

文章编号:1007-2780(XXXX)XX-0001-16

# YOLO26-DeepSpace:一种面向深空弱小目标的多尺度多目标检测跟踪网络

赵妍妍\*, 曹 玥

(吉林交通职业技术学院, 长春 130000)

**摘要:**在太空预警与空间目标监视系统中,为了有效探测各种空间碎片和其他体积小且信号弱的行星,需要正视深空环境下噪声干扰、目标特征微弱、轨迹非连续性等难题,提出了基于改进YOLO26的目标检测与跟踪算法。首先图像子区域自感知增强模块得到部署,通过局部对比度优化与边缘保护机制加强灰暗目标视觉特性的清晰程度;其次对YOLO26检测网络进行轻量化设计,引入了改进多尺度注意力模块GCEMA,加强弱小目标的检测能力;最终结合OCSort跟踪算法与外观重新识别模型CosmicReID,实现多目标编目与稳定跟踪。实验结果表明,与原始网络YOLO26和OCSort算法相比,改进后网络结构具有更少的参数数量和更快的推理速度,检测速度提高了11.9%;集成系统跟踪准确率提升了6.2%,目标身份切换频次减少48.5%。满足了自动跟踪测量系统的检测精度和跟踪精度等要求。

**关键词:**多目标跟踪;图像处理;目标检测;数据关联

中图分类号:TP391.41 文献标识码:A doi:10.37188/CJLCD.2026-0090 CSTR:32172.14.CJLCD.2026-0090

## YOLO26-DeepSpace: a multi-scale and multi-target detection and tracking network for dim and small targets in deep space

ZHAO Yanyan\*, CAO Yue

(Jilin Communications Polytechnic, Changchun 130000, China)

**Abstract:** In space early warning and space target surveillance systems, aiming to effectively detect various space debris and other small-size, weak-signal celestial targets, it is necessary to address the challenges in deep space environments such as noise interference, faint target features and discontinuous trajectories. Therefore, a target detection and tracking algorithm based on improved YOLO26 is proposed. Firstly, an image sub-region self-perception enhancement module is deployed to enhance the visual clarity of dim and dark targets via local contrast optimization and edge preservation mechanism. Secondly, the YOLO26 detection network is lightweighted, and an improved multi-scale attention module GCEMA is introduced to strengthen the detection capability for dim and small targets. Finally, combined with the OCSort tracking algorithm and the appearance re-identification model CosmicReID, multi-target cataloging and stable tracking are realized. Experimental results show that compared with the original YOLO26 network and OCSort algorithm, the improved network has fewer parameters and faster inference

收稿日期:2026-05-19;修订日期:2026-06-16.

基金项目:吉林省科技发展计划项目(No.20240206004YY)

Supported by Jilin Province Science and Technology Development Plan Item (No.20240206004YY)

\*通信联系人, E-mail: 13604311978@163.com

speed, with the detection speed increased by 11.9%; the tracking accuracy of the integrated system is improved by 6.2%, and the frequency of target identity switching is reduced by 48.5%. The proposed method meets the requirements on detection accuracy and tracking accuracy of automatic tracking and measurement systems.

**Key words:** multi-target tracking; image processing; object detection; data association

## 1 引言

近地轨道空间中的碎片持续大量增加,使得航天器安全和载人航天面临了新的难题,对碎片探测、预警、防护核心技术的需求变得非常紧迫<sup>[1-2]</sup>。地基空间目标监测时,光学观测设备具有价格适中、作用距离更远、测量数据准确三大优势,逐渐成为主流手段<sup>[3]</sup>。其中红外观测通过中波红外相机获取目标热辐射数据,结合先验信息分析可辨识目标特性<sup>[4-5]</sup>;高灵敏观测利用长曝光技术<sup>[6-7]</sup>探测远距离弱目标,二者协同可获得多维信息。然而,深空环境下的星点干扰、噪声污染及信噪比低等问题,严重制约了目标检测精度。

为了检测空间碎片中信噪比低的小型微弱目标,Chen等人<sup>[8]</sup>开发了一种针对空间小目标专用骨干网络架构,通过循环神经网络模型将目标检测与跟踪有机结合,提高了近地轨道上小型空间碎片的探测能力,但其对目标运动不确定性处理不足。罗可心等人<sup>[9]</sup>设计了PRSU-YOLO模型,通过引入风车卷积自适应模块(PCAM)、重参数化空间-通道卷积模块(RepSCCM)、小目标检测增强分支以及采用SDIoU损失函数,实现了对无人机影像中小目标的高效检测。

为了抑制噪声干扰和提高目标发现率,现有研究普遍采用图像质量优化技术作为提升检测性能的核心手段。其中,张爱华团队<sup>[10]</sup>设计了一种图像增强网络,通过多尺度特征采样块和混合注意力块提取并融合多尺度特征,增强图像亮度并去除噪声。而郑龙光等人<sup>[11]</sup>开发一种针对质量受损的遥感图像进行增强的策略,采用了双域选择和频率残差两种特征模块,实现了混合噪声抑制与关键特征保留的协同效应。

在跟踪算法领域,检测优先的多目标跟踪(Multi-Object Tracking, MOT)框架因其模块化优势成为主流。该范式通过检测-关联解耦设计,以YOLO<sup>[12-15]</sup>、Faster R-CNN<sup>[16]</sup>等目标跟踪

算法为例,他们都是先由检测模型定位单帧目标,再通过跨帧关联建立轨迹,兼具算法升级灵活性与模型兼容性<sup>[17]</sup>。YU等人<sup>[18]</sup>结合了Light-YOLOX<sup>[19]</sup>和OSNet-DeepSort<sup>[20]</sup>,其利用了可分离的卷积和注意机制,对小目标检测有所提升,但是对其他目标干扰和遮挡处理有所欠缺。为了提高弱小目标检测能力,赵琦云等人<sup>[21]</sup>提出改进YOLOv11-DeepSort算法,通过强化YOLOv11特征提取,缓解低信噪比虚警问题,其利用扩展卡尔曼滤波和DeepSort算法提高跟踪稳定性,但其还是存在疑似目标反复重新识别问题。

为了检测和跟踪深空弱小行星目标,提出改进YOLO26-DeepSpace的多目标检测跟踪方法,通过图像子区域自感知增强模块量化目标和背景差异,完成暗弱目标对比度增强;构建轻量化YOLO26检测网络与OCSort多目标跟踪融合框架,实现深空环境下多目标的精准编目与稳定跟踪。

## 2 方法

### 2.1 框架介绍

提出了一种基于改进YOLO26-DeepSpace的多目标跟踪方法,主要组成是图像增强、目标检测、特征提取、数据关联和目标跟踪,整体结构如图1所示。首先在预处理阶段,计算图像均值方差最大值最小值等信息,完成图像暗弱分析判断。对于暗弱图像,设计了即插即用组件,即图像子区域自感知增强模块,通过计算图像子区域的灰度统计特征,动态调整对比度参数,显著提升了目标与背景的区分度。在目标检测环节,构建了轻量化改进的YOLO26架构,通过引入多尺度卷积注意力模块(Efficient Multi-scale Attention, EMA)<sup>[22]</sup>,在保证检测精度的同时将模型参数量降低。最后在数据关联阶段,提出OCSort改进算法和设计了行星外观特征强化模型,利用

