

文章编号 1004-924X(2025)17-2792-18

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

徐礼珺, 薛武*

(航天工程大学, 北京 101416)

摘要: 针对暗弱天体目标具有像素占比小、与背景对比度低、内部信息稀缺等特点, 提出面向暗弱天体目标检测的一种层次化注意力密集嵌套网络 HADN-Net, 首先提出了多分支 Ghost-空洞注意力模块 Mul-GDAM, 采用多感受野特征提取策略增强目标局部邻域的上下文信息建模能力, 结合轻量化 Ghost 卷积与空间因式分解卷积, 在降低计算开销的同时能有效抑制背景噪声并强化暗弱目标的特征表示能力; 然后提出层次化特征聚合模块 HiFAM, 采用跨空间-通道维度特征交互实现多尺度特征图的自适应加权融合, 通过空间重加权与通道自适应融合提高暗弱目标信息在融合特征图中的表征质量。HADN-Net 显著提升了暗弱目标的检测能力, 在真实地基光学图像上进行实验, HADN-Net 实现了 94.648% 的召回率、95.518% 的检测精度和 95.081% 的 F1 分数, 均达到 SOTA 性能, 优于现有的 5 种先进方法, 特别在召回率上, 较次优方法性能提升 2.855%, 证实了 HADN-Net 在暗弱天体目标检测方面的有效性。该方法为天文图像中的暗弱天体目标检测提供了一种新的解决方案, 对深空探测、太空资源开发等任务具有实际应用意义。

关键词: 计算机视觉; 地基光学天文图像; 暗弱天体; 目标检测; 神经网络

中图分类号: TP391.41; TP183 **文献标识码:** A

doi: 10.37188/OPE.20253317.2792 **CSTR:** 32169.14.OPE.20253317.2792

HADN-Net: hierarchical attention dense nested network for faint astronomical target detection

XU Lijun, XUE Wu*

(Space Engineering University, Beijing 101416, China)

* Corresponding author, E-mail: xuewu_81@126.com

Abstract: Faint astronomical target detection is fundamental to space resource exploration, development, and utilization, providing essential information for celestial object tracking, asteroid mining, and deep-space mission planning. Detecting such targets remains challenging due to minimal pixel coverage, low signal-to-noise ratios (SNR), and sparse intrinsic features, which contribute to high false-negative rates and limited performance in existing approaches. To address these limitations, a Hierarchical Attention Dense Nested Network (HADN-Net) is proposed, a deep-learning framework specifically designed to enhance detection accuracy for faint targets in astronomical imagery. HADN-Net incorporates two novel modules to tackle the principal challenges of faint target detection. The Multi-branch Ghost-Dilated Attention Module (Mul-GDAM) adopts a multi-receptive-field feature extraction strategy that combines dilated con-

收稿日期: 2025-06-14; 修订日期: 2025-07-10.

基金项目: 航天工程大学青年创新基金资助项目

volution with ghost modules to expand contextual modeling while preserving computational efficiency. This module effectively captures local neighborhood features, suppresses complex background noise, and strengthens the discriminative representation of faint targets. The Hierarchical Feature Aggregation Module (HiFAM) employs cross spatial-channel attention mechanisms to dynamically fuse multi-scale features. By adaptively weighting feature maps across resolutions, HiFAM preserves faint-target information and mitigates the scale-variation problem common in astronomical observations. Extensive experiments on real ground-based optical images demonstrate that HADN-Net achieves state-of-the-art performance, yielding a recall of 94.648%, precision of 95.518%, and an F1-score of 95.081%, and outperforming five leading methods. In particular, recall is improved by 2.855% relative to the second-best method, confirming the effectiveness of the proposed approach for faint celestial target detection. This work introduces a scalable solution applicable to space debris monitoring, exoplanet discovery, and near-Earth object (NEO) tracking.

Key words: computer vision; ground-based optical astronomical images; faint astronomy; target detection; neural networks

1 引言

暗弱天体目标检测是天文观测、空间监视和遥感探测等领域的关键技术挑战之一,其核心在于从复杂背景或低信噪比数据中提取微弱目标信号。这类目标包括深空暗弱星系、太空碎片、高动态范围图像中的微弱目标特征等,其有效检测可提高科学发现的深度和观测数据的利用率。在近地天体监测中,能否尽早发现移动的暗弱天体目标关乎潜在碰撞风险;在深空探测中,对暗弱星系的识别有助于研究宇宙演化过程;在空间态势感知中,微小空间碎片的检测能力直接关系到航天器的安全。因此,提高暗弱目标检测的灵敏度具有重要的科学意义和工程价值^[1-2]。

暗弱目标检测主要分为两大类:传统方法和基于深度学习的方法。传统方法主要基于人工设计的图像处理技术,通过信号增强和背景抑制等手段提升检测性能,典型方法包括信号叠加技术^[3]、背景建模方法^[4]、运动轨迹关联算法^[5]以及自适应阈值分割操作^[6]等,这些方法构成了早期暗弱天体检测的主要技术框架。研究表明,传统方法在特定观测条件和目标特性下能够实现稳定的检测效果,为后续自动化检测算法的发展奠定了重要基础。

随着一系列大型天文数据库的建立^[7],研究人员将基于深度学习的方法引入天体目标检测领域,用以自动化处理海量的天文图像并检测多

样的天体类型。神经网络具有直接从数据中学习背景与目标间特征差异的能力,较传统方法具有更强的目标适应性和场景泛化性。天体目标检测中常用的两类神经网络为语义分割网络^[8-10]和目标检测网络^[11-13],它们在暗弱目标检测方面具有较好的检测性能和发展潜力^[14-15]。尽管如此,现有深度学习方法在暗弱目标检测方面仍有不足。当前主流网络架构多以卷积神经网络为主,在特征提取过程中容易导致微弱的信号在网络传播中逐渐衰减,加之有限的感受野设计,难以有效建模暗弱目标与背景间的长程依赖关系^[8,16],而暗弱目标的判别却又高度依赖周围环境信息。其次,主流网络结构多倾向于捕捉显著特征,对微弱信号的特征响应不敏感,特别在多尺度特征融合过程中存在对暗弱目标信息在通道和空间维度注意力分配不均的问题,易造成微弱信号在融合过程中被背景噪声淹没的现象^[17]。受限于观测条件及目标自身特性,暗弱目标在图像上的尺寸普遍小于 9×9 像素,并且由于低信噪比,其在图像中呈现的信息相当有限,仅以微弱光点的形式表示,与背景间的区分度低,人眼难以察觉。像素占比低、外观模糊、特征稀疏、易与背景相混淆等诸多挑战,使一般目标检测模型难以直接应用于暗弱目标检测任务中,需要设计专门的网络模型进行处理。

针对上述问题,本文提出面向暗弱天体目标检测的层次化注意力密集嵌套网络(Hierarchical At-

tention Dense Nested network, HADN-Net), 通过层次化特征增强和自适应上下文建模解决暗弱目标因特征稀疏、背景混淆等挑战引起的检测失效问题。具体而言, 提出了多分支 Ghost-空洞注意力模块(Multi branch Ghost- Dilated Attention Module, Mul-GDAM)和层次化特征聚合模块(Hierarchical Feature Amalgamation Module, HiFAM), 有效提高网络增强与捕获暗弱目标特征的能力。HADN-Net使用基于跳跃连接的密集嵌套 U-Net 作为骨干网络, 保证暗弱目标信息在骨干网络中得到有效传播的同时促进各级特征图间的充分交互, 以增强暗弱目标的特征表示并提高信息利用率; Mul-GDAM 作用于骨干网络每个节点上, 其多分支感受野结构帮助捕获暗弱天体目标丰富的细节信息和上下文信息, 通过建模目标与周围环境间的关系捕获两者具有判别性的特征表示, 有效缓解暗弱目标与背景易混淆的问题; HiFAM 用于多尺度特征图间的自适应加权融合, 采用跨空间-通道维度的特征交互方式突出目标在空间维度和通道维度中的关键信息, 通过保留与融合上述信息提高特征图的融合质量。基于上述设计, HADN-Net 能有效应对暗弱目标检测带来的挑战, 在真实地基光学图像中的实验结果证明了 HADN-Net 在提高暗弱天体目标检测方面的有效性。

2 相关工作

2.1 传统天体目标检测

传统天体目标检测方法依靠各种图像处理技术和算法实现天体目标检测, 其核心算法包括背景估计与减除、图像变换、目标检测等。为了方便研究人员使用及提高整体方法处理效率, 一系列开源天体图像处理软件被提出^[18-19], 软件中集成了多种算法, 各类算法按照预先设定的流程依次运行, 自动完成天体目标的检测和提取工作, 减少人工分步操作的时间成本, 代表软件有 SExtractor^[20], MTOBJECTS^[21], ProFound^[22]等。其中, SExtractor^[20]是天文学图像处理的代表性软件, 其核心算法基于标准化天体检测流程, 主要包含背景估计、阈值分割、信号解混等关键步骤, 常用于处理大规模巡天图像。然而, 基于阈值分割的目标检测模式要求目标的响应强度应显著高于背景标准差, 这一检测条件导致信噪比低的暗弱

目标易被判定为背景噪声, 影响软件的暗弱目标检测能力。针对 SExtractor 在暗弱目标检测方面的局限性, MTOBJECTS^[21]通过引入最大树结构对图像进行多尺度表征, 相较 SExtractor 采用的全局背景统计方法能够更精确地分析局部区域特征、更细致考察暗弱目标邻域像素分布情况, 有效提升对暗弱目标的识别率。ProFound^[22]则采用分水岭分割算法替代阈值分割算法, 通过分析图像灰度梯度特征实现更精确的目标区域划分, 显著改善了检测结果的精确性和稳定性。随着天文观测技术的不断发展, 新一代开源数据平台整合了越来越多的先进算法, 持续推动传统方法的性能优化^[23-25]。

