 核强化对长条状太阳能板、不规则天线等非对称结构的特征捕捉。为进一步强化特征判别性,每个分支引入双路径特征增强机制:将分解卷积输

出与对应尺度的普通深度可分离卷积(DWConv 3×3 对应 a_1 、DWConv 5×5 对应 a_2 等)输出进行逐元素乘法,其中分解卷积负责扩大感受野,普通深度卷积负责强化局部特征关联性;随后将4个分支的增强特征沿通道维度拼接,生成全局注意力权重图 $A \in \mathbb{R}^{B \times C \times H \times W}$,该权重图可自适应凸显不同尺度目标的关键特征;将权重图 A 与特征保留分支 x 进行逐元素加权融合,得到 $X_{\text{weight}} = x \otimes A$,实现注意力对原始特征的定向增强;最后通过 1×1 点卷积将特征通道数恢复至原始维度,同时引入可学习缩放参数 $\alpha \in \mathbb{R}^{1 \times C \times 1 \times 1}$ (初始化为全0张量),用于动态调整注意力增强特征的贡献强度。该参数通过梯度下降优化自适应更新对目标检测有益的特征通道, α 会学习到较大值以强化其贡献;反之, α 会自动减小以抑制干扰,最终通过残差连接实现增强特征与原始特征的自适应平衡,最终输出公式为:

$$X_{\text{out}} = \text{PWConv}(X_{\text{weight}}) \cdot \alpha + X, \quad (16)$$

其中:PWConv表示点卷积操作,用于整合加权后的特征通道。MLKDA模块通过多尺度大核分解与通道分流注意力的深度耦合,嵌入到主干网络中,实现了 3×3 至 9×9 尺度范围的全覆盖,精准适配空间目标从小型部件到完整结构的特征分布,显著提升稀疏特征的聚合能力,为后续空间目标的精准定位与分类提供了高鲁棒性、高判别性的特征支撑,尤其适配复杂光照如强光干涉、低光照与多尺度混合场景下的检测需求。MLKDA模块结构如图5所示。

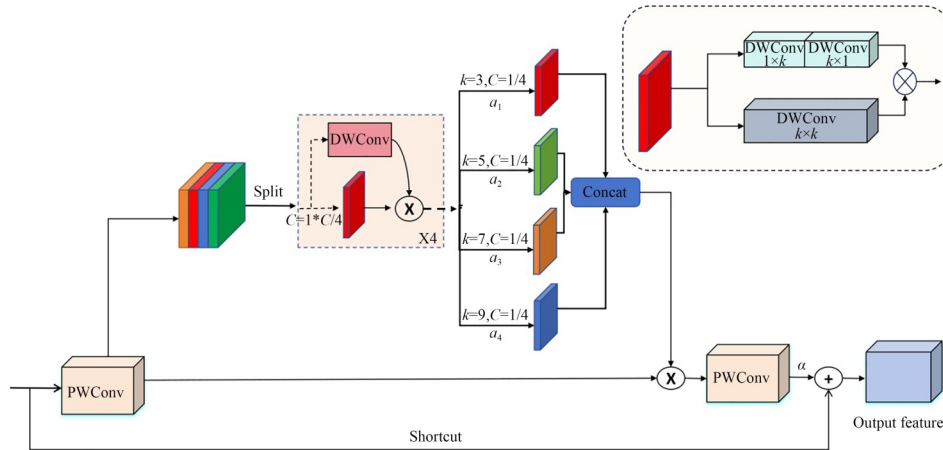


图5 多尺度大核分解注意力MLKDA

Fig. 5 Multi-scale large-kernel decomposition attention MLKDA

3 实验结果与分析

3.1 数据集

深度学习模型的性能在很大程度上依赖于大规模且高质量的训练数据的可用性。然而,公开可用的空间卫星数据集仍然极为稀缺。这种稀缺性主要归因于太空影像的敏感性以及对其获取的严格限制;同时,太空环境的复杂性如强光干涉、暗光成像等进一步加剧了空间目标检测的难度,现有公开数据集难以匹配真实在轨场景的检测需求。为应对上述挑战,本文搭建了航天器在轨模拟观测系统,构建了一套专用空间卫星数据集,用于改进模型的性能验证,同时为空间目标检测与识别研究提供丰富的基准资源。该数据集共包含 8 000 张标注图像,聚焦卫星、太阳能电池板、不规则球形天线三类核心空间目标,构建过程充分考虑目标不同观测角度、多尺度分布及强光干涉、暗光环境两类复杂成像条件。

3.1.1 数据采集与模拟观测系统搭建

本文搭建的航天器在轨模拟观测系统由三轴电动转台、空间目标模拟源、太阳光模拟系统、高分辨率光学成像设备四部分构成:三轴转台用于模拟卫星在轨运行的俯仰、偏航、滚转姿态变化;空间目标模拟源包含 1:20 缩比的卫星本体、太阳能电池板、球形天线模型,覆盖真实卫星的核心结构特征;太阳光模拟系统可实现 100 000 lx 的照度连续调节,用于模拟在轨强光直射、地球反照、暗光阴影等复杂光照场景。成像设备采用自研相机,核心参数如下:传感器类型为全局快门 CMOS,分辨率 $2\,592 \times 1\,944$,像元尺寸 $2.2 \times 2.2 \mu\text{m}$,镜头焦距 25 mm,光谱响应范围 400~1 000 nm,最大帧率 14 fps。采集过程中,目标观测距离范围为 2~20 m,对应成像尺寸范围为 $32 \times 32 \sim 600 \times 600$ pixels,完整覆盖在轨近距离观测的目标尺度范围。