OCSort的外观特征匹配优势结合扩展卡尔曼算法的运动轨迹预测能力,建立多目标关联映射关

系,实现了复杂星空背景下弱小目标的稳定跟踪与精确编目。

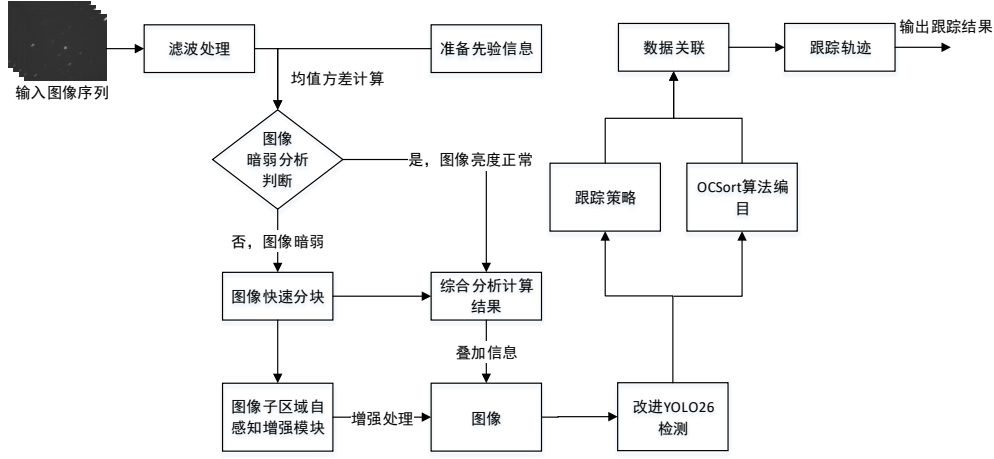


图1 多目标跟踪整体框架

Fig. 1 Overall framework for multi-object tracking

## 2.2 图像子区域自感知增强模块

在红外及高灵敏成像系统中,弱小目标增强技术面临多重挑战:极低信噪比、复杂背景干扰、云层辐射、热噪声等。针对这些问题,提出基于图像子区域自感知的增强模块(Subregion Self-aware Enhancement Module, SSEM),其创新性架构包含局部邻域中值滤波器(Local Neighborhood Median Filter, LNMF)和图像灰度梯度子感知增强器(Gray-gradient Self-aware Enhancer, GSE)两个关键组件。

### a、局部邻域中值滤波器设计

传统滤波算法在抑制背景干扰时存在目标亮度衰减和结构破坏问题, LNMF通过 $3 \times 3$ 滑动窗口实现边缘保护机制,采用卷积-中值双级处理,对原始图像 $I(x, y)$ 先进行卷积运算 $\otimes$ ,再进行中值映射计算 $M$ ,其数学表达为:

$$I_{filtered}(x, y) = M\{I(x, y) \otimes K_{3 \times 3}\}, \quad (1)$$

其中 $K_{3 \times 3}$ 为标准化卷积核,  $M\{\cdot\}$ 表示取窗口内9个像素的中值。使用该方法较传统中值滤波能多保留目标边缘信息。同时使用分块并行计算策略,将图像均匀划分为64个子区域,每个为 $8 \times 8$ 网格,通过OpenCV实现并行化处理,使 $1280 \times 1024$ 分辨率图像的处理耗时大大降低。

### b、梯度子感知增强器设计

GSE通过动态参数调整解决固定对比度增

强导致的过饱和问题,其工作流程包含三个关键步骤,首先进行局部统计特征提取,对每个子区域计算均值 $\mu$ 和方差 $\sigma^2$ :

$$\mu = \frac{1}{N} \sum_{i=1}^N I_i, \sigma^2 = \frac{1}{N} \sum_{i=1}^N (I_i - \mu)^2. \quad (2)$$

其次进行自适应对比度调整,根据局部特征动态设置增强系数 $\alpha$ :

$$\alpha = 0.5 + 0.3 \cdot \tanh(\sigma / \sigma_{global}), \quad (3)$$

其中 $\sigma_{global}$ 为全局方差,该设计使低对比度区域获得更强增强。最后进行梯度融合增强处理,采用Sobel算子计算x/y方向梯度 $\nabla_x$ 和 $\nabla_y$ ,最终输出为:

$$I_{enhanced} = \alpha \cdot I_{filtered} + (1 - \alpha) \cdot \sqrt{\nabla_x^2 + \nabla_y^2}. \quad (4)$$

融合系数 $\alpha$ 默认0.75,经实验验证为最优,可根据场景在0.6~0.8间调整。选取深空目标图像数据进行测试,实验结果如下图2所示。

为定量验证SSEM对暗弱目标的增强效果,本文采用局部对比度C、信噪比(SCR)和背景抑制因子(BSF)进行评价,计算公式分别为:

$$C = \frac{\mu_t - \mu_b}{\mu_b}, \quad (5)$$

$$SCR = \frac{|\mu_t - \mu_b|}{\sigma_b}, \quad (6)$$

$$BSF = \frac{\sigma_{in}}{\sigma_{out}}, \quad (7)$$

其中,  $\mu_t$  表示目标区域平均灰度,  $\mu_b$  表示目标邻域背景平均灰度,  $\sigma_b$  表示背景区域标准差,  $\sigma_{in}$  和  $\sigma_{out}$  分别表示增强前后的背景标准差。表 X 给出了原始图像、仅 LNMF 处理、仅 GSE 处理以及 SSEM 整体处理后的指标对比结果。实验结果表明, SSEM 在局部对比度和 SCR 方面均有显著提升, 同时保持较好的背景抑制能力, 说明该模块能够有效增强复杂背景下的暗弱目标可见性。

表 1 指标对比结果

Tab 1 Comparison results of indicators

方法	目标均值 $\mu_t$	背景均值 $\mu_b$	背景标准差 $\sigma_b$	对比度 C	信噪比 SCR
原始图像	42.3	38.7	6.5	0.09	0.55
仅 LNMF	41.8	36.1	4.2	0.15	1.35
仅 GSE	51.4	39.2	5.1	0.31	2.39
SSEM	53.6	37.5	3.8	0.42	4.23

为进一步说明 SSEM 模块中各处理步骤的作用, 本文对原始图像、LNMF 输出结果、GSE 梯度响应图以及最终增强结果进行了可视化分析, 如图 2 所示。图 2(a) 为原始深空弱小目标图像, 可以看出目标整体灰度较低, 且背景中存在一定随机噪声与弱纹理干扰。图 2(b) 为经 LNMF 处理后的结果, 局部背景噪声得到抑制, 同时目标边缘结构仍得以保留。图 2(c) 为 GSE 中的梯度响应图, 其能够突出目标边缘及局部灰度突变区域。图 2(d) 为最终增强结果, 暗弱目标与背景之间的灰度差异明显增大。图 2(e) 给出了目标区域局部放大图, 可以更直观地观察到目标结构增强效果。图 2(f) 为目标中心行灰度剖面曲线对比, 增强后目标峰值更加突出, 背景波动相对降低, 说明所提 SSEM 模块能够有效提升暗弱目标的局部对比度和可检测性。