尽管目前天体目标检测软件均实现了自动化处理, 但在实际应用时仍需要人工进行繁琐的参数设置工作, 且软件中的参数通常是针对特定观测条件或目标类型设置的, 适用性有限。当图像背景复杂或天体目标种类繁多时, 传统方法的检测性能因泛化能力不足而明显下降; 特别在检测信噪比低的暗弱目标时, 由于目标特征稀疏、与背景对比度低等特点, 在图像预处理或目标识别等关键步骤中容易丢失目标, 且后续流程无法恢复与利用在先前步骤中被遗漏的暗弱目标信息。这一局限性严重影响了传统方法在暗弱目标检测任务中的表现。

2.2 基于深度学习的天体目标检测

基于深度学习的方法借助神经网络强大的自主学习能力, 在特征提取和特征表示方面较传统方法具有显著优势。一些研究^[26-27]采用级联式检测策略, 先通过传统方法获得初步检测结果, 再利用神经网络进行后处理以增强目标特征表示, 以此降低传统方法的误检率和漏检率。级联式方法虽然可以有效抑制误检并发现更多暗弱目标, 但由于神经网络无法恢复在初始检测阶段已丢失的暗弱目标信息, 第一阶段的检测性能制约了方法整体性能的提升。

为解决上述问题, 一系列端到端的深度学习框架被提出。Chen 等^[10]提出一种密集嵌套层次网络, 提出分段位深分解技术对 16 位深单通道图像进行分层特征增强, 有效解决宽动态范围条件下暗弱目标检测的技术难题, 为解决高动态图像的暗弱目标检测难题提供新的技术路径。Peng 等^[17]结合

Faster R-CNN 与特征金字塔,首次实现宽视场小口径望远镜图像的自动化目标检测和分类,较传统方法目标检测率增加两倍,且瞬态目标识别率提高 25%。Farias 等^[28]基于 Mask R-CNN 开发首个检测、定位与分类一体化的天文图像处理网络,不仅实现了像素级目标分割精度,还达到角秒级的空间定位精度。Jia 等^[29]采用改进的 Faster R-CNN 框架处理斯隆数字巡天(Sloan Digital Sky Survey, SDSS)图像,有效解决传统方法在多波段数据融合方面的技术瓶颈,该网络支持任意数量波段图像的联合分析,还能识别星系等扩展天体目标。目前基于深度学习的方法,根据框架的任务目的及输出形式,主要可将框架划分为语义分割网络和目标检测网络两类。前者能够输出与输入图像同分辨率的高分辨率特征图,有助于更完整地保留暗弱目标的细节信息,从而有效改善因特征表达能力不足引起的漏检和误检问题。然而,该类网络在训练时依赖像素级真值掩码标签,由于原始标签仅包含目标位置及粗略尺度信息,同时天体目标在图像中的排列相对密集,不同亮度、尺度目标间存在干扰,在生成真值掩码标签时在目标边界处容易产生分类模糊或断裂现象,真值掩码标签边界定位的偏差直接影响网络学习性能。后者网络训练时减少了真值掩码生成环节,避免了边界分类的难题,但其在特征提取过程中存在明显的分辨率损失问题,连续的下采样操作使特征图的分辨率逐渐衰减,造成暗弱目标细节信息的大量丢失,最终导致目标与背景间的特征表示区分性不高,增加了漏检的风险。

尽管基于深度学习的方法通过多种技术一

定程度上改良了暗弱目标的检测性能,但仍存在两个关键性缺陷:一是未能充分重视暗弱目标细节信息的保留与利用,二是忽略了前景与背景特征表达的差异性对检测结果的影响。尽可能提高暗弱目标有限信息的利用率,才能增强相关特征的表示,从而提高目标与背景间特征表示的区分度,促进网络加速聚焦目标关键区域,最终提高检测率。

3 原 理

本文提出的 HADN-Net 整体框包括两个核心模块:Mul-GDAM 和 HiFAM。HADN-Net 采用基于 U-Net 改进的密集嵌套结构作为基础框架,确保能够获取高分辨率特征图;Mul-GDAM 作用于骨干网络的每个节点上,采用多感受野特征提取策略用于获取目标细节信息、上下文关联信息和尺度信息,以提高目标信息利用率并实现目标和背景间具有判别性的特征表示;HiFAM 则通过自适应权重分配策略实现多尺度特征图的加权融合,引入跨空间-通道注意力混合机制捕获不同维度下目标的关键信息,增强了各尺度目标在特征图中的特征表示,显著改善融合特征图的质量。最后,对融合特征图进行灰度化并采用基于阈值的二值分割操作得到目标分割结果,结合八连通域提取和质心定位后处理方式实现天体目标的检测。其中,以连通域外接矩形框作为目标预测框,以连通域内原图像中的质心定位结果作为目标定位结果,整体架构设计如图 1 所示。

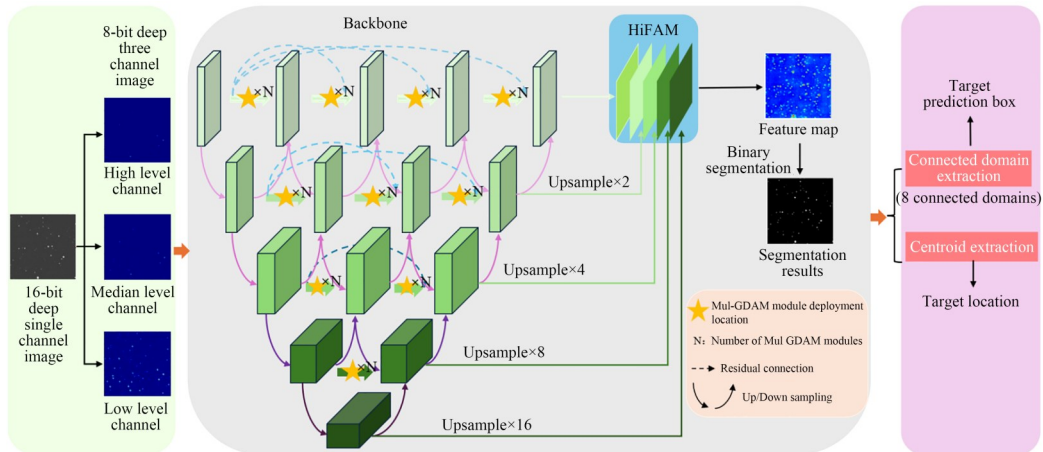


图 1 HADN-Net 的整体架构示意图

Fig. 1 Schematic diagram of overall architecture of HADN-Net

3.1 多分支 Ghost-空洞注意力模块

Mul-GDAM 设计的核心思想是通过建立前景与背景间上下文关联模型获取具有判别性的特征表示,从而提高网络区分目标和背景的能力。针对地基光学图像中暗弱目标通常表现为微弱点目标、像素覆盖范围小等特点, Mul-GDAM 着重挖掘目标局部邻域信息而非全局特征,以获取目标如边缘信息等更多有价值的信息。同时,考虑到细节信息对暗弱目标检测的重要性, Mul-GDAM 采用多分支架构将 ghost 卷积、空洞卷积和 scSE 注意力机制有机结合,实现多感受野特征提取以协同捕获目标细节信息、上下文关联信息和尺度信息,通过建立目标在不同感受野范围内与背景间的上下文联系并在空间维度和通道维度进行动态特征筛选,在抑制噪声的同时有效增强对关键特征的响应。特别地,针对暗弱目标信息丢失问题, Mul-GDAM 还引入一个线性映射分支用于保持输入特征的细节信息,提高了细节信息的可用率。 Mul-GDAM 的整体结构如图 2 所示。

设第 i 层第 j 个特征图编号为 $F_{i,j}$, 则 Mul-GDAM 接受来自三个方向的特征图作为输入特征图:同层的所有浅层特征图 $F_{i,k} \big|_{k=0}^{j-1}$ 以及两个相

邻层特征图 $F_{i-1,j}$ 和 $F_{i+1,j-1}$ 。一般地,输入 Mul-GDAM 的 F 特征可以表示为:

$$F = \text{Concat} [F_{i,k} \big|_{k=0}^{j-1}, C_{s=2}(F_{i+1,j-1}), D_{s=2}(F_{i-1,j})], \quad (1)$$

式中: $\text{Concat} []$ 表示以通道维度进行特征堆叠操作, $C_{s=2}()$ 表示步幅为 2、卷积核为 4 的卷积运算, $D_{s=2}()$ 表示相应的反卷积运算。

Mul-GDAM 采用多感受野特征提取策略,小范围感受野分支专注于提取和增强目标的细节结构特征,具有全局信息关联的大范围感受野分支则致力于建立目标和周边环境的语义关联。 Mul-GDAM 融合了空间和通道双重注意力机制,对来自各分支的特征图及线性映射特征进行跨维度交互处理,有效实现细节特征、上下文信息和尺度特征的协同优化,通过抑制背景噪声突出目标关键信息在特征图中的表示,增强了网络对暗弱目标的识别能力。值得注意的是, Mul-GDAM 巧妙结合了 ghost 卷积和空间因式分解卷积(即 F_2, F_3 分支中 1×3 卷积和 3×1 卷积的级联卷积,其实质等效于 3×3 卷积,但在参数量上有所降低),在保证特征提取性能的前提下大幅降低计算复杂度。 Mul-GDAM 的完整处理流程