数据集原始影像通过上述系统采集,模拟近地轨道真实观测场景,采集过程严格控制成像质量以保障数据有效性。采集范围覆盖三类目标的全场景特性:卫星目标包含完整舱体及不同在轨姿态;太阳能电池板涵盖长条状阵列的不同摆放角度与尺度,宽高比覆盖 5:1~20:1;不规则球形天线包含不同直径规格及表面反射特性差异。

成像环境的量化标准如下:强光干涉场景照度范围 80 000~100 000 lx,对应图像局部过曝区域占比 10%~30%;暗光环境照度范围 50~500 lx;同时纳入正常光照样本以实现场景均衡。

原始采集图像共 9 100 张,经质量筛选剔除模糊、运动拖影、目标占比 $< 0.05\%$ 的无效样本后,最终保留有效样本 8 000 张,统一标准化为 640×640 pixels,确保像素级特征完整性与模型训练适配性。

3.1.2 数据标注规范

采用 LabelImg 标注工具完成目标边界框标注,标注格式采用 YOLO 标准格式,适配后续改进模型的训练需求,对标注偏差 > 2 像素的样本进行二次复核,最终标注准确率 $\geq 98\%$,保障数据集标注质量。明确划分三类目标:卫星本体:含完整舱体及姿态控制系统的一体式空间目标;太阳能电池板:长条状阵列结构,宽高比 $\geq 5:1$,为卫星能量供给部件;不规则球形天线:球形主体带凸起或凹陷结构的通信部件。卫星本体、太阳能电池板和不规则球形天线的数量分别为 7 990(49.3%),4 995(30.8%),3 230(19.9%)

3.1.3 数据集划分

采用分层抽样策略划分数据集,严格保证各类别、场景及尺度样本的分布一致性,按 8:1:1 的比例划分为训练集(6 400 张)、验证集(800 张)和测试集(800 张),分别用于模型参数优化、超参数调优与泛化性能评估。

3.1.4 数据增强策略

针对空间目标样本特性,仅对训练集执行 4 类定向数据增强:(1)几何变换增强,模拟卫星在轨姿态变化;(2)光照与噪声增强,提升模型对复杂光照与传感器噪声的鲁棒性;(3)小目标专项增强,缓解小型天线样本稀缺导致的漏检问题;(4)Mosaic 增强,丰富多目标场景的样本多样性,抑制模型过拟合。

3.1.5 与公开数据集的对比

本文自建空间卫星数据集与主流公开的空间目标数据集(SPAEK 和 SPEED+)的核心对比如下:


(1)本文数据集包含 8 000 张有效标注样本,完整覆盖了暗光阴影、常规光照、强光干涉三类在轨典型光照场景,而 SPARK 数据集仅包含深

空背景下的常规光照样本, SPEED + 数据集以实验室暗箱固定光照场景为主, 二者均缺乏在轨极端光照与复杂背景样本, 本文数据集的场景覆盖更全面, 与真实在轨观测环境的匹配度更高。

(2) 本文数据集针对在轨服务的核心感知需求, 完成了卫星本体、太阳能电池板、球形天线三类关键部件的精细化标注, 可同时支撑完整卫星检测与部件级精细化识别任务; 而 SPARK, SPEED+ 等公开数据集仅对完整卫星本体进行单类别标注, 无部件级标注信息, 无法适配在轨捕获、维修等近距离服务的精细化感知需求, 本

文数据集的标注体系更贴合在轨工程应用场景。数据集样本如图 6 所示。


此外, 为了论证改进模型的泛化能力, 本文引入 ExDark (Exclusively Dark Image Dataset) 数据集验证改进模型的普遍性。ExDark 数据集是低照度目标检测领域的权威通用基准, 包含 12 类常见检测目标、总计 7 363 张低照度图像, 覆盖室内外 10 种不同暗光成像环境。与本文自建数据集同属低信噪比、低对比度的暗弱成像场景, 可有效验证模型暗光检测能力的通用有效性。针对本文空间目标检测模型的论证需求, 对 Ex-



(a) 不同角度和尺度的卫星
(a) Satellites with different angles and scales



(b) 强光干涉下的卫星
(b) Satellites under strong light interference



(c) 暗光环境下的卫星
(c) Satellites in low-light environment

图 6 部分空间卫星数据集图片

Fig. 6 Images from the partial space object dataset

Dark 数据集进行针对性适配处理,保障实验数据处理的一致性,避免数据预处理差异影响实验结果的客观性。通过模型在该数据集上的检测性能,验证模型是否能将空间目标检测任务中学习到的特征提取、目标定位能力,迁移至类似形态的通用目标检测任务中,弥补空间卫星数据集仅能验证专用场景性能的局限。

3.2 实验环境

实验硬件采用配备双路 Intel Xeon Platinum 8368 处理器与 NVIDIA GeForce RTX 4090 显卡的服务器,软件基于 Ubuntu 20.04.3 LTS 系统与 PyTorch 2.5.1 框架,CUDA 与 cuDNN 均按硬件兼容性适配优化。为保证公平对比,所有模型均采用默认配置。除此之外,各模型的其他参数均采用官方默认的针对检测任务的最优超参数,所有模型均训练至完全收敛。

3.3 评价指标

在实验中,通过以下五个指标进行评估:(1)浮点运算(FLOPs/G):反映计算复杂度,代表模

型的计算资源需求;(2)平均准确率(mAP):数据集中所有类别的平均准确率;(3)参数量(Params):衡量模型复杂性的重要指标,直接影响模型的存储需求、计算成本和训练时间;(4)FPS、精度(P)和召回率(R):这些是评估分类器性能的重要指标。