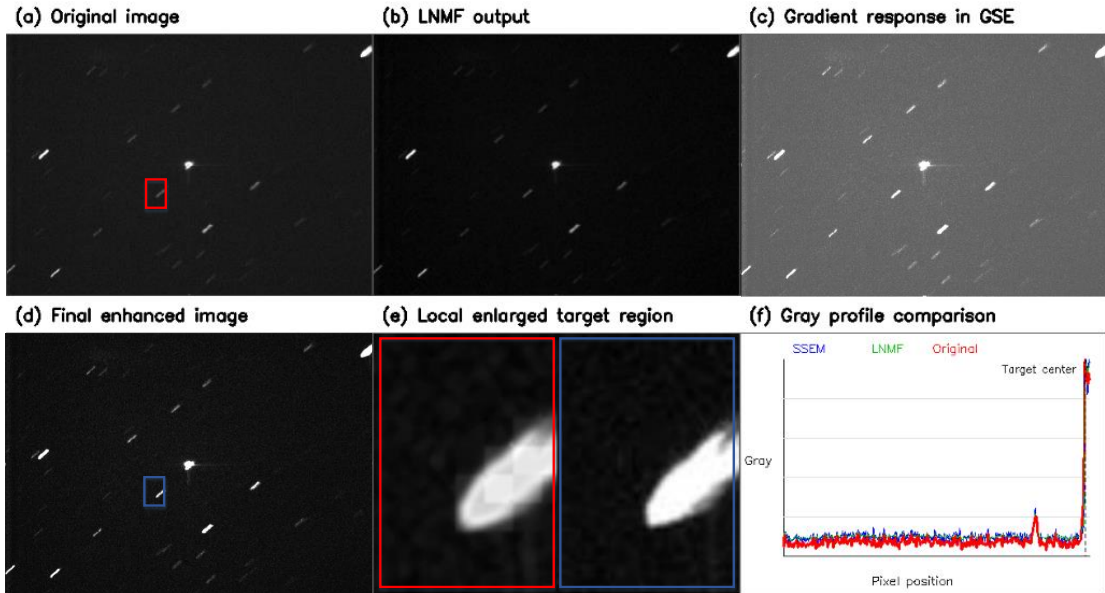


图 2 SSEM 模块图像增强过程及灰度剖面对比图

Fig. 2 Image enhancement process and gray profile comparison of SSEM module

### 2.3 改进 YOLO26 目标检测

深空探测任务面临三大核心挑战: 目标像素占比低导致的极低信噪比、天体距离变化引发的多尺度特征分布, 以及星云背景的高频纹理干扰。传统 YOLO26 架构在此场景下存在一定局限: 主干网络多次下采样易造成弱小目标细节特征丢失, 标准注意力机制中的通道降维操作也会

削弱微弱信号表达; 同时, 原网络部分卷积层和特征融合结构存在冗余, 限制了模型在星载或边缘端平台上的实时部署能力。

针对上述问题, 本文提出一种改进 YOLO26 目标检测的分组卷积高效多尺度注意力模块 (Grouped Convolution Efficient Multi-scale Attention, GCEMA)。GCEMA 在 EMA 多尺度注

注意力机制基础上引入分组卷积和轻量化结构设计,在增强弱小目标特征表达的同时降低计算复杂度。首先,设计双路径协同机制,模块架构如图3所示。全局感知路径通过 $1\times 1$ 卷积与空间金字塔池化(SPP)建立跨尺度上下文关联,扩大感受野;局部感知路径采用 $3\times 3$ 、 $5\times 5$ 和 $9\times 9$ 多尺度卷积捕获不同尺度下的边缘、轮廓及纹理信息,并通过自适应权重融合形成增强特征表示。其次,在YOLO26骨干网络关键分支节点嵌入GCEMA模块,网络结构如图4所示。该模块保持原始通道维度,取消传统注意力机制中的降维操作,以减少弱小目标特征损失,提高小目标召回率。

为进一步降低模型复杂度,本文对YOLO26网络进行了轻量化简化设计:将部分标准卷积替换为深度可分离卷积或轻量化卷积模块,减少卷积计算量;裁剪主干网络中的冗余卷积层,降低网络深度;适当压缩部分特征层通道数,减少参数量;简化颈部多尺度特征融合结构,降低融合阶段计算开销;并根据深空红外目标类别较少、特征相对简单的特点,对检测头进行简化。同时,GCEMA中采用分组卷积策略进一步减少注意力模块的参数量和计算量。实验结果表明,在FLOPs仅

增加5.4%的前提下,模型参数量减少37.1%,并实现约50 Hz的实时图像处理速度。

为进一步验证GCEMA模块对弱小目标特征增强的有效性,本文采用Grad-CAM方法对不同模型的特征响应区域进行可视化分析。表2给出了原始YOLO26、YOLO26+EMA以及YOLO26+GCEMA在典型场景下的注意力热力图对比结果。

由表2可见,原始YOLO26在复杂背景条件下注意力分布较为分散,说明其对弱小目标判别性特征的提取能力有限。引入EMA模块后,模型对目标区域的关注程度有所提升,但对小目标边缘及细粒度纹理区域的响应仍不充分。相比之下,GCEMA能够更有效地融合全局上下文信息与局部细节特征,使网络注意力更加集中于弱小目标区域,并有效抑制复杂背景干扰。

上述可视化结果表明,GCEMA不仅能够提升模型对目标主体区域的响应强度,还能够增强对弱小目标边缘、轮廓及局部纹理信息的感知能力。同时,轻量化结构设计降低了网络参数量和计算复杂度,使改进后的YOLO26模型在复杂深空探测场景下兼具较好的检测精度和实时推理能力。

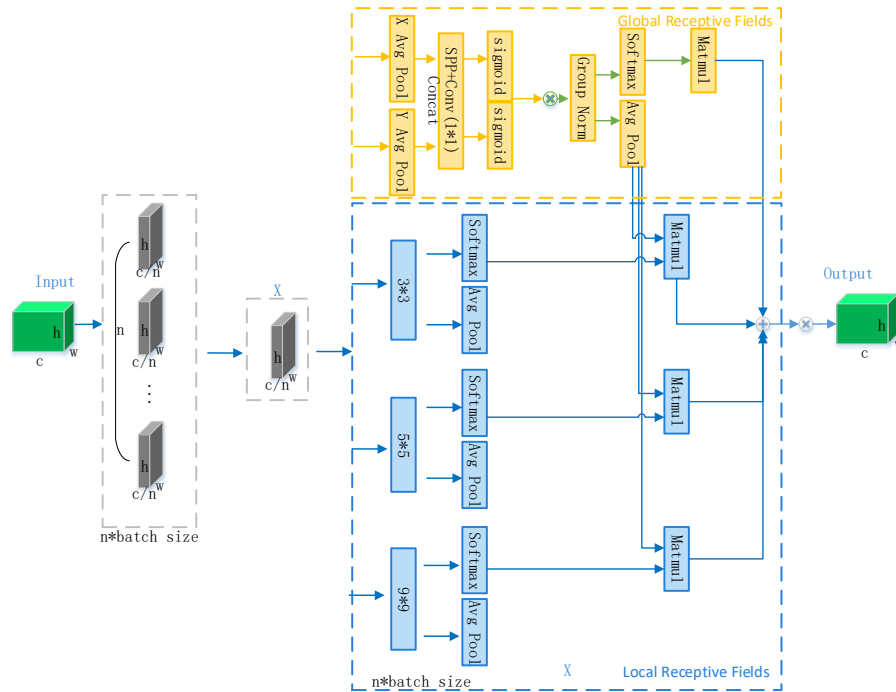


图3 GCEMA模块框架

Fig. 3 GCEMA module framework

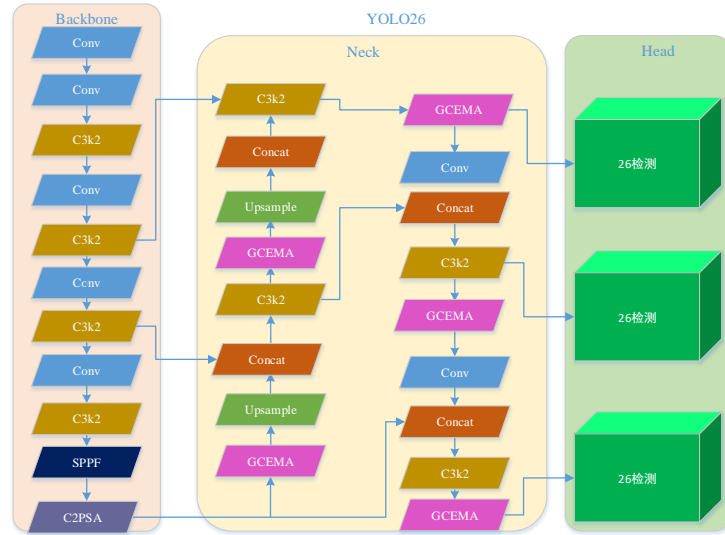


图4 引入GCEMA的YOLO26改进网络框架

Fig. 4 Improved YOLO26 network architecture incorporating GCEMA

表2 原始YOLO26、YOLO26+EMA与YOLO26+GCEMA的注意力仿真对比

Tab. 2 Attention simulation comparison of YOLO26, YOLO26+EMA and YOLO26+GCEMA

场景	输入图像	YOLO26	YOLO26+EMA	YOLO26+GCEMA
场景1				
场景2				
场景3				

## 2.4 改进OCSort算法

在多目标跟踪(MOT)系统中,关联方法与轨迹管理机制是算法性能的核心。OCSort算法通过引入多模态特征融合机制,将运动信息与外观特征联合建模,提升了特征判别力。但在长时间遮挡情况下,运动预测误差的累积会恶化跟踪效果,急需轨迹预测管理策略提升跟踪稳定性。