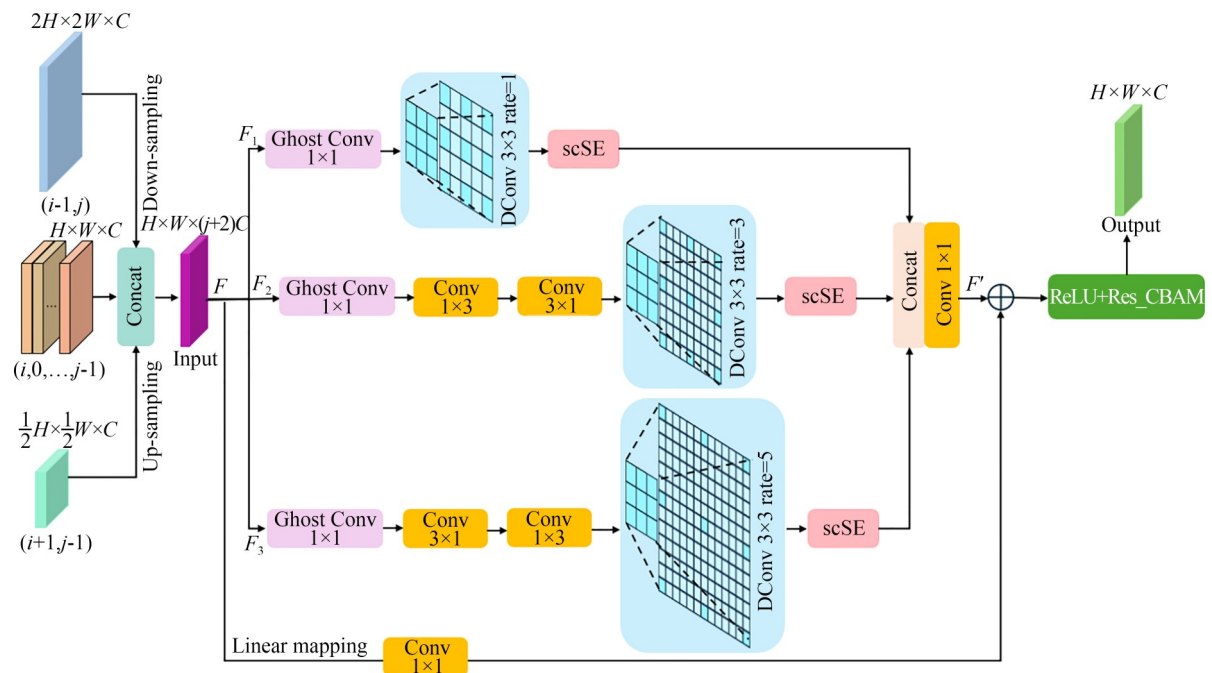


图 2 Mul-GDAM 的结构示意图

Fig. 2 Structural diagram of Mul-GDAM

如下:

$$F_1 = \text{scSE} [\text{DC}_1(\text{GhostConv}_1(F))], \quad (2)$$

$$F_2 = \text{scSE} [\text{DC}_3(\text{Conv}_{3 \times 1}(\text{Conv}_{1 \times 3}(\text{GhostConv}_1(F))))], \quad (3)$$

$$F_3 = \text{scSE} [\text{DC}_5(\text{Conv}_{1 \times 3}(\text{Conv}_{3 \times 1}(\text{GhostConv}_1(F))))], \quad (4)$$

$$F' = \text{Conv}_1(\text{Concat}(F_i)), \quad (5)$$

$$F_{\text{out}} = \text{Res_CBAM} [\text{ReLU}(F' \oplus \text{Conv}_1(F))], \quad (6)$$

式中: $i \in [1, 2, 3]$, F_i 表示对应分支的输出特征图; F 表示 Mul-GDAM 的输入特征图; F_{out} 表示 Mul-GDAM 的输出特征图, 具有与输入特征图相同的分辨率; $\text{GhostConv}_m(\cdot)$ 表示 ghost 卷积, $\text{Conv}_n(\cdot)$ 表示标准卷积, 下标均表示卷积核大小; $\text{DC}_{ra=k}(\cdot)$ 表示空洞卷积, 下标为空洞率; $\text{scSE}(\cdot)$ 表示 scSE 注意力机制; $\text{Res_CBAM}(\cdot)$ 表示基于残差连接的 CBAM 注意力机制; $\text{ReLU}(\cdot)$ 表示 ReLU 激活函数; \oplus 表示逐元素相加操作。

Mul-GDAM 作为网络前端的特征提取器, 是 HADN-Net 实现特征提取的核心模块, 主要负责解决暗弱目标和背景易混淆的问题。经 Mul-GDAM 模块输出的特征图包含多尺度的目标特征, 且特征图中的噪声得到有效抑制, 暗弱目标的特征得到增强, 为后续模块提供了更丰富、更准确的特征表示。

3.2 层次化特征聚合模块

暗弱目标检测中, 尺度特征对于解决目标信号微弱、像素占比小等挑战具有重要作用。通常情况下, 小尺度特征保留暗弱目标的细节信息(也可称为空间位置信息), 但缺乏对目标高层次的语义理解, 大尺度特征则提供目标抽象的语义信息, 难以直观显示目标的像素级信息。由于暗弱目标在图像中的亮度接近背景噪声, 其信号比背景标准差仅高出 1~3 倍, 仅依靠单一尺度特征难以实现目标和背景噪声间的有效区分, 且常规下采样操作会迅速丢失仅占少数像素的暗弱目标信息, 仅凭单一尺度特征难以快速定位暗弱目标关键信息区域, 从而增加网络对该类目标的遗漏概率。因此, 多尺度上下文建模通过促进细节

信息和语义信息间的有效交互, 提供暗弱目标位置信息和语义信息的综合线索, 帮助增强暗弱目标和背景间的特征判别性, 提高网络捕获与保留暗弱目标关键信息的能力。

多尺度特征图的融合构成了实现尺度特征综合利用的典型策略。然而, 以往的研究多采用直接跨层连接多尺度特征图, 这种融合方式并未充分考虑不同尺度特征图的重要性, 可能导致某一尺度特征图中的重要信息被其余尺度特征图中的无关信息所覆盖, 造成融合后特征图出现语义理解偏差或暗弱目标特征表示不完整等问题。

为了解决上述问题, HiFAM 引入跨空间-通道注意力机制生成混合注意力特征图, 实现多尺度特征在两个不同维度间的深度交互, 并在交互过程中采用自适应特征选择策略确定各尺度特征图的重要性权重, 解决了尺度特征图间直接融合存在的语义不一致或目标关键信息丢失问题。针对天体目标尺度差异大的特点, HiFAM 还设计了上下文特征感知单元(Context feature perception)进一步捕捉不同尺度下的目标上下文特征和背景特征, 帮助在高分辨率特征图中识别暗弱目标, 其结构如图 3 所示。HiFAM 充分关注多尺度特征图在空间维度和通道维度中的重要特征并进行自适应加权融合, 提高了暗弱目标在融合特征图中的特征表示质量, 能表示出更多的暗弱目标特征。

对于多尺度特征图 F_k , 首先采用反卷积将其采样至输入图像尺度并实现特征间通道维度的融合, 得到 F' 。其中, k 的取值根据骨干网络的层数而定:

$$F' = \text{Concat} [D_{s=2}(F_k)]. \quad (7)$$

F' 通过上下文特征感知单元捕获特征图中不同尺度的目标线索和背景线索, 通过增强特征图中目标特征的代表能力提高网络对不同尺度目标的感知力:

$$\hat{F} = \text{CFP}(\text{Conv}_1(F')), \quad (8)$$

$$\text{CFP}(\cdot) = \text{Conv}_3(\cdot) \oplus \text{Conv}_5(\cdot) \oplus \text{Conv}_7(\cdot). \quad (9)$$

增强后的特征图 \hat{F} 分别通过空间注意力机制和通道注意力机制生成相应维度注意力图 F^{sa} 和 F^{ca} , 通过混合两维度注意力图得到交互特征图 F_m , F_m 充分考虑了不同空间位置和通道位置