3.4 消融实验

为了验证每个改进模块在空间卫星检测任务中的性能,本文设计了一系列基于基线模型 YOLOv11 的消融实验。在消融实验中,本文先后引入了三种先进的增强技术:移动风车卷积 SPCConv, C3K2_ASTSA 检测头和多尺度大核分解注意力 MLKDA。每种技术的引入旨在提升模型的性能。空间卫星数据集聚焦非对称结构、多尺度分布及复杂光照场景,消融实验结果如表 1 所示,模型设计考虑了特征提取能力的提升和针对空间目标的优化利用。空间卫星数据集的消融实验结果如表 1 所示,√表示对基线模型中的对应模块进行了改动。

表 1 空间卫星数据集消融实验结果

Tab. 1 Ablation experimental results on the self-built space satellite dataset

SPCConv	C3K2_ASTSA	MLKDA	P%	R%	mAP@0.5	mAP@0.5:0.95	FLOPs/G	Params/M
			0.847	0.842	0.905	0.549	6.3	2.58
√			0.851	0.846	0.916	0.562	5.8	2.34
	√		0.855	0.844	0.918	0.559	6.7	3.03
		√	0.859	0.847	0.914	0.561	6.5	2.41
√	√		0.858	0.851	0.921	0.569	6.2	2.98
√		√	0.861	0.848	0.929	0.565	6.0	2.39
	√	√	0.869	0.849	0.931	0.568	6.9	3.24
√	√	√	0.884	0.855	0.937	0.578	7.2	3.42

首先,将 YOLOv11n 主干网络和颈部网络中的部分 C3K2 卷积替换为 SPCConv 模块,mAP@0.5 提升了 1.1%,mAP@0.5:0.95 提升了 1.3%,验证了其非对称感受野对卫星非对称结构特征的精准捕捉能力;在头部网络中融入 C3K2_ASTSA 特征检测头,mAP@0.5 提升了 1.3%,精度提升了 0.8%,证明其可有效抑制背景噪声、提升目标特征判别性;加入 MLKDA 注意力后进行更精准的目标定位,mAP@0.5 提升了 0.9%,召回率提高了 0.5%,其多尺度大核卷积设计实现 3×3 至 9×9 尺度全覆盖,验证了其

多尺度特征覆盖能力。三个模块同时引入后,模型实现全面性能最优,Sat-YOLO 在 mAP、精度及召回率均显著优于基线模型,mAP@0.5:0.95 提升幅度达 2.9%,充分证明三者形成非对称特征提取、噪声抑制与特征增强、多尺度特征聚合的完整提升,同时参数数量的上升幅度得到了有效控制。

为直观验证模型的特征关注特性,如图 7 所示,给出了基线 YOLOv11n 与本文 Sat-YOLO 在空间卫星数据集上的热力图对比。由图可知,基线模型存在背景噪声无效响应多、小目标关注度

低、非对称组件特征关注不连贯的缺陷;而 Sat-YOLO 可有效抑制背景噪声,显著提升对小目标

与非对称组件的特征关注度,目标区域响应集中且连贯,与定量实验的精度提升结果一致。




图 7 空间卫星数据集热力图对比

Fig. 7 Heat Map Comparison on the Space Satellite Dataset

图 8 为 YOLOv11 和 Sat-YOLO 在空间卫星数据集上的 $mAP@0.5$, $mAP@0.5:0.95$, Precision 和 Recall 曲线,由图 9 可得, Sat-YOLO 在 $mAP@0.5$ 和 $mAP@0.5:0.95$ 两个指标上分别提升了 3.2% 和 2.9%,从而验证了本文所提方案的有效性和实用性。而且, Sat-YOLO 相较于原始 YOLOv11n,有更高的准确率和召回率,分别提高了 3.7% 和 1.3%,检测性能更加优越。

SPConv 是通过无参数循环移位操作实现稀疏特征聚合,为量化其对空间卫星目标的特征增强增益,本节设计单变量对照实验:保持 SPConv

其余结构完全不变,仅移除循环移位操作,对比检测性能与特征质量指标。实验结果如表 2 所示。

实验结果表明,循环移位操作为无参数设计,不会增加模型的参数量与计算量,加入后可使模型 $mAP@0.5$ 较无循环移位进一步提升,可有效聚合空间卫星图像中分散的目标特征,抑制深空背景噪声,完美适配空间目标特征稀疏、分布分散的场景特性。

为进一步验证 SPConv 模块在空间卫星检测场景中的优越性,本节选取当前主流的卷积模块作为对照,如深度可分离卷积^[29](DWConv)、空

表 2 SPConv 循环移位对比实验

Tab. 2 Comparative experiments on SPConv cyclic shift

SPConv module	P%	R%	$mAP@0.5$	$mAP@0.5:0.95$	FLOPs/G	Params/M
No cyclic shift	0.845	0.844	0.908	0.551	5.7	2.32
With cyclic shift	0.851	0.846	0.916	0.562	5.8	2.34




图 8 空间卫星数据集消融实验对比

Fig. 8 Ablation experiment comparison on the space satellite dataset

洞卷积^[30](DConv)、大选择核卷积^[31](LSK-Conv)。保持主干网络与Neck层的下采样卷积

位置完全替换为对应模块,其余所有实验条件完全一致,横向对比结果如表3所示。

表 3 不同卷积模块的对比实验结果

Tab. 3 Comparison experimental results of different convolution modules

Convolution	P%	R%	mAP@0.5	mAP@0.5:0.95	FLOPs/G	Params/M
Conv	0.847	0.842	0.905	0.549	6.3	2.58
DWConv	0.842	0.838	0.897	0.541	5.5	2.21
DConv	0.845	0.840	0.901	0.545	5.7	2.38
LSKConv	0.849	0.843	0.908	0.543	6.5	2.72
SPConv	0.851	0.846	0.916	0.562	5.8	2.34