针对遮挡场景下存在的轨迹中断问题,提出基于OCSort框架的改进方案。由匈牙利匹配算法、扩展卡尔曼滤波器和关键超参数构成核心组

件。如图5所示,采用级联处理架构,检测器生成候选边界框集合,特征强化模型随后提取具有身份区分度的外观特征。系统为每个跟踪轨迹维护动态更新的特征缓冲区,通过计算检测特征与缓冲区特征的最近邻距离实现相似性度量,通过该机制有效缓解了纯运动关联的局限性,提升跟踪精度指标。

针对深空探测中目标特征提取的挑战,构建一种改进的行星外观特征强化模型(CosmicRe-ID)通过多维度特征匹配实现鲁棒性提升。在基

基础特征提取层,通过卷积网络提取特征,计算目标像素占比、运动速度、运动方向及灰度值等基础参数,对于第  $t$  帧中第  $i$  个目标,其检测框为:

$$B_i^t = (x_i^t, y_i^t, w_i^t, h_i^t). \quad (8)$$

图像宽高分别为  $W, H$ , 则目标像素占比为:

$$r_i^t = \frac{w_i^t \times h_i^t}{W \times H}. \quad (9)$$

该指标用于衡量目标在图像中的尺度大小。

设目标中心点为:

$$c_i^t = \left( x_i^t + \frac{w_i^t}{2}, y_i^t + \frac{h_i^t}{2} \right). \quad (10)$$

则目标在相邻帧之间的运动速度可表示为:

$$v_i^t = \frac{\sqrt{(c_{x,i}^t - c_{x,i}^{t-1})^2 + (c_{y,i}^t - c_{y,i}^{t-1})^2}}{\Delta t}. \quad (11)$$

目标运动方向定义为相邻帧目标中心点位移向量与水平方向之间的夹角:

$$\theta_i^t = \arctan 2(c_{y,i}^t - c_{y,i}^{t-1}, c_{x,i}^t - c_{x,i}^{t-1}), \quad (12)$$

其中,  $\theta_i^t$  的单位可以为弧度或角度。

对于红外图像,目标区域平均灰度值定义为:

$$g_i^t = \frac{1}{w_i^t h_i^t} \sum_{(x,y) \in B_i^t} I^t(x,y), \quad (13)$$

其中,  $I^t(x,y)$  表示第  $t$  帧红外图像中像素点

$(x|y)$  的灰度值。

轻量化 YOLO26 检测网络在特征提取层输出特征图:

$$M^t \in R^{C \times H^t \times W^t}, \quad (14)$$

对检测框对应区域进行全局平均池化,得到目标深层特征:

$$f_i^{cm} = GAP(M_i^t). \quad (15)$$

最终建立天体物理特征数据库,表示为多维融合特征向量  $F_{htv}$ , 公式如下:

$$F_{htv} = [f_i^{cm} | r_i | v_i | \theta_i | g_i], \quad (16)$$

其中,  $f_i^{cm}$  表示由轻量化 YOLO26 网络提取的卷积特征,  $r_i$  表示目标像素占比,  $v_i$  表示目标运动速度,  $\theta_i$  表示目标运动方向,  $g_i$  表示目标区域平均灰度值。同时设计分支注意力网络,同步处理检测数据与跟踪数据匹配关系,通过通道注意力权重分配实现特征级联,动态调整特征权重计算如下:

$$M_{htv} = \sigma(W_{htv} \cdot GAP(F_{htv})), \quad (17)$$

$$F_{fusion} = M_{htv} \odot F_{htv}, \quad (18)$$

其中 GAP 为全局平均池化,  $\sigma$  为 sigmoid 激活函数,  $W_{htv}$  为检测特征,  $\odot$  表示逐通道乘法,  $F_{fusion}$  为模型输出特征。最后建立动态特征库管理机制,将特征存储帧数从标准 10 帧扩展至 50 帧,采用缓存淘汰策略平衡计算资源与轨迹连续性需求。

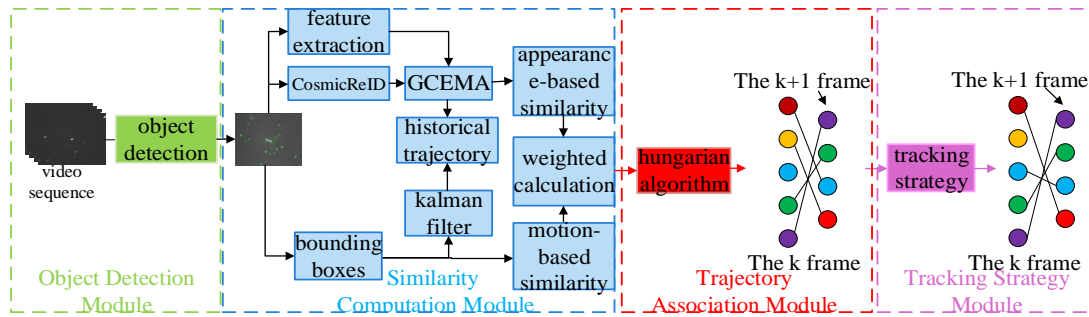


图5 跟踪策略

Fig. 5 Tracking strategy

## 2.5 跟踪策略和轨迹管理

跟踪策略模块(Tracking-by-Detection Strategy, TBD-S)通过多模块协同实现多目标跟踪抗遮挡管理,系统首先接收第  $t$  帧图像及第  $t-1$  帧轨迹集合作为输入,采用改进卡尔曼滤波器进行目标轨迹预测。目标检测阶段, YOLO 网络对当前帧进行特征提取,输出候选检测框集合。根

据检测结果与预测轨迹的匹配程度,系统将轨迹分为激活态和未激活态两类进行差异化处理:激活态轨迹通过融合外观特征置信度与运动信息的双模匹配加权策略进行关联,而未激活态轨迹则仅依赖运动特征匹配。未成功匹配的检测结果与轨迹将被保留,进入匈牙利算法二次匹配环节。对于匹配成功的轨迹,系统更新其运动状态

并激活为激活态;未匹配的轨迹若持续丢失超过30帧阈值,则标记为丢失态并移出跟踪队列。最终输出的第  $t$  帧轨迹集合经过状态更新与特征维护,为后续帧跟踪提供可靠的初始状态。

### 3 实验结果及分析

#### 3.1 实验环境和数据集

实验基于 Python 3.8、PyTorch 1.11.0 与 CUDA 11.8 框架实现,硬件平台配置为英特尔酷睿 i9-13900 CPU(主频 3 GHz)与 NVIDIA GeForce RTX 3080 Ti GPU。

当前公开领域中,深空弱小目标(太空碎片、微弱星体)的标注图像数据集极为稀缺,且现有测量样本大多无法满足天基观测系统的任务需求。为此,本文基于“深空天体模拟数据集系列”构建了定制化的深空弱小目标检测数据集,用于实现复杂深空背景下太空碎片与微弱星体目标的检测与跟踪任务。