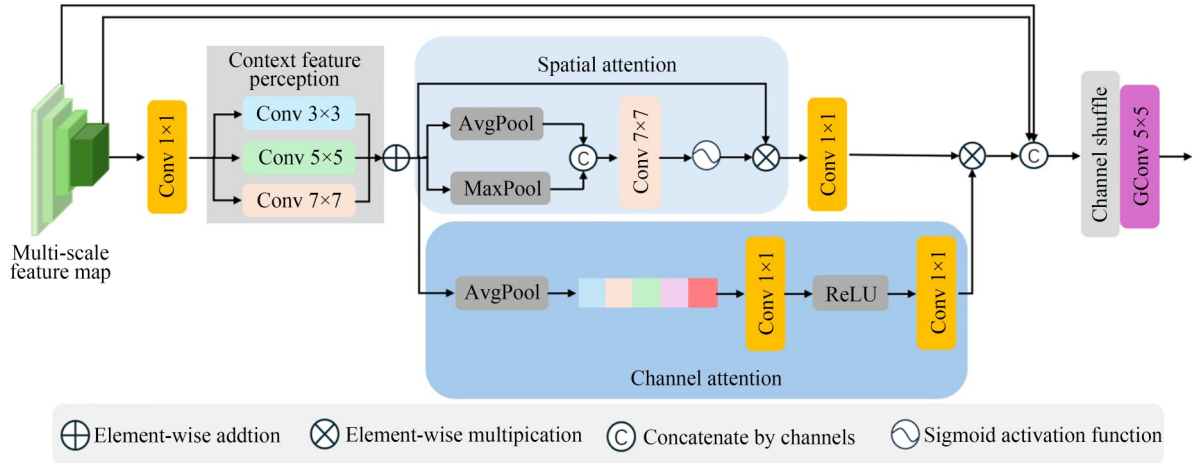


图 3 HiFAM 的结构示意图

Fig. 3 Structural diagram of HiFAM

的特征图重要性,避免特征图在融合过程中关键信息被无关信息所淹没,使得重要信息在融合后特征图上仍得到充分凸显与保留:

$$F_m = \text{Conv}_1(F^{sa}) \otimes F^{ca}, \quad (10)$$

$$F^{sa} =$$

$$\hat{F} \otimes [\sigma(\text{Conv}_7(\text{Concat}[\text{GAP}^s(\hat{F}), \text{GMP}^s(\hat{F})]))], \quad (11)$$

$$F^{ca} = \text{Conv}_1(\text{ReLU}(\text{Conv}_1(\text{GAP}^c(\hat{F})))), \quad (12)$$

式中: F^{sa} 表示经空间注意力机制处理得到的特征图, F^{ca} 表示经通道注意力机制处理得到的特征图; $\sigma(\cdot)$ 表示 sigmoid 激活函数; $\text{GAP}^c(\cdot)$ 和 $\text{GAP}^s(\cdot)$ 分别表示跨通道维度和跨空间维度的全局平均池化操作, $\text{GMP}^s(\cdot)$ 表示跨空间维度的全局最大池化操作。

为了保留原始特征图中有限的目标信息,特别是低级特征图中易被背景淹没的细节信息,额外构建了两个分支用于传输顶层特征图的语义信息和底层特征图的细节信息。最后,通过通道混洗与组卷积操作促进上述所有特征间的交互,帮助网络学习更加丰富的特征表示,提高特征多样性:

$$F_{\text{out}} = \text{GConv}_5(\text{CS}(\text{Concat}[F_s, F_D, F_m])). \quad (13)$$

式中: F_D 表示顶层特征图, F_s 表示底层特征图; $\text{GConv}_k(\cdot)$ 表示组卷积,下标为卷积核大小; $\text{CS}(\cdot)$ 表示通道混洗操作。

通过上述操作,多尺度特征图在融合过程中能够充分考虑目标在空间维度和通道维度中的重要性,并根据该重要性对不同位置或通道

处的特征进行自适应加权处理,使得暗弱目标所在位置处的特征得到更充分的利用,并突出与暗弱目标相关的特征通道。经 HiFAM 模块输出的特征图将来自不同层级和尺度的特征图进行自适应加权整合,能更好表示暗弱目标的综合特征,蕴含暗弱目标丰富的细节信息和语义信息,有效增强了网络感知与表示暗弱目标的能力。

HADN-Net 采用 Mul-GDAM 模块和 HiFAM 模块协同工作的方式,实现了暗弱目标特征的传递与接力处理。Mul-GDAM 模块侧重于特征提取与预处理,用于过滤特征图中的噪声并改善特征质量;HiFAM 模块侧重于特征融合,实现由 Mul-GDAM 模块输出的多尺度高质量暗弱目标特征的整合,提高了特征的代表质量和综合利用率。上述协同工作机制不仅有效发挥各模块的优势,还能实现两者间的功能互补,共同作用于特征处理流程实现暗弱目标特征的筛选、优化与增强,提高了网络检测性能。

3.3 损失函数

HADN-Net 骨干网络采用语义分割网络框架,需要提供像素级真值掩码标签支撑网络训练。而在地基光学图像中,目标的标注数据仅包含目标位置及粗略的尺度信息,加上天体目标本身具有边缘模糊特性,在生成真值掩码时难以精确标注目标边缘像素的类别。考虑到骨干网络训练的最终目的是实现目标的高精度定位,而目标中心区域像素和边缘区域像素对目标定位的

重要性存在显著差异,因此,采用基于二维高斯分布的软真值分割方式生成真值分割图^[10]。具体来说,通过为天体目标中心区域和边缘区域分配不同的监督权重,构建具有空间梯度变化的真值图,从而引导网络在训练过程中更关注对定位起关键作用的区域。

鉴于传统 IoU 度量算法对暗弱目标的变化高度敏感,不适合用于监督网络学习暗弱目标特征,因此,使用改进的基于面积的软 IoU 损失函数^[30]监督网络训练,增强网络对暗弱目标的关注度。软 IoU 损失可以表示为:

$$L_{\text{IoU}} = 1 - \frac{S_{\text{TP}} + s}{S_{\text{pred}} + S_{\text{GT}} - S_{\text{TP}} + s} K, \quad (14)$$

$$K = \frac{S_{\text{GT}} + s}{N_{\text{GT}} + s}, \quad (15)$$

式中: K 为由软分割真值计算的归一化系数,用于消除真值分割图像像素计数和像素值求和不等的影响; S_{TP} , S_{pred} 和 S_{GT} 分别表示正确预测像素值求和、预测像素值求和及真值像素值求和; N_{GT} 表示真值像素数; s 为平滑系数。由于 L_{IoU} 将像素数计数运算改为像素值求和运算,充分利用了软真值分割图中位于目标不同区域的像素权重,有利于提高目标定位结果的准确性并降低网络虚警率。

此外,由于亮目标(通常为大规模目标)包含的像素数通常远多于暗弱目标,目标间存在严重的正样本像素不均衡问题。为了缓解网络过度关注亮目标而忽略暗弱目标像素预测准确性问题,使用基于分布预测的软 Focal 损失函数监督网络^[31]。定义软 Focal 损失函数为:

$$L_{\text{SF}} = -|y - p|^{\beta} [(1 - y) \log(1 - p) + y \log y], \quad (16)$$

式中:对于软分割真值图中的每个像素, y 表示 $[0,1]$ 内连续的真值置信度, p 表示预测置信度; β 为调节因子。通过 L_{SF} 将预测严重偏离真值的像素赋予更高损失权重,帮助网络深度挖掘难分类像素样本特征,提高网络对暗弱目标的检测能力。

因此,HADN-Net 的总损失函数 L_{S} 定义如下:

$$L_{\text{S}} = L_{\text{IoU}} + \alpha L_{\text{SF}}, \quad (17)$$


式中: α 为权重因子,用于平衡 L_{IoU} 和 L_{SF} 对整体损失贡献相近的值,本研究中设置为 0.01。

4 实验

4.1 数据集及预处理

使用 4096×4096 像素的真实地基光学图像作为数据集来验证提出的网络在检测弱小天体目标中的有效性。使用的数据集涵盖多种尺度和亮度的天体,并且绝大多数天体具有尺度小、与背景对比度低的特点,属于弱小天体范畴,为检测带来一定难度。由于原图像尺度过大,不利于网络进行训练,因此,将每张图像切片成 256×256 大小,切片后的图像 90% 用作网络的训练和验证,剩余的 10% 用于测试。真实图像及其详细信息可于中国国家天文数据中心访问:<https://nadc.china-vo.org/data/data/ast3-2-image/f>。

由于天体目标具有尺度跨度大、亮度差异大的特点,图像呈现出一系列不同半径和亮度的圆斑,而使用的地基光学图像以 16 位深单通道 FITS 图像格式保存^[32],其具有 0~32768 的高动态数值范围,这会导致低亮度的暗弱目标和黑暗背景的区分度降低,同时高亮度的天体目标也会掩盖周围低亮度的暗弱目标,给暗弱目标检测带来挑战,如图 4 所示。考虑到天体目标的特性难以改变,因此从降低图像的动态范围入手,采用分段位深分解技术,将 16 位深单通道图像分解为 8 位深三通道图像^[10],降低通道级数值的动态范围,具体实施方式如图 5 所示。分解后的图像在不同通道上保留了不同尺度和亮度目标的特征,如图 6 所示。高位通道(图 6(b))和中位通道(图 6(c))的特征响应上仅存在少数峰值,表明其更多关注于亮星特征的表达,低位通道(图 6(d))在特征响应上具有更多的局部峰值,对应于强度远



(a) 90~3 000

(b) 90~150

图 4 数值动态范围对天体目标检测的影响

Fig. 4 Influence of numerical dynamic range on celestial object detection

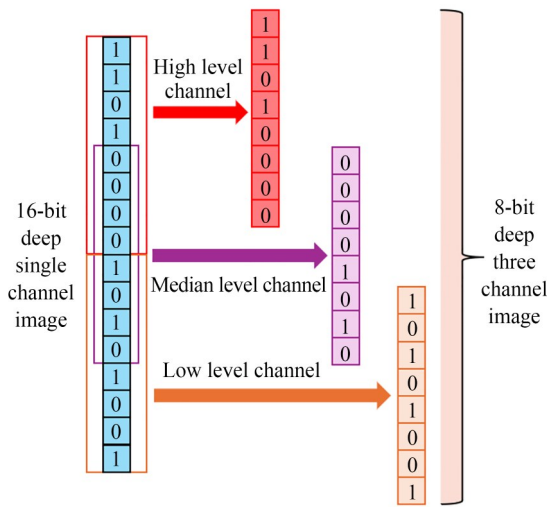


图 5 分段位深分解方法示意图

Fig. 5 Schematic diagram of segmented deep decomposition method

小于亮星而更接近背景的暗弱目标,形成有利于暗弱目标特征增强的表达,三通道并行输入网络较单通道提供了更丰富的特征表示信息,缓解亮星或背景对暗弱目标检测的影响,从而提高了暗弱目标检测率。