综上实验结果可知,本文提出的SPConv模块,既通过风车状非对称卷积设计实现了对卫星非对称结构特征的精准捕捉,又借助新增的循环移位操作完成了对稀疏分散目标特征的跨位置聚合,在不增加参数数量的前提下,实现了检测精度的显著提升,在所有对比模块中取得了最优的综合性能。

为验证本文提出的MLKDA模块对空间卫星多尺度目标的特征增强效果,以及相较于现有主流注意力模块的性能优势,选取几大主流注意

力模块如通道注意力^[32](Convolutional Block Attention Module, CBAM)、坐标注意力^[33](Coordinate Attention, CA)、高效通道注意力^[34](Efficient Channel Attention, ECA)、选择性核注意力^[35](Selective Kernel Network, SKNet)作为对照,保持主干网络中模块的嵌入位置、输入输出通道、其余网络结构与前述实验完全一致,结果如表4所示。

由上表可以看出,CBAM,CA,ECA等单尺度注意力模块仅依赖固定 3×3 卷积构建单一感

表 4 不同注意力模块的对比实验结果

Tab. 4 Comparison experimental results of different attention modules

Attention	P%	R%	mAP@0.5	mAP@0.5:0.95	FLOPs/G	Params/M
/	0.847	0.842	0.905	0.549	6.3	2.58
CBAM	0.849	0.844	0.909	0.553	7.9	3.51
CA	0.852	0.845	0.906	0.556	7.4	3.43
ECA	0.850	0.843	0.910	0.554	7.6	3.41
SKNet	0.855	0.846	0.911	0.552	6.9	2.98
MLKDA	0.859	0.847	0.914	0.561	6.5	2.41

受野,无法适配空间卫星的多尺度分布特性,易出现小目标细节特征丢失、大目标全局特征提取不完整的问题,因此仅能实现小幅精度提升;而 MLKDA 采用四分支并行结构,实现全尺度感受野覆盖,可同时捕捉小目标的细节纹理与大目标的全局轮廓,完美适配空间多尺度检测需求, mAP@0.5 提升幅度远超同类单尺度注意力模块。SKNet 多尺度注意力模块仅覆盖 $3 \times 3, 5 \times 5$ 两个尺度,对大尺寸卫星舱体的全局特征捕捉能力不足,且未针对非对称结构做定向优化,对长条状太阳能板的特征强化能力有限;而 MLKDA 对 5×5 及以上大核采用水平和垂直长条状卷积分解,在扩大感受野的同时,强化了对非对称长条状结构的定向特征提取,与空间卫星目标的结构特性高度契合,在参数量更低的前提下,实现了更优的检测性能。

3.5 对比实验

为验证本文所提 Sat-YOLO 模型的综合性能,选取近年来目标检测领域不同框架的优秀模型作为对比对象,在空间卫星数据集与 ExDark 公共数据集上开展公平对比实验。对比模型涵盖单阶段检测模型(SSD, YOLO 系列),核心技术路径为通用自然场景的平衡优化,未针对空间卫星检测的场景特性做定向改进;Transformer-based 检测模型(DINO, RT-DETR-l)为自注意力全局特征建模,具备强上下文建模能力但存在计算量与参数量过大的问题;空间卫星检测专用模型(YSKB, MHSA-YOLOv5s),为当前领域内针对空间目标检测的 SOTA 方案。具体对比模型为 SSD, DINO^[36], RT-DETR-l^[37], YOLOv8n, YOLOv11n, YOLO26n, YKSB, MHSA-YOLOv5s。实验核心对比指标包括精度(P%)、召回率(R%)、平均精度(mAP@0.5, mAP@0.5:

0.95)、FPS、计算量(GFLOPS)及参数量(Params/M)。在空间卫星数据集的对比实验结果如图 9 所示。

图 9 的可视化结果直观展示了各对比模型在空间卫星数据集上的检测效果, YOLOv8n, YOLO26n 仍受限于传统对称卷积结构,对目标与背景灰度差异小的低对比度场景适配不足,背景区域存在无效特征响应,且小目标的检测框完整性较差。YOLOv11n 基线模型在强光、暗光复杂样本中,存在目标检测框的定位精度不足,与基线模型的召回率、定位精度短板形成对应;DINO, RT-DETR-l 等 Transformer-based 模型虽具备较强的全局特征捕捉能力,但在弱纹理、多部件分散的空间目标场景中,易出现目标部件间的特征混淆,检测框与目标轮廓的贴合度较差;YSKB, MHSA-YOLOv5s 等空间专用模型虽针对空间目标做了特征增强优化,但在极端光照场景下,目标检测置信度出现明显下降,对弱纹理目标的特征捕捉能力仍有不足;与之相比,本文 Sat-YOLO 模型的检测效果最优,在各类复杂场景中均无目标漏检情况,检测框与目标轮廓精准贴合,不仅能完整识别卫星舱体主体,还能清晰捕捉小型球形天线、长条状太阳能电池板等细节部件,且所有目标的检测置信度显著高于其他对比模型,充分体现了其在航天器目标检测场景中的强适配性与性能优势。

空间卫星数据集的对比实验结果如表 5 所示,从实验结果可以看出,本文所提 Sat-YOLO 模型在各项核心评估指标中均优于所有对比模型。在精确率方面, Sat-YOLO 达到 88.4%, 高于所有对比模型,表明其对航天器目标的识别准确性更高,误检率更低;在召回率方面, Sat-YO-