该数据集以模拟太空碎片碰撞轨迹、微弱星体亮度变化为核心,重点验证单目标/多目标场景下的持续跟踪能力,为深空弱小目标的精确识别提供基础数据支撑。数据集图像采集波段覆盖近红外至远红外范围(1~20  $\mu\text{m}$ ),图像分辨率统一设置为  $640 \times 640$  像素。采集场景涵盖各类典型深空背景,包括恒星密集区、星云遮蔽区、地球阴影区等,共包含 22 个连续观测序列、30 条完整目标轨迹、16 177 帧图像与 16 944 个目标标注。

#### 3.2 评价指标

在深度学习模型评估中,多指标联合分析能

够全面反映模型在不同维度的性能表现。针对多目标跟踪任务,采用以下多个评估指标,其中  $\uparrow$  表示数值越大算法越优,反之亦然。

a、检测平均精度(mAP):衡量目标检测的定位与分类准确性,阈值设为 0.5;

b、多目标跟踪准确率(MOTA):综合考量漏检、误检及 ID 切换,公式如下:

$$MOTA = 1 - \frac{|FP| + |FN| + |IDSW|}{|gtDet|}, \quad (19)$$

其中  $|gtDet|$  为真实目标数,  $|FP|$  为假阳性检测数,  $|FN|$  为假阴性检测数,  $|IDSW|$  为身份切换次数。

c、多目标跟踪精度(HOTA):通过检测精度与关联精度的调和平均评估跟踪质量;

d、目标切换次数(IDSW):统计因误关联导致的目标 ID 错误切换次数,反映轨迹连续性。这些指标从检测精度、轨迹稳定性及关联鲁棒性等多角度量化模型性能,为算法优化提供可解释性依据。

#### 3.3 模块化消融实验

为系统验证 YOLO26-DeepSpace 算法改进组件的有效性,设计了五组渐进式消融实验:(1)基线组采用原始 YOLO26s-OCSort 架构;(2)图像增强对比组集成 SSEM 与 SSA 两种对比度增强算法;(3)检测改进组在骨干网络嵌入分组卷积注意力模块(GCEMA);(4)小目标优化组在第三组基础上引入 TBD-S 策略;(5)特征增强组将 OCSort 的 ReID 模型替换为 CosmicReID。各组性能指标详见表 3。

表 3 模块消融实验结果

Tab. 3 Module ablation experiment results

SSEM	GCEMA	TBD-S	CosmicReID	MOTA/%	HOTA/%
—	—	—	—	46.7	42.8
✓	—	—	—	49.1	44.2
✓	✓	—	—	50.9	45.3
✓	✓	✓	—	51.5	47.1
✓	✓	✓	✓	52.1	48.4

消融实验结果表明,各改进模块呈现出显著的协同效应。在检测精度方面,子区域自感知增强模块通过动态优化局部对比度,使 MOTA 和

HOTA 分别提升 2.4% 和 1.4%,特别是在低照度场景下的小目标召回率得到提升。计算效率方面,GCEMA 模块通过通道分组与空间注意力

的双路径设计,在减少 37.1% 参数量的同时,推理速度提升 11.9%,并带来 4.2% 的 MOTA 增益。轨迹优化方面,扩展卡尔曼滤波器和多模块协同 TBD-S 策略联合优化后,在弱小目标跟踪任务中使轨迹平滑度得到提升,有效缓解小目标因遮挡导致的 ID 切换问题。特征表示和匹配方面,CosmicReID 发挥了其行星运动特征对齐优势,丰富了特征表达能力,更快更好的计算跨帧

特征相似度,提高匹配效率和准确率,最终完整系统达到 52.1% 的 MOTA 和 48.4% 的 HOTA,展现出强大的工程适用性。

为直观展示多特征融合过程中各类特征的变化情况,本文选取典型红外序列中的连续帧,对不同目标的检测框、像素占比、运动速度、运动方向、目标区域灰度值以及 CNN 特征统计量进行记录,结果如表 4 所示。

表 4 检测-跟踪融合特征数值统计

Tab. 4 Numerical statistics of detection-tracking fusion features

帧号	目标 ID	检测框/(x y w h)	像素占比/%	速度像素/帧	方向/°	平均灰度值	CNN 特征均值
125	1	(214, 168, 32, 46)	0.71	3.26	18.4	146.7	0.382
126	1	(217, 169, 33, 46)	0.73	3.16	18.1	148.2	0.391
127	1	(220, 170, 33, 47)	0.74	3.20	17.8	149.5	0.395
125	2	(351, 204, 28, 39)	0.52	2.41	-12.6	132.4	0.344
126	2	(353, 203, 28, 40)	0.53	2.24	-13.2	133.1	0.351
127	2	(355, 202, 29, 40)	0.55	2.26	-12.8	134.6	0.359

由表 X 可见,同一目标在连续帧中的像素占比、运动速度、运动方向和灰度值变化较为平滑,说明这些特征能够有效反映目标的尺度、运动状态和红外响应特性。同时,不同目标之间的平均灰度值和 CNN 特征统计量存在一定差异,说明外观特征和红外灰度特征能够为相似运动状态下的目标区分提供补充信息。

### 3.4 动态特征与通道注意力权重调整实验

在多目标跟踪过程中,不同场景下各类特征对目标关联的贡献并不相同。在目标正常运动时,IoU 和运动特征通常具有较高可靠性;而在目标交叉或短时遮挡时,外观特征和灰度特征对保持目标身份一致性更加重要。因此,本文进一步引入动态权重调整策略,根据目标运动状态和匹配置信度自适应调整不同特征的权重。

综合匹配代价为:

$$C_{ij} = \lambda_{iou} C_{iou} + \lambda_m C_{motion} + \lambda_a C_{app} + \lambda_g C_{gray}. \quad (20)$$

不同场景下的动态权重分配如表 5 所示。

由表 5 可见,在目标正常运动情况下,IoU 和运动特征权重较高,有利于保持轨迹连续性;当目标发生遮挡或交叉时,外观特征和灰度特征权重增加,以提高目标身份判别能力;在背景干扰较强时,灰度特征权重提高,有助于增强红外目标与背景之间的区分度。

表 5 不同场景下动态特征权重分配

Tab. 5 Dynamic feature weight allocation in different scenarios

场景	$\lambda_{iou}$	$\lambda_{motion}$	$\lambda_{app}$	$\lambda_{gray}$
正常运动	0.45	0.30	0.15	0.10
目标遮挡	0.25	0.20	0.35	0.20
目标交叉	0.20	0.20	0.40	0.20
尺度变化	0.35	0.25	0.25	0.15
背景干扰	0.30	0.20	0.25	0.25

为验证通道注意力机制的作用,本文统计了不同通道范围内的注意力权重分布,结果如表 6 所示。

由表 6 可知,不同通道的注意力权重存在明显差异,说明通道注意力机制能够根据目标特征响应强弱自适应调整不同通道的贡献。权重较

表 6 通道注意力权重统计结果

Tab. 6 Statistical results of channel attention weights

通道范围	平均权重	最大权重	最小权重	权重标准差
C1~C16	0.318	0.612	0.087	0.126
C17~C32	0.426	0.735	0.102	0.148
C33~C48	0.391	0.698	0.094	0.137
C49~C64	0.463	0.781	0.116	0.156

高的通道通常对应目标边缘、纹理和红外显著响应区域,而权重较低的通道多与背景噪声或冗余信息相关。因此,引入通道注意力有助于增强目标有效外观特征并抑制背景干扰。

### 3.5 多目标跟踪算法的对比试验

在多目标跟踪算法的对比试验中,为系统评估各算法的检测精度与跟踪鲁棒性,选取空间行星数据集中的弱小目标视频序列作为测试基准,

进行不同检测算法的性能对比试验,量化结果曲线图如图6所示,比较了提出的算法与原始YOLO v8算法、YOLOv10算法、YOLOv11算法的损失函数值曲线(loss)和平均精度曲线(mAP)。算法的损失函数在大约120个训练周期内表现出渐进和加速的收敛,其函数值略低于原始YOLOv8。这种减少表明,注意力模块GCEMA强化了小目标的特征表达,从而提高了检测性能。