4.2 评价指标

为全面评估所提出的检测方法,引入精确

率 (Precision, P)、召回率 (Recall, R)、F1 分数 ($F1$)和虚警率 (False alarm Rate, F_a)4个评价指标。其中,召回率着重衡量检测器捕捉目标的能力,反映检测器在面对所有实际目标时能成功检测出的比例;精确率和虚警率则更聚焦于检测器在辨别目标真假方面的能力,精确率体现了检测器判定为目标的样本中实际为目标的比例,虚警率则表示检测器错误地将非目标判定为目标的情况出现的频率;F1分数是检测器的综合衡量指标,能够平衡精确率和召回率,反映检测器的整体性能。记正确预测目标数为 TP ,错误预测目标数为 FP ,未被检测的真值目标数为 FN ,真值目标总数为 $N = TP + FN$,则上述4个指标如下:

$$P = \frac{TP}{TP + FP} \times 100\%, \quad (18)$$

$$R = \frac{TP}{N} \times 100\% = \frac{TP}{TP + FN} \times 100\%, \quad (19)$$

$$F1 = 2 \times \frac{P \times R}{P + R} \times 100\%, \quad (20)$$

$$F_a = \frac{FP}{N} \times 100\% = \frac{FP}{TP + FN} \times 100\%. \quad (21)$$

本文认为目标丢失产生的危害最为严重,因此在方法评估时优先考虑召回率高的方法。

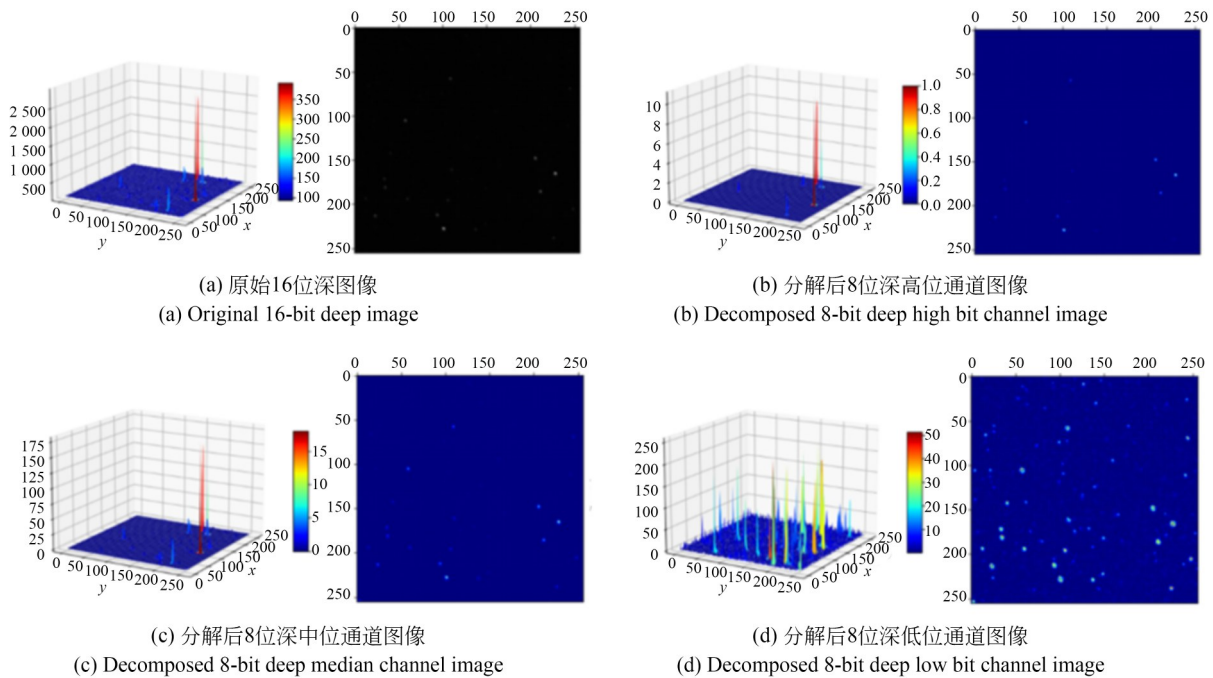


图 6 分段位深分解方法预处理的可视化结果

Fig. 6 Visualization results of pre-processing using segmented deep decomposition method

4.3 实验设置

HADN-Net 参数使用 Xavier 方法进行初始化,初始学习率设置为 0.05,采用余弦学习率调度算法对训练过程中学习率进行调整,批大小设置为 8,使用 Adagrad 优化器进行 100 轮次训练。所有实验均在配备有 Intel Xeon Silver 4210 @ 2.20GHz CPU 和 NVIDIA Quadro GV100 GPU 的计算机上完成。

4.4 对比实验

为了评估提出方法的有效性,与现有的 5 种基于深度学习的先进方法进行了比较:CDN-Net^[10],DNA-Net^[33],StarNet^[34],HCFNet^[35]和 SeRankDet^[36]。实验中对上述方法均进行重新训练,保证各个方法实验设计的一致性,以公正评估各方法性能。

4.4.1 定量结果分析

各方法的定量结果见表 1。HADN-Net 在所有指标上均实现 SOTA 性能,验证了所提方法的有效性,特别是在召回率指标上,较次优方法提高 2.855%,表明 HADN-Net 具有更强的目标检测能力。由于亮星在图像中具有较为明显的特征,更易于网络的学习与表示,可以推断所有方法指标上的差异主要来自暗弱目标检测的影响。现有的深度学习方法缺乏对暗弱目标信息的有效保留与增强,导致网络对暗弱目标信息的利用率和学习率不充足,因此在检测阶段容易忽略与背景相似的暗弱目标,影响最终的检测性能。HADN-Net 的两个核心模块:Mul-GDAM 和 HiFAM,有效缓解了上述问题,保证暗弱目标信息最小损失地在网络传播的同时实现目标特征的增强及关键信息的融合,通过增强有用特征表示并过滤无关特征表示促进网络快速聚焦目标关键区域,从而提高网络区分前景和背景的能力。

表 1 与先进方法的比较结果

Tab. 1 Comparison results with advanced methods(%)


Method	<i>P</i>	<i>R</i>	<i>F1</i>	<i>F_a</i>
CDN-Net ^[10]	91.378	90.853	91.617	8.572
DNA-Net ^[33]	91.699	91.608	91.654	8.292
StarNet ^[34]	92.505	91.793	92.148	7.437
HCFNet ^[35]	94.604	89.368	91.911	5.098
SeRankDet ^[36]	95.485	91.168	93.277	4.311
HADN-Net	95.518	94.648	95.081	4.282

与同样为检测暗弱目标设计的 DNA-Net 网络和 SeRankDet 相比,HADN-Net 在召回率和精确率方面分别提高 3.040%,3.819% 和 3.480%,0.033%,表现优秀。

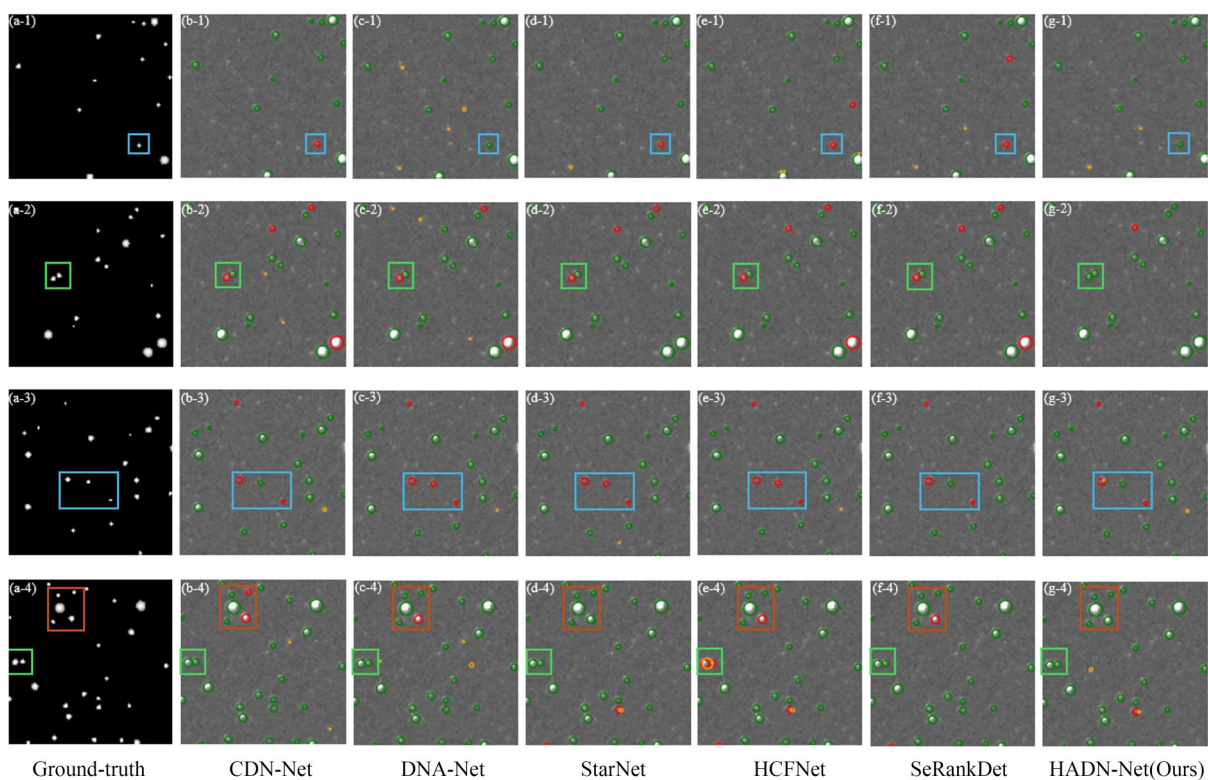
在实际应用中,精确率和召回率之间存在一定的制约关系:召回率指标越高,表明网络漏检的正样本越少,即网络向将更多样本判定为正样本的趋势学习,但这种趋势会增加误检的负样本的概率,从而降低精确率。因此,网络学习的目标之一是找到召回率和精确率间的一个平衡点。从结果来看,绝大多数方法都未能达到召回率和精确率间的最佳平衡状态,而 HADN-Net 在实现高召回率的同时有效保证了检测的精确率,取得了最低的虚警率,检测到的真实目标最多。由定量结果分析可知,HADN-Net 在检测暗弱天体目标方面具有更强的能力。