图 9 空间卫星数据集上的图像检测结果

Fig. 9 Image detection results on the space satellite dataset

表 5 空间卫星数据集的对比实验结果

Tab. 5 Comparison experimental results on the spatial celestial object dataset

Model	P%	R%	mAP@0.5	mAP@0.5:0.95	FPS	FLOPs/G	Params/M
SSD	0.870	0.839	0.899	0.533	40.3	115	26.35
DINO	0.877	0.844	0.901	0.541	15	190	32.57
RT-DETR-l	0.879	0.851	0.927	0.568	80	108	32.97
YOLOv8n	0.835	0.831	0.898	0.542	82	8.1	3.08
YOLOv11n	0.847	0.842	0.905	0.549	95	6.3	2.58
YOLO26n	0.878	0.848	0.919	0.561	108	5.8	2.39
YSKB	0.871	0.839	0.906	0.545	73	17.2	14.8
MHSA-YOLOv5s	0.869	0.836	0.912	0.551	70	18.51	15.9
Sat-YOLO	0.884	0.855	0.937	0.578	97	7.2	3.42

LO为85.5%,略高于RT-DETR-l和YOLO26n,显著高于其他对比模型,说明其能更全面地捕捉航天器目标及组件,有效降低小目标漏检率;在平均精度方面,Sat-YOLO的mAP@0.5达到93.7%,较基线模型YOLOv11n提升3.2%,较RT-DETR-l提升1%,较YOLO26n提升1.8%,mAP@0.5:0.95达到57.8%,同样领先于所有对比模型,证明其在不同置信度阈值下均能保持优异的检测性能;在实时性方面,Sat-YOLO参数量仅3.42M,虽略高于YOLO26n与YOLOv11n,但远低于SSD,DINO,RT-DETR-l及

空间专用模型YSKB,MHSA-YOLOv5s,同时FPS达97,满足在轨实时检测需求,具备优异的工程部署潜力。

为验证本文模型在暗弱目标检测场景下的通用适配能力,排除模型对航天专属场景的过拟合风险,本文选取ExDark低照度数据集开展跨场景对比实验。本文自建的空间卫星数据集与ExDark数据集同属暗弱成像场景,与本文Sat-YOLO改进的设计目标高度契合,本文在ExDark数据集上完成横向对比实验,实验可视化结果如图10所示。

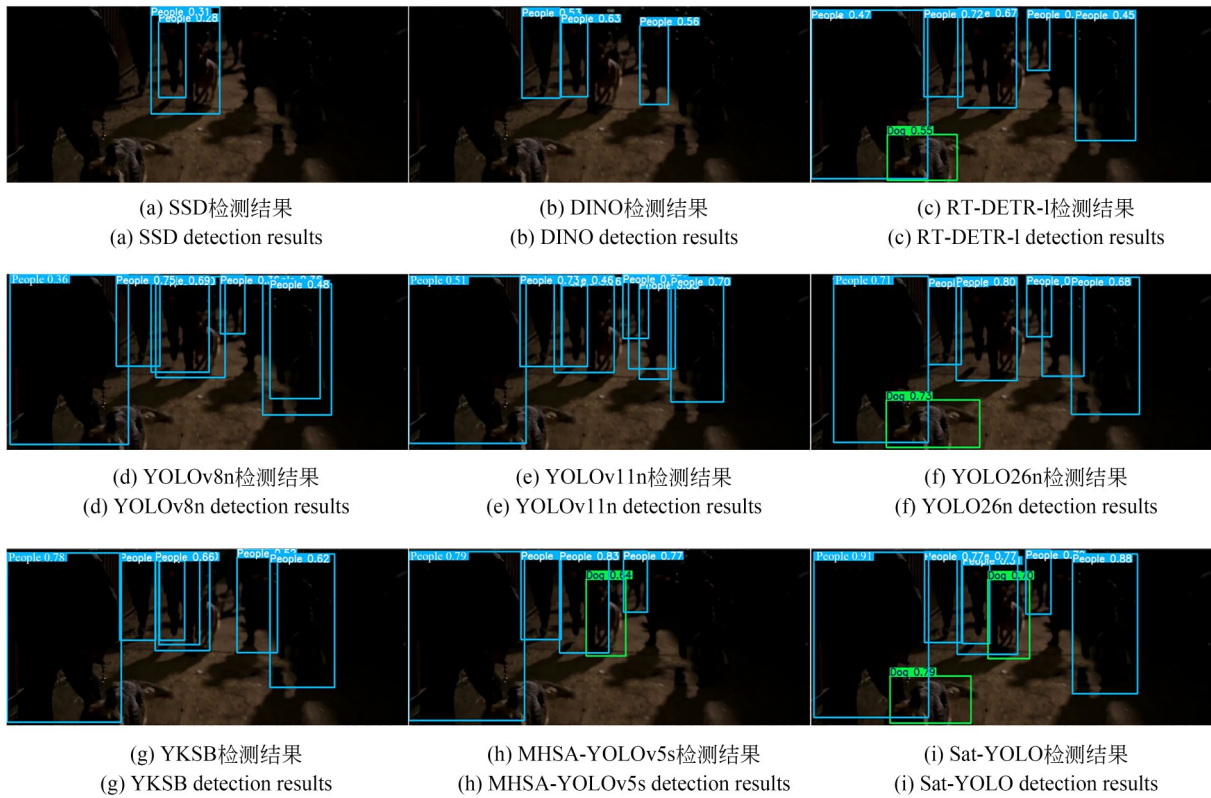


图 10 ExDark 数据集上的图像检测结果

Fig. 10 Image detection results on the exdark dataset

图 10 为各对比模型在 ExDark 公开数据集上的检测结果可视化对比,样本覆盖了夜间室外、室内弱光、逆光强噪声、低对比度目标融合四类暗光检测核心挑战场景。由图可知,本文提出的 Sat-YOLO 模型在所有典型暗光场景中均实现了最优检测效果,无目标漏检情况,检测框与各类目标的真实轮廓精准贴合,即使在强噪声、低对比度的极端暗光环境中,仍能保持稳定的高检测