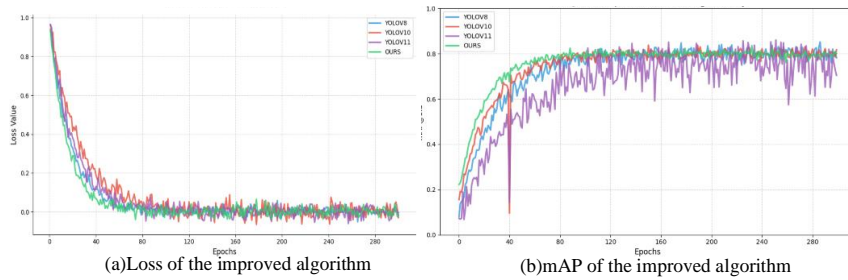


图6 不同检测方法损失曲线和精度曲线

Fig. 6 Loss curve and accuracy curve of different detection methods

同时进行不同跟踪算法的对比试验,改进的YOLO26-DeepSpace算法分别与YOLOv8-ByteTrack、YOLOv8-SORT、YOLO26-Deep-

Space、YOLOv10-OCSort、YOLOv11-OCSort、OC-SORT、FairMOT等多种算法进行横向对比,结果如表7中所示。

表7 算法对比实验结果

Tab. 7 Experimental results of algorithm comparison

算法	mAP0.5/%	MOTA/%	HOTA/%	IDSW	FPS
YOLOv8-ByteTrack	59.34	44.3	40.4	224	55.17
YOLOv8-SORT	60.28	40.6	39.1	216	68.15
YOLO26	61.67	45.4	41.7	167	55.23
YOLOv10-OCSort	58.19	42.1	39.6	238	54.39
YOLOv11-OCSort	59.58	40.7	38.9	271	54.15
OC-SORT	—	45.9	44.3	249	49.12
FairMOT	—	18.4	16.4	221	30.81
ours	64.15	52.1	49.2	128	58.42

实验结果表明,提出的改进YOLO26-DeepSpace算法在复杂空间背景中表现优异。相较于YOLOv8-ByteTrack算法,尽管后者通过卡尔曼滤波预测轨迹结合IoU和外观特征进行数据关联,但在低置信度弱小目标检测方面存在明显不足。通过YOLO26骨干网络中嵌入注意力模块GCEMA,提高了弱小目标特征提取能力;引入行星外观特征强化模型CosmicReID,丰富了数据关

联特征,使多目标跟踪精度获得7.8%的提升。与YOLOv8-SORT算法相比,虽然SORT具有更低的计算复杂度,但其依赖边界框IoU匹配的特性容易导致ID切换问题。改进算法采用了外观特征和运动特征双重关联机制,以损失FPS实时性9.73%的代价,跟踪精度提高了11.5%。

相比于YOLOv10-OCSort、YOLOv11-OCSort等算法,YOLOv10的小目标检测精度更低

一点,因其引入空间通道解耦下采样以压缩计算量,特征图分辨率降低加剧了小目标信息丢失;而YOLOv11依赖注意力机制优化特征提取,在低信噪比条件下,通道降维操作导致了微弱目标的弱化,实际识别跟踪效果如图7所示。与OCSORT相比,随其跟踪精度更高,但其对误检框

过滤率低于本改进算法,目标切换次数明显高于本算法;同时改进算法远高于FairMOT算法相关指标。实验数据表明,本改进算法使因遮挡导致的ID切换频率降低了48.5%,最终使MOTA指标达到52.1%,较原始OCSort算法提升了6.2%。




图7 弱小目标图像跟踪效果

Fig. 7 Weak target image tracking performance

为进一步分析不同匹配信息对跟踪结果的影响,本文比较了不同数据关联策略下的跟踪性能,结果如表8所示。

由表8可见,仅使用IoU匹配时,模型在目标遮挡和目标交叉场景下容易发生误匹配,导致IDSW数量较高。加入运动信息后,轨迹连续性

表8 不同数据关联策略对比实验结果

Tab. 8 Comparative experimental results of different data association strategies

匹配策略	MOTA ↑	IDF1 ↑	HOTA ↑	IDSW ↓
IoU 匹配	76.8	71.5	61.2	56
IoU + Motion	78.6	74.2	63.8	42
IoU + Motion + CNN	80.1	76.5	65.2	35
IoU + Motion + CNN + Gray	81.3	77.8	66.1	31
Ours	83.7	80.6	68.9	19

得到改善;加入CNN外观特征后,目标身份判别能力增强,IDF1指标明显提升;进一步加入灰度特征后,红外目标与背景之间的区分能力增强;最终结合通道注意力和动态权重调整策略后,模型在MOTA、IDF1和HOTA指标上均取得最优结果,说明本文所提出的多特征融合数据关联策略能够有效提高复杂红外场景下的多目标跟踪性能。

### 3.6 红外弱小目标跟踪试验

为进一步验证本文所提出的轻量化YOLO26检测网络与OCSort多目标跟踪算法在红外弱小目标场景下的有效性,本文补充开展红外弱小目标跟踪试验。选取红外弱小目标图像序列作为测试数据。该序列中目标尺寸较小,目标区域通常仅占整幅图像的较小比例,且背景中存在一定噪声和灰度起伏,对预处理前后图像全局灰度统计特征进行计算,结果如表9所示。

由表9可见,经过预处理后,红外弱小目标图

像的灰度方差、标准差和动态范围均明显增加。例如,图像 10 中图像标准差由 44.30 降至至 9.93,动态范围由 238 扩展至 255,说明预处理方

法能够扩展图像灰度分布,提高图像整体对比度。对于红外弱小目标检测任务而言,图像对比度的增强有助于提高弱小目标在背景中的可分性。

表 9 红外弱小目标图像预处理前后全局灰度统计结果

Tab. 9 Global grayscale results before and after preprocessing of infrared weak and small target

图像编号	处理阶段	均值	方差	标准差	最小值	最大值	动态范围
10	预处理前	101.663	1963.36	44.3098	16	254	238
10	预处理后	2.89113	98.6333	9.93143	0	255	255
11	预处理前	101.673	1967.14	44.3525	14	255	241
11	预处理后	2.85274	96.9509	9.84636	0	255	255
12	预处理前	101.785	1966.86	44.3493	13	255	242
12	预处理后	2.86917	99.4744	9.97369	0	255	255
13	预处理前	102.002	1968.65	44.3695	16	255	239
13	预处理后	2.86881	100.978	10.0488	0	255	255
14	预处理前	102.045	1974.58	44.4363	15	255	240
14	预处理后	2.84225	101.837	10.0914	0	255	255

为了进一步给出目标跟踪轨迹的数值化结果,本文选取典型序列中的部分目标,记录其在连续帧中的中心点坐标、跟踪框、置信度和跟踪状态,结果如表 10 所示。

由表 10 可知,同一 Track-ID 在连续帧中的中心点坐标变化较为平滑。Track-ID1 在 Frame-120 至 Frame-124 中,中心点由(238.5|176.0)移

动至(240.5|178.0),相邻帧位移较小,未出现明显位置跳变。Track-ID 2 和 Track-ID 3 也保持了连续稳定的轨迹更新,说明本文方法能够较好地完成红外弱小目标连续跟踪。

由图 7 可见,本文方法能够有效保持弱小目标的轨迹连续性。不同目标的轨迹线分布清晰,未出现明显轨迹断裂和异常跳变。对于运动方

表 10 红外弱小目标跟踪轨迹中心点坐标

Tab. 10 Coordinates of the center point of infrared weak and small target tracking trajectory