4.4.2 定性结果分析

基于 4 组随机切片图像检测的可视化结果如图 7(a)所示,绿色圆圈表示正确检测目标,红色圆圈表示漏检目标,黄色圆圈表示误检目标(彩图见期刊电子版)。结果表明,所有方法基本实现对亮天体目标的高质量检测,方法间的性能差距主要体现在暗弱目标检测方面,HADN-Net 在保证亮目标精确检测的同时能检测出更多的暗弱目标,因此在召回率和精确率指标上取得了最优性能。对切片图像的局部区域放大观察(图 7(b))进一步揭示了 HADN-Net 在复杂场景下检测暗弱目标的优势。在单个暗弱目标检测场景(蓝色标注区域)中,虽然所有方法均存在不同程度的漏检现象,但 HADN-Net 展现出更强的检测灵敏度,较多数对比方法能检测到更多的暗弱目标;在暗弱目标间距离接近的场景(绿色标注区域)中,现有的 5 种对比方法表现出较差的检测稳定性,存在目标漏检现象,容易将两个目标识别为一个目标,相比之下,HADN-Net 在不同背景条件下均能有效区分邻近目标间的每个独立目标,展现出更强的空间分辨力和检测稳定性;在亮暗目标混合场景(橙色标注区域)中,暗弱目标的特征信息易受到邻近亮目标干扰,HADN-Net 通过分段位深分解的图像预处理方式和 Mul-GDAM 与 HiFAM 成功克服了亮目标的干扰问题,实现了对亮目标周围暗弱目标的完整检测。



(a) 原始切片图像检测结果
(a) Original slice image detection results



(b) 切片图像局部放大
(b) Localized enlargement of sliced images

图 7 真实地基光学图像上的检测结果
Fig. 7 Detection results on real ground optical images

此外,从可视化结果中也能看出 HADN-Net 具有较小的虚警框,它能在保证高检测率的同时将虚警率控制在最低水平。HADN-Net 在客观性能指标和主观视觉评估两方面都取得了最好的结果,验证了其在天体目标检测特别是暗弱天体目标检测方面的卓越性能。

尽管如此,HADN-Net 仍存在漏检现象,由于天体图像的复杂背景,不同位置处的天体目标受噪声和干扰等因素的影响程度不同,即使通过建模目标与周围环境间的关系能一定程度缓解目标与背景混淆的问题,但在某些干扰严重等复杂背景中暗弱目标信息变得更加微弱,甚至完全被背景淹没,导致网络无法捕获该信息,从而造成漏检。此外,Mul-GDAM 模块更倾向于捕捉暗弱目标的细节特征和上下文特征,其感受野范围并没有设计得很大,由于大目标占据较大空间区域,其特征分布较为分散,当存在足够大的天体目标时,其感受野可能无法完全覆盖大目标的整体范围,难以提取其完整特征,导致漏检。由

于天文图像中像上述大尺度目标较少,且依靠人眼即能实现观察,并不像小尺度目标和暗弱目标需要依赖神经网络进行标注,因此牺牲几个大尺度目标来换取更多小尺度目标甚至暗弱目标的成功检测是可以接受的。

对所有方法的融合特征图进行可视化如图 8 所示,所有特征图均对亮目标展现出足够的关注度与高质量特征表示,但对暗弱目标的关注和特征表示上有所差异:暗弱目标在 DNA-Net 的特征图中特征表示质量差,目标与背景间的特征区分度非常低,尽管目标具有清晰的边界,但目标特征响应微弱基本接近背景噪声水平,人眼难以察觉,这也反映出网络对暗弱目标的关注度明显不足;CDN-Net 的特征图中暗弱目标存在明显的边界干扰现象,邻近目标间边界存在重叠现象,导致目标间的分离性低,影响目标特别是密集目标区域中独立目标的识别(蓝色区域所示);相比之下,HADN-Net 的特征图中目标具有较强的特征响应以及收敛的边界,目标在特征图中的特征




图 8 不同方法的特征结果可视化

Fig. 8 Visualization of feature results from different methods

表示质量明显更高,人眼能够直观观察到特征图中更多的天体目标,且在高密度区域内目标间仍能保持清晰的边界特征。特别是在邻近区域有亮目标干扰的情况下,仍能有效提取暗弱目标信息并在特征图中完整呈现,展现了优秀的抗干扰能力,如红色区域所示。HADN-Net成功捕获了被其他方法遗漏的亮目标周围的暗弱目标,进一步验证了该方法在暗弱目标检测中的优越性能。

4.5 消融实验

消融研究旨在评估提出的各项设计对网络性能的影响,同时探索并确定网络的最佳配置。

4.5.1 预处理方式

为了验证本文使用的分段位深分解技术对提高网络检测暗弱目标能力的有效性,与几种常用的图像预处理方式进行比较,包括:Min-Max归一化方法^[37-38]、标准化方法^[39]和统计阈值截断方法^[40],检测结果如表2所示。Min-Max归一化方法和标准化方法基于全局图像的统计特性进行像素值映射,然而,暗弱目标在全局分布中往往具有与背景相似的统计特征(如均值、方差等),上述方法会因过度依赖图像的整体分布特性而削弱暗弱目标与背景间的局部对比度,从而限制召回率的提升。相比之下,基于图像局部区域的统计阈值截断方法通过动态剔除偏离局部邻域统计值的异常像素,有效抑制背景噪声对暗弱目标检测的干扰,同时能够保留暗弱目标的边缘细节,召回率较全局统计的方法有所提升。分段位深分解方法通过对图像亮度范围进行分段,以此降低图像的数值动态范围并将图像拆解为多个通道,各通道分别聚焦特定亮度区间的目标特征表示,能够凸显不同亮度层次的目标信息,较单通道图像显著提升了暗弱目标在复杂背景下的可辨识度,因此取得了最佳的召回率。

表2 图像预处理方式的消融研究

Tab.2 Research on ablation of image preprocessing methods (%)

Method	<i>P</i>	<i>R</i>	<i>F1</i>	<i>F_a</i>
Normalization	89.161	88.980	89.070	10.817
Standardization	94.129	92.463	93.289	5.768
Sigma-clipping	96.136	93.497	94.798	3.758
Hierarchy	95.518	94.648	95.081	4.282

4.5.2 网络结构

在一般目标检测任务中,网络设计倾向于往深层架构发展,通过逐层抽象获取目标高层语义特征,然而针对暗弱目标特性,过深的网络结构会导致低层细节信息在传播过程中逐渐衰减或丢失,这对信息量本就有限的暗弱目标尤为不利。实验结果如表3所示,随着网络深度从3层增至5层,召回率呈现单调递增的趋势(共提升2.195%),但当深度从5层向6层扩展后,由于浅层信息的不可逆损失,召回率开始出现下降。值得注意的是,3层网络虽然在检测精度(提升1.218%)和虚警率(降低1.163%)两项指标上表现最优,但其召回率显著低于5层网络。综合考量检测性能的均衡性,认为5层网络架构在特征保留与语义提取之间达到最优平衡,能够最大程度地提升整体检测性能。

表3 网络层数的消融研究

Tab.3 Research on ablation of network layers (%)

Method	<i>P</i>	<i>R</i>	<i>F1</i>	<i>F_a</i>
Layer-3	96.736	92.453	94.546	3.119
Layer-4	95.880	93.209	94.525	4.005
Layer-5	95.518	94.648	95.081	4.282
Layer-6	94.368	93.583	93.974	5.586

采样策略的消融结果见表4。传统方法包括池化操作与基于最近邻或双线性插值的重采样技术。最近邻采样选取离采样点最近的像素值作为插值,一定程度上能够保留暗弱目标的边缘特征从而缓解细节信息遗漏的问题。然而,由于该方法忽略了像素间的空间连续性及相关性,重采样后的暗弱目标边缘易出现明显的锯齿效应或几何失真现象,影响目标的准确识别与精确定位。相比之下,双线性插值通过综合考虑采样点水平和垂直方向4个最近邻像素的加权平均值,能够缓解边缘锯齿效应,但其固有的平滑操作会导致暗弱目标的边缘锐度下降,造成细节信息的模糊,从而削弱目标与背景间的可区分性。为提升网络对暗弱目标邻域信息的有效提取与重建能力,HADN-Net采用卷积与反卷积相结合的策略实现特征图分辨率调整,该方案通过卷积核的局部感受野实现特征的高效提取,并利用可学习的反卷积操作逐步恢复空间细节信息,从而增强