置信度。

定量实验结果如表 6 所示。实验结果表明,本文提出的 Sat-YOLO 模型在 ExDark 数据集上取得了同量级模型中的最优综合检测性能,mAP@0.5 达到 89.5%,相较于本文基线模型 YOLOv11n 提升 3.1%,mAP@0.5:0.95 达到 55.2%,较基线模型提升 2.9%;同时,本文模型的检测性能显著优于 SSD, YOLOv8n, YO-

表 6 ExDark 数据集的对比实验结果

Tab. 6 Comparison experimental results on the ExDark dataset

Model	P%	R%	mAP@0.5	mAP@0.5:0.95	FPS	FLOPs/G	Params/M
SSD	86.2	78.5	82.3	48.6	40.3	115	26.35
DINO	82.7	76.3	79.5	45.2	15	190	32.57
RT-DETR-l	84.1	80.2	83.6	50.1	80	108	32.97
YOLOv8n	85.3	81.5	85.2	51.7	82	8.1	3.08
YOLOv11n	85.7	82.1	86.4	52.3	95	6.3	2.58
YOLOv26n	86.5	82.8	87.2	53.1	108	5.8	2.39
YSKB	86.3	83.0	87.0	52.8	73	17.2	14.8
MHSA-YOLOv5	86.5	83.2	86.9	52.6	70	18.51	15.9
Sat-YOLO	88.1	84.3	89.5	55.2	97	7.2	3.42

LO26n 等同量级轻量级检测模型,也超越了 DINO,RT-DETR-l 等大参数量高精度 Transformer 类模型。在轻量化指标上,Sat-YOLO 模型始终保持 3.42 M 的参数量与 7.2 GFLOPs 的计算量,仅较基线模型有极小幅提升,远低于同性能的大

参数量对比模型,实现了暗光检测精度与实时性部署特性的优化

3.6 空间卫星数据集的视觉实验效果

图 11 给出了 Sat-YOLO 在自建空间卫星数据集上的视觉检测结果,结果表明,即便在弱纹

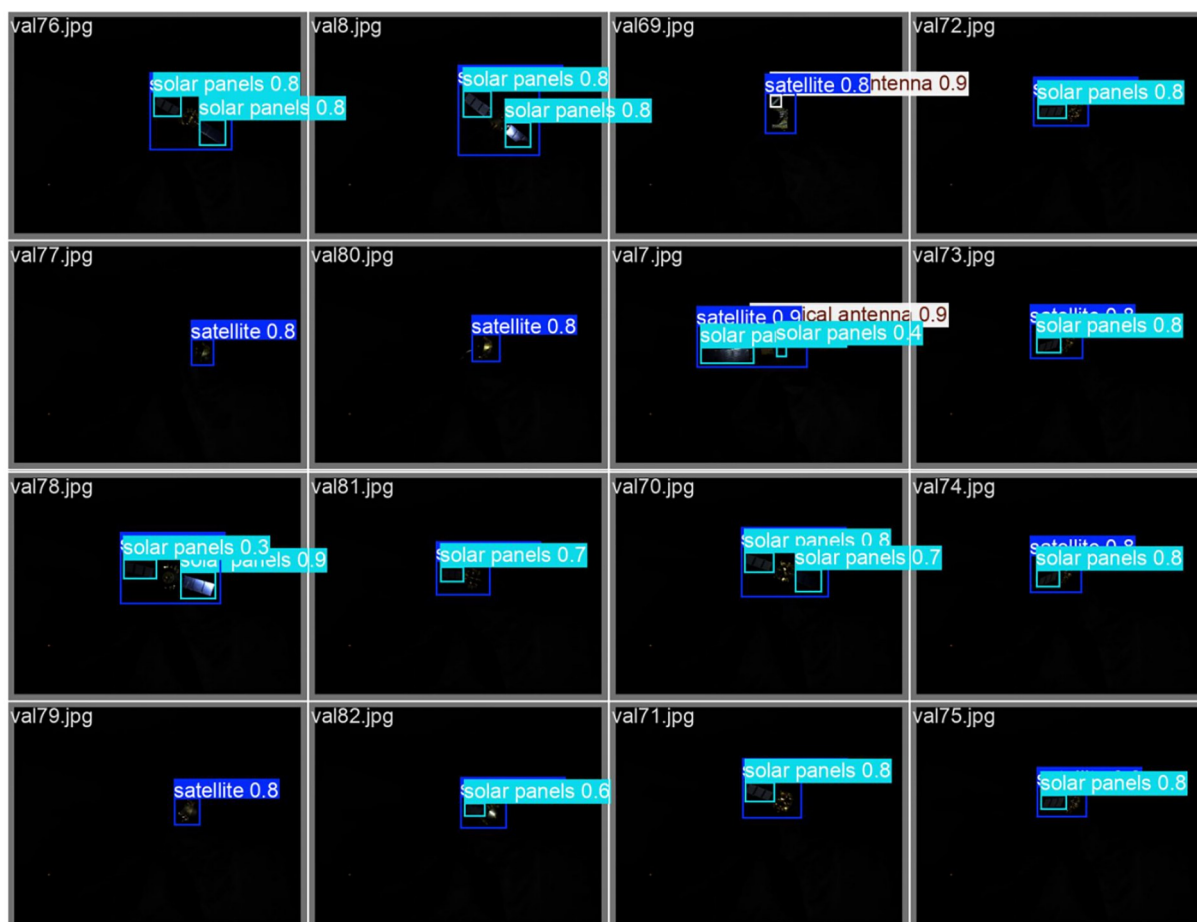


图 11 空间卫星数据集的视觉实验结果

Fig. 11 Some visual experiment results on the space object dataset.