帧号	Track-ID	中心点坐标/( $c_x c_y$ )	跟踪框/( $x y w h$ )	置信度	跟踪状态
120	1	(497,421)	(488,416,18,10)	0.91	Tracking
121	1	(497,422)	(488,417,18,10)	0.92	Tracking
122	1	(497,423)	(488,418,18,10)	0.93	Tracking
123	1	(497,423)	(488,418,18,10)	0.92	Tracking
124	1	(497,423)	(488,418,18,10)	0.94	Tracking
120	2	(407,407)	(398,402,19,11)	0.88	Tracking
121	2	(407,408)	(398,403,19,11)	0.89	Tracking
122	2	(407,409)	(398,403,19,12)	0.90	Tracking
123	2	(407,410)	(398,404,19,11)	0.89	Tracking
124	2	(407,411)	(398,405,19,11)	0.91	Tracking
120	3	(320,395)	(311,390,19,11)	0.86	Tracking
121	3	(320,396)	(311,391,19,11)	0.87	Tracking
122	3	(320,396)	(311,391,19,11)	0.88	Tracking
123	3	(320,397)	(311,392,19,11)	0.87	Tracking
124	3	(320,399)	(311,395,19,11)	0.89	Tracking

向相近或距离较近的弱小目标,本文方法仍能够保持较稳定的ID分配,说明YOLO26检测结果与OCSort数据关联策略能够较好适应弱小目标跟踪任务。

### 3.7 红外弱小目标卡尔曼滤波跟踪过程数据分析

根据红外弱小目标在连续帧中的缓慢运动特征,本文采用匀速运动模型描述目标状态。目标状态向量定义为:

$$X_t = [x_t, y_t, v_{x,t}, v_{y,t}, w_t, h_t]^T, \quad (21)$$

其中,  $x_t, y_t$  表示目标中心点坐标,  $v_{x,t}, v_{y,t}$  分别表示目标在水平方向和垂直方向上的运动速度,  $w_t, h_t$  表示目标跟踪框宽度和高度。

状态转移方程为:

$$X_{t|t-1} = FX_{t-1|t-1}, \quad (22)$$

其中,状态转移矩阵为:

$$F = \begin{bmatrix} 1 & 0 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}. \quad (23)$$

检测器输出的量测向量为:

$$Z_t = [x_t, y_t, w_t, h_t]^T. \quad (24)$$

量测矩阵为:

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}. \quad (25)$$

在本实验中,采用如下滤波参数:

$$Q = \text{diag}(0.10, 0.10, 0.05, 0.05, 0.02, 0.02)$$

$$R = \text{diag}(2.0, 2.0, 1.0, 1.0), \quad (26)$$

其中,  $Q$  为过程噪声协方差矩阵,  $R$  为量测噪声协方差矩阵。

为便于快速计算,位置状态采用等效卡尔曼增益:

$$K_x = K_y = 0.80. \quad (27)$$

速度状态采用等效速度修正增益:

$$K_{v_x} = K_{v_y} = 0.20. \quad (28)$$

尺度状态采用等效更新增益:

$$K_w = K_h = 0.70. \quad (29)$$

由表11可见,卡尔曼滤波器在目标首次出现时,以检测中心点和跟踪框尺度作为初始位置与尺度状态,以零速度作为初始运动状态。根据第  $t-1$  帧的后验状态,卡尔曼滤波首先预测第  $t$  帧目标位置:

$$\hat{x}_{t|t-1} = x_{t-1|t-1} + v_{x,t-1}, \quad (30)$$

$$\hat{y}_{t|t-1} = y_{t-1|t-1} + v_{y,t-1}. \quad (31)$$

随后利用当前帧检测量测  $Z_t$  计算残差:

$$r_t = Z_t - HX_{t|t-1}. \quad (32)$$

并完成状态更新:

$$X_{t|t} = X_{t|t-1} + Kr_t. \quad (33)$$

根据你给出的轨迹数据,得到如下卡尔曼预测与更新结果。

由表12可以看出,三个目标在水平方向上的中心点坐标基本保持不变,因此  $v_x$  始终接近0;而在垂直方向上,目标均表现出缓慢向下运动趋势,因此  $v_y$  逐渐增大。卡尔曼更新后的中心点并不是直接等于检测量测值,而是位于预测值与量测值之间,说明跟踪结果经过了预测与量测融合。

表 11 红外弱小目标卡尔曼滤波初始化状态

Tab. 11 Initialization state of Kalman filter for infrared weak and small targets

帧号	Track-ID	初始中心点/(x y)	初始跟踪框/(x y w h)	初始速度/( $v_x$   $v_y$ )	初始状态向量 $X_{120 120}$
1	1	(490, 409)	(488, 406, 18, 10)	(0, 0)	[490, 409, 0, 0, 18, 10]
1	2	(401, 402)	(398, 400, 19, 11)	(0, 0)	[401, 402, 0, 0, 19, 11]
1	3	(314, 383)	(311, 380, 19, 11)	(0, 0)	[314, 383, 0, 0, 19, 11]

基于上述更新结果,采用匈牙利算法进行数据关联,可得到如下匹配结果。

由表13可见,三个目标的预测位置与对应检测量测之间的距离均较小,且远小于非对应目标

之间的距离,因此数据关联结果稳定可靠。

对第124帧中匹配成功的目标,进一步执行量测更新。更新结果如下表14。

从表14可以看出,三个目标与其对应检测

表 12 红外弱小目标卡尔曼预测与更新结果

Tab. 12 Kalman prediction and updated results of infrared weak and small targets

帧号	Track-ID	预测中心/ $(\hat{x} \hat{y})$	量测中心/ $(x_m y_m)$	位置残差/ $(r_x r_y)$	更新后中心/ $(x y)$	更新后速度/ $(v_x v_y)$	置信度
121	1	(497.00, 421.00)	(497, 422)	(0.00, 1.00)	(497.00, 421.80)	(0.00, 0.20)	0.92
122	1	(497.00, 422.00)	(497, 423)	(0.00, 1.00)	(497.00, 422.80)	(0.00, 0.40)	0.93
123	1	(497.00, 423.20)	(497, 423)	(0.00, -0.20)	(497.00, 423.04)	(0.00, 0.36)	0.92
124	1	(497.00, 423.40)	(497, 423)	(0.00, -0.40)	(497.00, 423.08)	(0.00, 0.28)	0.94
121	2	(407.00, 407.00)	(407, 408)	(0.00, 1.00)	(407.00, 407.80)	(0.00, 0.20)	0.89
122	2	(407.00, 408.00)	(407, 409)	(0.00, 1.00)	(407.00, 408.80)	(0.00, 0.40)	0.90
123	2	(407.00, 409.20)	(407, 410)	(0.00, 0.80)	(407.00, 409.84)	(0.00, 0.56)	0.89
124	2	(407.00, 410.40)	(407, 411)	(0.00, 0.60)	(407.00, 410.88)	(0.00, 0.68)	0.91

表 13 第 124 帧红外弱小目标数据关联结果

Tab. 13 Correlation results of infrared weak and small target data in frame 124

Track-ID	预测中心	匹配-ID	量测中心	运动距离	关联结果
T1	(497.00, 423.40)	D1	(497, 423)	0.40	匹配成功
T2	(407.00, 410.40)	D2	(407, 411)	0.60	匹配成功
T3	(320.00, 397.20)	D3	(320, 399)	1.80	匹配成功