暗弱目标信息在深层网络中的传播与浅层网络中的重建。值得注意的是,与传统固定插值方法不同,反卷积层的权重可通过端到端训练过程自适应优化,使其能够更好地适应复杂场景变化和

目标特性差异,这种自主学习的方式赋予网络更强的暗弱目标特征表示能力和细节信息恢复能力,因此,在多项指标中特别是召回率指标上展现了最优性能。

表 4 采样策略的消融研究

Tab. 4 Research on ablation of sampling strategy

(%)

Method	P	R	$F1$	F_a
Nearest neighbor sampling	96.623	93.174	94.867	3.257
Bilinear interpolation sampling	96.871	93.168	94.983	3.009
Conv+DConv	95.518	94.648	95.081	4.282

4.5.3 网络组件

Mul-GDAM 和 HiFAM 在暗弱目标特征提取及网络关注机制方面的影响,如图 9 所示,展现了对基线模型、单独引入各模块及联合引入两模块的特征热力图可视化结果。可以看出,基线模型仅对亮目标表现出显著关注度,而对暗弱目标的关注度严重不足,导致多数暗弱目标在特征热力图中几乎完全淹没于背景噪声之中;单独引入 HiFAM 后,热力图呈现出更多可辨识的暗弱目标响应区域,表明 HiFAM 能够有效保留特征图中暗弱目标的微弱特征信息,引导网络增强对低信噪比目标的关注度;单独引入 Mul-GDAM 后,所有目标的特征均呈现更高的响应强度及更聚

焦的空间分布,证明 Mul-GDAM 不仅优化了暗弱目标的特征表示能力、提高网络对其的关注度,还提高了目标的空间定位精度,使网络能够更高效地捕捉目标关键信息区域;当同时引入两模块时,特征热力图中不同亮度目标的响应强度趋于一致,表明网络对亮目标和暗弱目标基本实现同等的关注度,这一结果验证了 HiFAM 与 Mul-GDAM 的协同工作在暗弱目标信息保留、特征表示增强及关键性信息融合方面的重要作用,充分证明所提模块在提升暗弱目标检测性能方面的有效性。表 5 给出了定量分析结果,为 Mul-GDAM 和 HiFAM 的有效性提供数据支撑。




图 9 不同网络组件特征热力图的可视化结果

Fig. 9 Visualization results of heat maps of different network component characteristic

作为 HADN-Net 特征提取的核心模块, Mul-GDAM 在节点中的级联个数对网络性能的影响如表 6 所示。在暗弱目标检测任务中,仅使用单个 Mul-GDAM 模块即可取得最高的召回率,并实现召回率与检测精度间的最优平衡。由于

Mul-GDAM 模块本身即针对暗弱天体目标特性进行设计,其多分支架构已具备较强的暗弱目标特征提取能力,当级联个数过多时可能存在过拟合风险。更多的参数赋予网络更强的数据学习能力,但由于暗弱目标有效信息匮乏,网络能学

表 5 网络组件的消融研究

Tab. 5 Research on ablation of network components

(%)

Baseline	HiFAM	Mul-GDAM	P	R	$F1$	F_a
✓			95.668	86.029	90.593	4.186
✓	✓		95.699	91.556	93.582	4.115
✓		✓	95.828	93.655	94.729	4.077
✓	✓	✓	95.518	94.648	95.081	4.282

表 6 Mul-GDAM 级联个数的消融研究

Tab. 6 Research on ablation of Mul-GDAM cascade number

(%)

Cascade quantity	P	R	$F1$	F_a
Cascade-1	95.518	94.648	95.081	4.282
Cascade-2	94.944	93.205	94.066	4.964
Cascade-3	96.287	93.710	94.981	3.614

习到数据中更多的亮目标、噪声等特征,从而对召回率产生负面影响;此外,过多的级联数量可能导致特征饱和问题,后端的级联模块会对前端模块已提取的特征进行过度细化,甚至引入冗余或干扰信息,使得特征的有效性和区分度降低,影响网络对暗弱目标的准确检测。单个 Mul-GDAM 模块取得了最高的召回率和 F1 分数,表

明它已具备精准捕捉暗弱目标关键信息的能力,较多模块级联而言在降低计算复杂度的同时避免了网络过拟合或特征饱和问题,在提高网络召回率以及整体性能方面具有更为优秀的表现,因此,在 HADN-Net 骨干网络的每个节点处仅使用 1 个 Mul-GDAM 模块作为特征提取器。

图 10 展示了上述不同设计方式下网络训练过程中召回率随训练轮次的变化情况(仅包含 70~100epoch,此阶段络训练已相对稳定)。可以看出,当网络的图像预处理方式采用分段位深分解方式、采样方式采用卷积-反卷积方式、网络层数设置为 5、Mul-GDAM 模块级联个数设置为 1、采用 Mul-GDAM 模块和 HiFAM 模块协同工作时,网络整体性能达到最优,因此,上述设计组合为最优的网络设置。

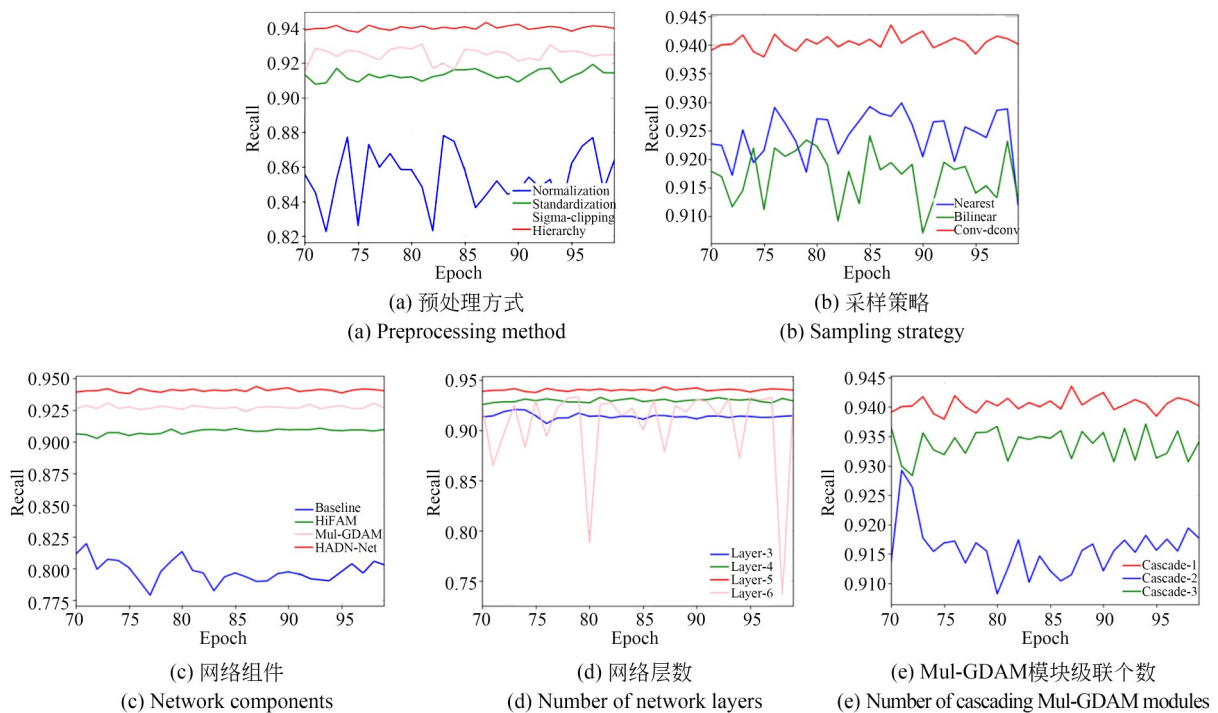


图 10 不同设计下网络召回率的变化情况

Fig. 10 Changes in network recall rate under different designs

5 结 论

本文提出了一种面向暗弱天体目标检测的网络 HADN-Net,并提出了 Mul-GDAM 和 Hi-FAM,显著提升了暗弱天体目标的检测性能。Mul-GDAM 采用多感受野特征提取机制,深入挖掘暗弱目标局部邻域的多尺度上下文信息,建立目标与背景间的判别性特征表示,在有效抑制背景噪声的同时显著增强了暗弱目标在特征图上的响应强度,使网络能够快速定位目标关键区域,提高了网络发现与捕获暗弱目标的能力;Hi-FAM 采用跨维度特征交互机制实现多尺度特征图的自适应加权融合,解决了传统多尺度融合中的语义不一致性问题,并通过特征选择机制突出各尺度特征图中的关键信息,显著提升了融合特征图中暗弱目标的特征表征能力,提高了融合质

量。在真实地基光学数据集上进行实验,HADN-Net 取得了 94.648% 的召回率、95.518% 的检测精度和 95.081% 的 F1 分数,相较于 5 种先进方法在各项评价指标上均达到了最优性能,特别是在召回率指标上较次优方法提升 2.855%,验证了提出方法在天体目标检测方面的有效性。消融实验和特征可视化分析进一步验证了所提网络在暗弱天体目标特征捕获和表征方面的优越性,为暗弱天体目标检测领域提供了有效的解决方案。

作者贡献声明:

徐礼珺:改进方法的提出,实验操作与分析,论文撰写;