理、低对比度的复杂太空环境中,Sat-YOLO 仍能精准检测卫星主体舱体、小型球形天线、长条状太阳能电池板等各类目标,检测框定位精准,无漏检、误检情况,且检测置信度均保持在较高水平,充分验证了模型的实际检测效果。

4 结 论

针对空间卫星目标检测存在的性能瓶颈,本文提出的改进 YOLOv11n 模型 Sat-YOLO,有效提升了检测精度。通过消融实验与对比实验,系统验证了所提模型在空间卫星检测任务中的有效性。首先在空间卫星数据集上开展针对性实验,性能对比显示,与基线模型 YOLOv11n 相比,所提模型的精确率提升 3.7%、召回率提升 1.3%、mAP@0.5 提升 3.2%、mAP@0.5:0.95 提升 2.9%,且综合性能优于当前主流目标检测模型。随后在 ExDark 公共数据集上验证了模型

的广泛适用性与鲁棒性。实验结果表明,该模型能够有效应对弱纹理、目标非对称、多尺度等复杂场景干扰下的目标检测任务,充分体现了其强环境适应性。未来研究将围绕两个方向展开:其一,进一步丰富空间卫星数据集的类别与场景覆盖,重点攻克极小空间目标的检测与优化难题;其二,推动所提模型在太空有效载荷中的高效部署与工程化应用。

作者贡献声明:

贾国瑜:测量方法的提出,论文构思和撰写;
测量实验的设计及数据整理和分析;
任龙:论文审核与编辑写作,管理与协调;
张海峰:论文的数据支持
肖海峰:整理数据,维护研究数据;
钟琼:分析合成研究数据,对研究结果和实验进行核实验证;
秦欣睿:对数据进行标注和整理。

参考文献:

- [1] 徐礼璐,薛武. HADN-Net: 面向暗弱天体目标检测的层次化注意力密集嵌套网络[J]. 光学精密工程, 2025, 33(17): 2792-2809.
XU L J, XUE W. HADN-Net: hierarchical attention dense nested network for faint astronomical target detection [J]. *Opt. Precision Eng.*, 2025, 33(17): 2792-2809. (in Chinese)
- [2] 郑鸿儒,马岩,张帅,等. 空间目标轨道外热流计算及辐射特性研究[J]. 中国光学(中英文), 2024, 17(1): 187-197.
ZHENG H R, MA Y, ZHANG S, *et al.* Calculation of orbit external heat flow and radiation characteristics of space target [J]. *Chinese Optics*, 2024, 17(1): 187-197. (in Chinese)
- [3] 汪亚妮,汪西莉. 基于注意力和特征融合的遥感图像目标检测模型[J]. 激光与光电子学进展, 2021, 58(2): 0228003.
WANG Y N, WANG X L. Remote sensing image target detection model based on attention and feature fusion [J]. *Laser & Optoelectronics Progress*, 2021, 58(2): 0228003. (in Chinese)
- [4] ZHUO X Y, TIAN J J. YOLO-pole: a deep learning framework for precise pole localization in aerial orthophotos [J]. *IEEE Geoscience and Remote Sensing Letters*, 2025, 22: 6008905.
- [5] YAN Y L. Application of the principle of common but differentiated responsibility and respective capabilities to the passive mitigation and active removal of space debris [J]. *Acta Astronautica*, 2023, 209: 117-131.
- [6] 刘胜利,郭裕兰,王刚. 基于注意力机制与动态激活的空间目标检测算法[J]. 激光与光电子学进展, 2022, 59(14): 1415021.
LIU S L, GUO Y L, WANG G. Space target detection algorithm based on attention mechanism and dynamic activation [J]. *Laser & Optoelectronics Progress*, 2022, 59(14): 1415021. (in Chinese)
- [7] BI J X, ZHENG X Y, LI K D, *et al.* SDWS-YOLO: a lightweight small object detection model for aerial remote sensing images [J]. *IEEE Signal Processing Letters*, 2025, 32: 4354-4358.
- [8] ALDAHOUL N, KARIM H A, DE CASTRO A, *et al.* Localization and classification of space objects using EfficientDet detector for space situational awareness [J]. *Scientific reports*, 2022, 12(1): 21896.
- [9] YANG Y C, DAI J H, WANG Y, *et al.* FM-RT-DETR: small object detection algorithm based on enhanced feature fusion with mamba [J]. *IEEE Sig-*