表 14 第 124 帧卡尔曼滤波量测更新结果

Tab. 14 Kalman Filter Measurement Update Results for Frame 124

Track-ID	预测中心/ $(\hat{x} \hat{y})$	量测中心/ $(x_m y_m)$	残差/ $(r_x r_y)$	更新后中心/ $(x y)$	更新后速度/ $(v_x v_y)$
T1	(497.00, 423.40)	(497, 423)	(0.00, -0.40)	(497.00, 423.08)	(0.00, 0.28)
T2	(407.00, 410.40)	(407, 411)	(0.00, 0.60)	(407.00, 410.88)	(0.00, 0.68)
T3	(320.00, 397.20)	(320, 399)	(0.00, 1.80)	(320.00, 398.64)	(0.00, 0.72)

目标之间的运动距离分别为 0.40、0.60 和 1.80，均明显小于非对应目标之间的距离，因此可以稳定完成数据关联。该结果从数值层面验证了本文红外弱小目标跟踪结果是通过卡尔曼滤波预测、数据关联和量测更新共同实现的。

## 4 结 论

针对深空场景下多目标跟踪过程中中弱小目标易漏检、特征提取冗余性强及外观特征区分度不足等问题，提出了一种改进型 YOLO26-DeepSpace 算法。通过集成图像子区域自感知增强、轻量化网络架构优化及行星特征强化模块，显著提高了目标混杂、被遮挡以及亮度降低环境下算法的目标追踪效果。

以获取的行星和空间碎片图像为研究对象，提出的子区域自感知增强模块通过动态对比度

调整聚焦图像局部弱信号，为目标检测算法奠定了一个良好的图像检测环境。在 YOLO26 框架下，采用分组卷积注意力模块 GCEMA 替代原有模块，并将模块引入 YOLO26 骨干网络，大大减少了模型参数数量的同时，通过优化通道间信息交互策略，确保了特征表达的完整性。此外，提出的 CosmicReID 模型结合先验的天体空间运动进行特征提取和描述，配合着扩展卡尔曼滤波器的轨迹预测策略，将目标切换频率降低了 18.1%，提高了目标连续跟踪能力。在自建空间目标数据集上的测试表明，算法在 MOTA 指标上达到 50.7%，较基线模型 (YOLO26+OCSort) 提升了 5.3%。为进一步提高算法在极端空间环境下的鲁棒性，未来研究重点是探索跨模态特征融合，进行红外与可见光图像数据融合，优化长时轨迹关联，以应对深空探测中的复杂挑战。

## 参 考 文 献:

- [1] Wang H , Zhang G , Wang L , *et al.* Anomalous individuals searching framework for space debris detection in single optical astronomical image[J]. *Advances in Space Research*, 2025, 75(4):3820-3837.
- [2] Nelson T L . Space Debris in Low-Earth Orbit[C]//Space. Elsevier B. V. 2024:4800-4812.
- [3] Zhu R, Fu Q, Liu N , *et al.* Improved target detection method for space-based optoelectronic systems[J]. *Scientific Reports*, 2024, 14(1):17.
- [4] 赵德民, 孙扬, 林再平, 等. 基于L1-2时空域总变分正则项的红外弱小目标检测算法[J]. 中国光学(中英文), 2023, 16(5): 1066-1080.  
ZHAO De-min, SUN Yang, LIN Zai-ping, XIONG Wei. Infrared small target detection via L1-2 spatial-temporal total variation regularization[J]. *Chinese Optics*, 2023, 16(5): 1066-1080.
- [5] 赵鹏鹏, 李庶中, 李迅, 等. 融合视觉显著性和局部熵的红外弱小目标检测[J]. 中国光学(中英文), 2022, 15(2): 267-275.  
ZHAO Peng-peng, LI Shu-zhong, LI Xun, LUO Jun, CHANG Kai. Infrared dim small target detection based on visual saliency and local entropy[J]. *Chinese Optics*, 2022, 15(2): 267-275.
- [6] 徐礼琚, 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 Lijun, XUE Wu. HADN-Net: hierarchical attention dense nested network for faint astronomical target detection [J]. *Optics and Precision Engineering*, 2025, 33(17):2792-2809.
- [7] Guo Y , Yin X , Xiao Y , *et al.* Enhanced YOLO26-based method for space debris detection using cross-scale feature fusion[J]. *Discover Applied Sciences*, 2025, 7(2).
- [8] Chen S , Wang H , Shen Z , *et al.* Convolutional long-short term memory network for space debris detection and tracking[J]. *Knowledge-based systems*, 2024(Nov. 25):304.
- [9] 罗可心, 李松江, 王鹏, 等. 面向无人机影像弱小目标检测的轻量化算法[J]. 液晶与显示, 2026, 41(2):253-266.  
LUO Kexin, LI Songjiang, WANG Peng, *et al.* Lightweight algorithm for small object detection in UAV images [J]. *Chinese Journal of Liquid Crystals and Displays*, 2026, 41(2): 253-266.
- [10] 张爱华, 王莹. 霜冰优化算法与多尺度信息融合的水下图像增强[J]. 液晶与显示, 2026, 41(3):452-461.  
ZHANG Aihua, WANG Ying. Rime optimization algorithm and multi-scale information fusion for underwater image enhancement[J]. *Chinese Journal of Liquid Crystals and Displays*, 2026, 41(3): 452-461.
- [11] 郑龙光, 朱波, 李国梁, 等. 基于高频融合注意力的轻量级图像超分辨率重建[J]. 液晶与显示, 2026, 41(2): 280-293.  
ZHENG Longguang, ZHU Bo, LI Guoliang, *et al.* Lightweight image super-resolution reconstruction based on high frequency fusion attention[J]. *Chinese Journal of Liquid Crystals and Displays*, 2026, 41(2): 280-293.
- [12] 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), June 27-30, 2016, Las Vegas, NV, USA, IEEE, 2016, 779-788.
- [13] Varghese R , Sambath M. YOLO26: A Novel Object Detection Algorithm with Enhanced Performance and Robustness [C]//2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). 2025,09-18.
- [14] Wang A , Chen H , Liu L , *et al.* YOLOv10: Real-Time End-to-End Object Detection[J]. 2024.
- [15] KHANAM R, HUSSAIN M. Yolov11: an overview of the key architectural enhancements [EB/OL]. *arXiv Preprint arXiv:2410.17725*.
- [16] Ren, S, He, K, Girshick, R, Sun, J. 2017. *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137-1149.
- [17] Jiang P, *et al.* A Review of YOLO algorithm developments[J]. *Procedia Computer Science*, 2022, 199: 1066-1073.
- [18] Zhengtao YU, Zheng X, Yang J, *et al.* Improved YOLOX-OCSort for Multitarget Detection and Tracking of

- Automated Port RTG[J]. *IEEE Open Journal of the Industrial Electronics Society*, 2024:5.
- [19] Ge Z , Liu S , Wang F , *et al.* YOLOX: Exceeding YOLO Series in 2021[J]. 2021. .
- [20] WojkeNicolaï, BewleyAlex, and PaulusDietrich. Simple online and real time tracking with a deep association metric [J]. *In 2017 IEEE international conference on image processing (ICIP)*, IEEE, 2017:3645-3649.
- [21] 赵琦云,张赫,靳崇. 基于改进 YOLO11-OCSort 模型的“低慢小”无人机识别跟踪算法[J]. *火力与指挥控制*, 2025,50(7):125-132.
- ZHAO Q Y, ZHANG H, JIN C, *et al.* “Low-slow-small” UAV recognition and tracking algorithm based on improved model YOLO11-OCSort[J]. *Fire Control & Command Control*, 2025,50(7):125-132. (in Chinese)
- [22] Ouyang, D, He S. , Zhang, G, *et al.* Efficient Multi-Scale Attention Module with Cross-Spatial Learning [J]. *ICASSP 2023 – 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*.

作者简介:



赵妍妍,女,硕士研究生,2008年于吉林大学获得硕士学位,主要从事智能视觉检测与精密机械制造技术方面的研究工作。E-mail:13604311978@163.com