薛武:论文构思,资源提供,实验设计与数据整理,论文的审核与编辑。

参考文献:

- [1] KARPOV S, MALKOV O, AVDEEVA A. New ultracool dwarf candidates from multi-epoch WISE data [J]. *Astronomy & Astrophysics*, 2025, 695: A195.
- [2] 焦建超,王超,俞越,等. 轻型高灵敏暗弱空间目标探测光学相机技术[J]. *红外与激光工程*, 2023, 52(5): 272-277.
JIAO J CH, WANG CH, YU Y, *et al.* Lightweight and high-sensitive optical camera technology for faint space target detection [J]. *Infrared and Laser Engineering*, 2023, 52(5): 272-277. (in Chinese)
- [3] DING Z G, WANG G X, ZHANG T Y, *et al.* A parametric 3-D ISAR imaging method of celestial target under low SNR [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5216118.
- [4] QUAN F H, LIU S, SUN G F, *et al.* A compensation method for full-field-of-view energy nonuniformity in dark-and-weak-target simulators [J]. *Sensors*, 2024, 24(13): 4147.
- [5] EUBANKS T M. High-drag interstellar objects and galactic dynamical streams [J]. *The Astrophysical Journal Letters*, 2019, 874(2): L11.
- [6] SAMIA S, AFROGE S. Detection and segmentation of cosmic objects based on adaptive thresholding and back propagation neural network[J/OL]. *Arxiv*. 2023. [2024-05-25]. <https://arxiv.org/abs/2308.00926>. DOI:arXiv:2308.00926
- [7] VALLENARI G C A, BROWN A G A, PRUSTI T, *et al.* Gaia Data Release 3 Summary of the content and survey properties [J]. *Astronomy & Astrophysics*. 2023, 674, A1.
- [8] IRURETA-GOYENA B Y, RACHITH E, HELLMICH S, *et al.* A method for asteroid detection using convolutional neural networks on VST images [J]. *Astronomy & Astrophysics*, 2025, 694: A49.
- [9] FARIAS H, ORTIZ D, DAMKE G, *et al.* Mask galaxy: morphological segmentation of galaxies [J]. *Astronomy and Computing*, 2020, 33: 100420.
- [10] CHEN G, XUE B D, LI X Y, *et al.* CDN-net: faint celestial target detection based on densely nested hierarchical network [J]. *The Astronomical Journal*, 2025, 169(3): 146.
- [11] YAN R Q, YIN Z Y, DAI C, *et al.* Weak celestial source fringes detection based on multi-task learning and pseudo soft threshold residual denoising network [J]. *Digital Signal Processing*, 2025, 159: 105014.
- [12] ZHANG Z, JIANG B, ZHANG Y X. Automatic detection and classification of radio galaxy images by deep learning [J]. *Publications of the Astronomical Society of the Pacific*, 2022, 134 (1036) : 064503.

- [13] SORTINO R, MAGRO D, FIAMENI G, *et al.* Radio astronomical images object detection and segmentation: a benchmark on deep learning methods [J]. *Experimental Astronomy*, 2023, 56 (1) : 293-331.
- [14] RIZZUTO S S, CIPOLLONE R, DE VITTORI A, *et al.* Object detection on space-based optical images leveraging machine learning techniques[J]. *Neural Computing and Applications*, 2025, 37 (22): 17153-17177.
- [15] LIU L, SUN R Y, ZHAO H. Identification of megaconstellations in wide-field astronomical images with machine learning [J]. *The Astronomical Journal*, 2025, 169(4): 205.
- [16] LEE A, KAVELAARS J J, TEIMOORINIA H, *et al.* A convolutional neural network - based approach for detecting solar system objects in wide-field imaging [J]. *The Planetary Science Journal*, 2025, 6(6): 147.
- [17] JIA P, LIU Q, SUN Y Y. Detection and classification of astronomical targets with deep neural networks in wide-field small aperture telescopes [J]. *The Astronomical Journal*, 2020, 159(5): 212.
- [18] FITZPATRICK M, VINICIUS M P, ADAM B, *et al.* Modernizing iraf to support gemini data reduction [J/OL]. *Arxiv*. 2024. [2025-04-04]. <https://arxiv.org/abs/2401.01982>. DOI: arXiv: 2401.01982.
- [19] COLLABORATION T A, ROBITAILLE T P, TOLLERUD E J, *et al.* Astropy: a community Python package for astronomy [J]. *Astronomy & Astrophysics*, 2013, 558: A33.
- [20] BERTIN E, ARNOUTS S. SExtractor: software for source extraction [J]. *Astronomy and Astrophysics Supplement Series*, 1996, 117 (2) : 393-404.
- [21] TEENINGA P, MOSCHINI U, TRAGER S C, *et al.* Statistical attribute filtering to detect faint extended astronomical sources [J]. *Mathematical Morphology-Theory and Applications*, 2016, 1 (1):100-115.
- [22] ROBOTHAM A S G, DAVIES L J M, DRIVER S P, *et al.* ProFound: source extraction and application to modern survey DataFree[J]. *Monthly Notices of the Royal Astronomical Society*, 2018, 476(3): 3137-3159.
- [23] SHARMA K, KUMAR H, CHOUDHARY H, *et al.* Astreaks: astrometry of NEOs with trailed background stars[J]. *Monthly Notices of the Royal Astronomical Society*, 2023, 524(2): 2651-2660.
- [24] COLLINS K A, KIELKOPF J F, STASSUN K G, *et al.* Astroimagej: image processing and photometric extraction for ultra-precise astronomical light curves[J]. *The Astronomical Journal*, 2017, 153(2): 77.
- [25] COLLABORATION T A, ROBITAILLE T P, TOLLERUD E J, *et al.* Astropy: a community Python package for astronomy [J]. *Astronomy & Astrophysics*, 2013, 558: A33.
- [26] JIA P, ZHAO Y F, XUE G, *et al.* Optical transient object classification in wide-field small aperture telescopes with a neural network[J]. *The Astronomical Journal*, 2019, 157(6): 250.
- [27] TURPIN D, GANET M, ANTIER S, *et al.* Vetting the optical transient candidates detected by the GWAC network using convolutional neural networksFree [J]. *Monthly Notices of the Royal Astronomical Society*, 2020, 497(3): 2641-2650.
- [28] FARIAS H, ORTIZ D, DAMKE G, *et al.* Mask galaxy: morphological segmentation of galaxies [J]. *Astronomy and Computing*, 2020, 33: 100420.
- [29] JIA P, ZHENG Y, WANG M, *et al.* A deep learning based astronomical target detection framework for multi-colour photometry sky survey projects [J]. *Astronomy and Computing*, 2023, 42: 100687.
- [30] RAHMAN M A, WANG Y. *Optimizing Intersection-over-union in Deep Neural Networks for Image Segmentation* [M]. *Advances in Visual Computing*. Cham: Springer International Publishing, 2016: 234-244.
- [31] LIN T Y, GOYAL P, GIRSHICK R, *et al.* Focal loss for dense object detection[C]. *2017 IEEE International Conference on Computer Vision (ICCV)*. October 22-29, 2017, Venice, Italy. IEEE, 2017: 2999-3007.
- [32] HANISCH R J, FARRIS A, GREISEN E W, *et al.* Definition of the flexible image transport system (FITS) [J]. *Astronomy & Astrophysics*, 2001, 376(1): 359-380.
- [33] LI B Y, XIAO C, WANG L G, *et al.* Dense nested attention network for infrared small target detection[J]. *IEEE Transactions on Image Processing*,

- 2022, 32: 1745-1758.
- [34] XUE D N, SUN J Q, HU Y Q, *et al.* Dim small target detection based on convolutinal neural network in star image[J]. *Multimedia Tools and Applications*, 2020, 79(7): 4681-4698.
- [35] XU S B, ZHENG S C, XU W H, *et al.* HCF-net: hierarchical context fusion network for infrared small object detection[C]. *2024 IEEE International Conference on Multimedia and Expo (ICME)*. July 15-19, 2024, Niagara Falls, ON, Canada. IEEE, 2024: 1-6.
- [36] DAI Y M, PAN P W, QIAN Y L, *et al.* Pick of the bunch: detecting infrared small targets beyond hit-miss trade-offs *via* selective rank-aware attention[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5006215.
- [37] SUMITH K V. Comprehensive evaluation of satellite-based rainfall measurements through rain gauge validation using advanced statistical regression and machine learning models by using Python[J]. *Water Resources Management*, 2025, 39(9): 4563-4587.
- [38] ZHANG Y, GAO H. Development and nursing application of kidney disease prediction models based on machine learning[J]. *Computer Methods in Biomechanics and Biomedical Engineering*, 2025: 1-12.
- [39] CAO L, JIA P, LI J X, *et al.* Image preprocessing framework for time-domain astronomy in the artificial intelligence era[J]. *The Astronomical Journal*, 2025, 169(4): 215.
- [40] YAO G L. A survey on pre-processing in image matting [J]. *Journal of Computer Science and Technology*, 2017, 32(1): 122-138.

作者简介:



徐礼珺(2002—),女,湖南益阳人,硕士研究生,2023年于航天工程大学获得学士学位,主要从事光学天文图像处理、计算机视觉、图像处理等方面的研究。E-mail: LiJun_Xu@hgd.edu.cn

通讯作者:



薛武(1988—),男,山东宁阳人,博士,副研究员,2011年、2014年、2017年于信息工程大学分别获得学士、硕士和博士学位,主要从事光学遥感信息处理方面的研究。E-mail: xuewu_81@126.com