- nal Processing Letters*, 2025, 32: 1570-1574.
- [10] SVOTINA V V, CHERKASOVA M V. Space debris removal – Review of technologies and techniques. Flexible or virtual connection between space debris and service spacecraft[J]. *Acta Astronautica*, 2023, 204: 840-853.
- [11] BAO W Q, WANG P, HU W. MSPA-YOLO: remote sensing target recognition method based on improved YOLOv10[C]. 2025 *IEEE International Conference on Pattern Recognition, Machine Vision and Artificial Intelligence (PRMVAI)*. June 20-22, 2025, Loudi, China. IEEE, 2025: 1-5.
- [12] SHI S H, FANG Q, XU X, *et al.* Multiscale Gaussian attention mechanism for tiny-object detection in remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5635216.
- [13] QIN L, SHI Y, ZHANG X, *et al.* Salient object detection of dynamic night scenes *via* bio-inspired spotlight attention and hierarchical edge-texture fusion[J]. *IEEE Open Journal of Intelligent Transportation Systems*, 2025, 6: 1377-1390.
- [14] LIU Y, XIE Z W, LIU H. Three-line structured light vision system for non-cooperative satellites in proximity operations[J]. *Chinese Journal of Aeronautics*, 2020, 33(5): 1494-1504.
- [15] PARK T H, D'AMICO S. Adaptive neural-network-based unscented Kalman filter for robust pose tracking of noncooperative spacecraft[J]. *Journal of Guidance, Control, and Dynamics*, 2023, 46(9): 1671-1688.
- [16] HE J Y, EDDIE LAW K L. Deep learning models for rotated object detection in aerial images: survey and performance comparisons[J]. *IEEE Access*, 2024, 12: 180436-180457.
- [17] REED B B, SMITH R C, NAASZ B J, *et al.* *The Restore-1 Servicing Mission*[M]. AIAA space 2016. 2016: 5478.
- [18] 牛海鹏, 颜昌翔, 王一霖, 等. 基于快速局部对比度和目标特征的星图弱小目标检测算法[J]. *液晶与显示*, 2024, 39(1): 69-78.
- NIU H P, YAN C X, WANG Y L, *et al.* Star map spatial target detection method based on fast local contrast and target features[J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(1): 69-78. (in Chinese)
- [19] LIU C, GUO W L, HU W D, *et al.* Real-time vision-based pose tracking of spacecraft in close range using geometric curve fitting[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2020, 56(6): 4567-4593.
- [20] MAESTRINI M, DE LUCA M A, DI LIZIA P. Relative navigation strategy about unknown and uncooperative targets[J]. *Journal of Guidance, Control, and Dynamics*, 2023, 46(9): 1708-1725.
- [21] LI C, ZHAO G P, GU D Q, *et al.* Improved lightweight YOLOv5 using attention mechanism for satellite components recognition[J]. *IEEE Sensors Journal*, 2023, 23(1): 514-526.
- [22] SHEN N J, XV R, GAO Y, *et al.* An improved YOLOv5 model based on feature fusion and attention mechanism for multiscale satellite recognition[J]. *IEEE Sensors Journal*, 2024, 24(12): 19385-19396.
- [23] LIU Y F, WANG W J, YE R D, *et al.* Multi-head self-attention-incorporated YOLOv5s for satellites detection[J]. *IEEE Access*, 2024, 12: 167530-167541.
- [24] CHEN Y L, GAO J M, ZHANG K B. R-CNN-based satellite components detection in optical images[J]. *International Journal of Aerospace Engineering*, 2020, 2020(1): 8816187.
- [25] 寇鹏, 智帅峰, 程耘, 等. 空间目标自适应光学图像椭圆部件检测[J]. *中国光学*, 2022, 15(3): 454-463.
- KOU P, ZHI S F, CHENG Y, *et al.* Detection of elliptical components in adaptive optical image of space target[J]. *Chinese Journal of Optics*, 2022, 15(3): 454-463. (in Chinese)
- [26] 梁海翔, 唐艳慧, 王宇庆, 等. 高分辨率遥感图像的目标检测[J]. *液晶与显示*, 2024, 39(10): 1350-1360.
- LIANG H X, TANG Y H, WANG Y Q, *et al.* Object detection methods for high resolution remote sensing images[J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(10): 1350-1360. (in Chinese)
- [27] LIU W, ANGUELOV D, ERHAN D, *et al.* *SSD: Single Shot Multibox Detector*[M]. Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [28] CHEN X, LI H, LI M, *et al.* Learning a Sparse Transformer Network for Effective Image Deraining[C]. *Proceedings of the IEEE/CVF conference*

- on computer vision and pattern recognition. 2023: 5896-5905.
- [29] HOWARD A G, ZHU M L, CHEN B, *et al.* MobileNets: efficient convolutional neural networks for mobile vision applications [EB/OL]. 2017: *arXiv*: 1704.04861. <https://arxiv.org/abs/1704.04861>
- [30] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[EB/OL]. 2015: *arXiv*: 1511.07122. <https://arxiv.org/abs/1511.07122>
- [31] LI Y X, HOU Q B, ZHENG Z H, *et al.* Large selective kernel network for remote sensing object detection[C]. 2023 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 1-6, 2023, Paris, France. IEEE, 2024: 16748-16759.
- [32] WOO S, PARK J, LEE J Y, *et al.* CBAM: Convolutional Block Attention Module[M]. Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 3-19.
- [33] HOU Q B, ZHOU D Q, FENG J S. Coordinate Attention for Efficient Mobile Network Design [C]. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 20-25, 2021, Nashville, TN, USA. IEEE, 2021: 13708-13717.
- [34] WANG Q L, WU B G, ZHU P F, *et al.* ECA-net: efficient channel attention for deep convolutional neural networks[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 11531-11539.
- [35] LI X, WANG W H, HU X L, *et al.* Selective kernel networks[C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 15-20, 2019, Long Beach, CA, USA. IEEE, 2020: 510-519.
- [36] ZHANG H, LI F, LIU S L, *et al.* DINO: DETR with improved DeNoising anchor boxes for end-to-end object detection [EB/OL]. 2022: *arXiv*: 2203.03605. <https://arxiv.org/abs/2203.03605>
- [37] ZHAO Y A, LV W Y, XU S L, *et al.* DETRs Beat YOLOs on real-time object detection[C]. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 16-22, 2024, Seattle, WA, USA. IEEE, 2024: 16965-16974.

作者简介:



贾国瑜(1997—),男,山西晋中人,硕士研究生,2021年于中北大学获得学士学位,现为中国科学院大学在读硕士,主要从事计算机视觉图像处理方面的研究。E-mail: jiaguoyu369@outlook.com

通讯作者:



任龙(1988—),男,河南巩义人,博士,副研究员,硕士生导师,2010年于西安电子科技大学获得学士学位,2013年于西安电子科技大学获得硕士学位,2022年于西安交通大学获得博士学位,主要从事嵌入式软件开发、目标检测、计算机视觉方面的研究。E-mail: renlong@opt.ac.cn